

Modelo Computacional de Aprendizaje Adaptativo Basado en Machine Learning para la Optimización de Procesos de Enseñanza en Entornos Digitales

Computational Model of Adaptive Learning Based on Machine Learning for the Optimization of Teaching Processes in Digital Environments

Arturo González Torres ¹[0000-0002-3337-7600] Marina Imelda Terrazas Gómez ²[0000-0002-6559-4052]
Jordy Christian Granda Feijoo ³[0000-0001-6767-6409] Vinicio Alexander Chávez Vaca ⁴[0000-0003-3623-4178]

¹ Instituto Tecnológico de Milpa Alta, México, arturo.gt@milpaalta.tecnm.mx

² Universidad Autónoma de Chihuahua, Delicias, Chihuahua, México, miterrazas@uach.mx

³ Universidad Nacional de Loja, Grupo Investigación InnoTEFL, Loja, Ecuador, jordy.granda@unl.edu.ec

⁴ Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López, Calceta, Manabí, Ecuador, vachavez@esepam.edu.ec

CITA EN APA:

González Torres, A., Terrazas Gómez, M. I., Granda Feijoo, J. C., & Chávez Vaca, V. A. (2026). Modelo Computacional de Aprendizaje Adaptativo Basado en Machine Learning para la Optimización de Procesos de Enseñanza en Entornos Digitales. *Technology Rain Journal*, 5(1), e138. Recuperado a partir de <https://technologyrain.com.ar/index.php/trj/article/view/138>

Recibido: 02 de marzo del 2026

Aceptado: 19 de mayo del 2026

Publicado: 08 de junio del 2026

Technology Rain Journal
ISSN: 2953-464X



Los contenidos de este artículo están bajo una licencia de Creative Commons Attribution 4.0 International (CC BY 4.0)

Los autores conservan los derechos morales y patrimoniales de sus obras.

Resumen: El presente artículo analiza el modelo de aprendizaje adaptativo basado en machine learning como estrategia para optimizar los procesos de enseñanza en entornos educativos mediados por tecnología. A través de una revisión bibliográfica sistemática bajo el enfoque PRISMA, se examinaron estudios recientes relacionados con inteligencia artificial educativa, analítica del aprendizaje, minería de datos educativos, sistemas de recomendación y personalización del aprendizaje. Los resultados evidencian que los algoritmos de machine learning permiten predecir el rendimiento académico, detectar estudiantes en riesgo, construir perfiles dinámicos y recomendar recursos, actividades o rutas formativas ajustadas a las necesidades individuales. Asimismo, se identifica que la efectividad de estos modelos depende de la calidad de los datos, la explicabilidad algorítmica, la privacidad, la interoperabilidad tecnológica y la participación del docente. Se concluye que el aprendizaje adaptativo debe entenderse como un ecosistema sociotécnico que integra datos, algoritmos, pedagogía y acompañamiento humano para favorecer una enseñanza más personalizada, oportuna, ética y centrada en el estudiante, con impacto potencial en la mejora continua de la calidad educativa institucional actual.

Palabras clave: machine learning, inteligencia artificial, analítica del aprendizaje, minería de datos educativos, personalización del aprendizaje, procesos de enseñanza.

Abstract: This article analyzes an adaptive learning model based on machine learning as a strategy to optimize teaching processes in technology-mediated educational environments. Through a systematic literature review following the PRISMA approach, recent studies related to educational artificial intelligence, learning analytics, educational data mining, recommendation systems, and learning personalization were examined. The results show that machine learning algorithms make it possible to predict academic performance, detect at-risk students, build dynamic profiles, and recommend resources, activities, or learning paths adjusted to individual needs. Likewise, the effectiveness of these models depends on data quality, algorithmic explainability, privacy, technological interoperability, and the active participation of teachers. It is concluded that adaptive learning should be understood as a sociotechnical ecosystem that integrates data, algorithms, pedagogy, and human support to promote more personalized, timely, ethical, and student-centered teaching, with potential impact on the continuous improvement of current institutional educational quality.

Keywords: machine learning, artificial intelligence, learning analytics, educational data mining, learning personalization, teaching processes.

1. INTRODUCCIÓN

La transformación digital de los sistemas educativos ha impulsado el desarrollo de entornos de aprendizaje cada vez más flexibles, personalizados y mediados por tecnologías inteligentes. En este contexto, el aprendizaje adaptativo se ha consolidado como una línea de investigación estratégica dentro de la informática educativa, al permitir que los sistemas ajusten contenidos, recursos, actividades, evaluaciones y retroalimentaciones de acuerdo con las características, necesidades y desempeño de cada estudiante. A diferencia de los modelos tradicionales de enseñanza, basados en rutas homogéneas de aprendizaje, los sistemas adaptativos buscan responder dinámicamente a la diversidad de perfiles cognitivos, ritmos de avance, estilos de interacción y niveles de dominio presentes en los entornos educativos contemporáneos (Kabudi et al., 2021).

El crecimiento de la inteligencia artificial y del aprendizaje automático ha ampliado significativamente las posibilidades técnicas del aprendizaje adaptativo. Los algoritmos de *machine learning* permiten analizar grandes volúmenes de datos educativos generados en plataformas virtuales, sistemas de gestión del aprendizaje, entornos colaborativos, evaluaciones digitales y recursos interactivos. A partir de estos datos, es posible identificar patrones de comportamiento, predecir el rendimiento académico, detectar riesgos de abandono, recomendar recursos personalizados y ajustar la secuencia de aprendizaje de manera automatizada (Ersozlu et al., 2024; Sghir et al., 2023). En consecuencia, el aprendizaje adaptativo basado en *machine learning* no solo representa una innovación pedagógica, sino también un campo de aplicación computacional que integra minería de datos educativos, analítica del aprendizaje, sistemas de recomendación, procesamiento de lenguaje natural, modelos predictivos y técnicas de inteligencia artificial explicable.

Diversas revisiones recientes evidencian que los sistemas adaptativos apoyados en inteligencia artificial han demostrado potencial para mejorar la personalización del aprendizaje, incrementar la participación estudiantil y optimizar la toma de decisiones docentes. Gligorea et al. (2023) destacan que la inteligencia artificial en entornos de *e-learning* permite configurar experiencias formativas individualizadas mediante la selección dinámica de contenidos, la adaptación de actividades y la retroalimentación personalizada.

De manera similar, du Plooy et al. (2024) señalan que el aprendizaje adaptativo personalizado en educación superior puede incidir positivamente en el rendimiento académico y el compromiso del estudiante, especialmente cuando los sistemas consideran variables relacionadas con el progreso, la interacción y las necesidades formativas. Estas posibilidades resultan

particularmente relevantes para instituciones que buscan mejorar la eficiencia de sus procesos de enseñanza mediante tecnologías basadas en datos.

Desde la perspectiva informática, el diseño de modelos de aprendizaje adaptativo exige una arquitectura capaz de integrar múltiples componentes tecnológicos. Entre ellos se incluyen la captura y preprocesamiento de datos educativos, la construcción de perfiles del estudiante, la selección de algoritmos de predicción, la generación de recomendaciones, la adaptación de contenidos y la visualización de resultados mediante paneles de analítica. En este sentido, la analítica del aprendizaje constituye un elemento clave, ya que permite transformar los datos generados por los estudiantes en información útil para docentes, tutores, gestores académicos y sistemas automatizados de intervención (Paulsen & Lindsay, 2024). Asimismo, los avances en aprendizaje profundo han permitido desarrollar modelos más sofisticados para representar trayectorias de aprendizaje, estimar niveles de conocimiento y anticipar comportamientos académicos complejos (Lin et al., 2025).

No obstante, la implementación de sistemas adaptativos basados en *machine learning* presenta desafíos importantes. Uno de los principales retos se relaciona con la calidad, disponibilidad e interoperabilidad de los datos educativos, debido a que los modelos predictivos dependen de información precisa, actualizada y representativa. Además, existen preocupaciones vinculadas con la privacidad, el sesgo algorítmico, la transparencia de las decisiones automatizadas y la aceptación de estas tecnologías por parte de docentes y estudiantes (Alfredo et al., 2024). La literatura reciente también advierte que muchos sistemas de inteligencia artificial aplicados a la educación carecen de enfoques suficientemente centrados en el ser humano, lo que puede limitar su utilidad pedagógica y su adopción institucional. Por ello, el desarrollo de modelos adaptativos debe equilibrar la eficiencia computacional con criterios éticos, pedagógicos y de explicabilidad.

En los últimos años, la investigación ha evolucionado desde modelos adaptativos centrados únicamente en reglas predefinidas hacia enfoques más robustos basados en aprendizaje automático, inteligencia artificial generativa y procesamiento de lenguaje natural. El uso de técnicas de NLP permite analizar respuestas abiertas, interacciones discursivas y necesidades comunicativas del estudiante, favoreciendo una personalización más profunda de la retroalimentación y de las rutas formativas (Tan et al., 2025). Asimismo, propuestas recientes como AdaptiveGPT evidencian el potencial de los modelos generativos para construir experiencias de aprendizaje más interactivas, inteligentes y contextualizadas (Sachete et al., 2024). Sin embargo, estas innovaciones requieren evaluaciones rigurosas que permitan determinar su impacto real en los procesos de enseñanza, así como sus limitaciones técnicas y pedagógicas.

En este escenario, resulta pertinente desarrollar una revisión bibliográfica orientada a analizar los fundamentos, avances, aplicaciones y desafíos de los modelos de aprendizaje adaptativo basados en *machine learning* para la optimización de los procesos de enseñanza. Esta revisión busca aportar una visión integradora desde el campo de la informática, considerando tanto los componentes tecnológicos como las implicaciones educativas de estos sistemas. Para ello, se examinan estudios recientes sobre inteligencia artificial en educación, minería de datos educativos, analítica del aprendizaje, sistemas adaptativos, aprendizaje personalizado y modelos predictivos aplicados a entornos formativos. El propósito es identificar tendencias actuales, técnicas predominantes, oportunidades de implementación y brechas de investigación que permitan sustentar el diseño de un modelo conceptual orientado a mejorar la personalización, eficiencia y calidad de los procesos de enseñanza mediante tecnologías inteligentes.

De esta manera, el presente artículo contribuye al debate académico al sistematizar evidencia reciente sobre el uso de *machine learning* en el aprendizaje adaptativo y al proponer una base teórica para el desarrollo de soluciones informáticas aplicadas a la educación. En particular, se enfatiza la necesidad de diseñar modelos que no solo automaticen decisiones pedagógicas, sino que también fortalezcan el rol del docente, promuevan la equidad en el acceso al aprendizaje personalizado y garanticen la transparencia de los procesos algorítmicos. En consecuencia, el aprendizaje adaptativo basado en *machine learning* se posiciona como una alternativa prometedora para optimizar la enseñanza, siempre que su implementación se fundamente en criterios técnicos sólidos, evidencia empírica actualizada y principios éticos centrados en el estudiante.

2. MARCO TEÓRICO

El aprendizaje adaptativo basado en *machine learning* surge como respuesta a una necesidad cada vez más evidente en los sistemas educativos actuales: no todos los estudiantes aprenden al mismo ritmo, de la misma manera ni con las mismas necesidades. En los entornos tradicionales, la enseñanza suele organizarse mediante rutas homogéneas, en las que todos los estudiantes reciben los mismos contenidos, actividades y evaluaciones. Sin embargo, esta lógica resulta limitada cuando se considera la diversidad de estilos de aprendizaje, niveles de conocimiento previo, motivación, desempeño académico y formas de interacción con la tecnología. En este sentido, el aprendizaje adaptativo propone una enseñanza más flexible, capaz de ajustarse al estudiante en función de los datos que genera durante su proceso formativo (Kabudi et al., 2021).

Desde una perspectiva conceptual, el aprendizaje adaptativo puede entenderse como un enfoque educativo mediado por tecnología que modifica dinámicamente la experiencia de

aprendizaje de acuerdo con las características y necesidades del estudiante. Esta adaptación puede darse en diferentes niveles: en la selección de contenidos, en la dificultad de las actividades, en el tipo de retroalimentación, en la secuencia de aprendizaje o en la forma de evaluación. Lo relevante no es únicamente que el sistema “personalice” recursos, sino que lo haga a partir de evidencias concretas sobre el comportamiento y progreso del estudiante. Por ello, el aprendizaje adaptativo no debe verse solo como una herramienta tecnológica, sino como un modelo de enseñanza apoyado en datos, donde la información obtenida permite tomar decisiones más oportunas y pertinentes (Gligorea et al., 2023).

En este contexto, el *machine learning* cumple un papel fundamental, ya que permite que los sistemas aprendan de los datos educativos y detecten patrones que no siempre son visibles para el docente. A través de algoritmos de clasificación, regresión, agrupamiento, sistemas de recomendación o aprendizaje profundo, es posible analizar variables como calificaciones, tiempo de conexión, número de intentos, participación en actividades, respuestas incorrectas, secuencias de navegación y desempeño en evaluaciones. A partir de estos datos, los modelos pueden predecir riesgos académicos, identificar necesidades de refuerzo, recomendar materiales personalizados o sugerir intervenciones docentes (Ersozlu et al., 2024; Sghir et al., 2023). Esto convierte al *machine learning* en un componente técnico clave para optimizar los procesos de enseñanza.

No obstante, es importante analizar que el uso de *machine learning* en educación no debe reducirse a la automatización de decisiones. Si bien los algoritmos pueden procesar grandes volúmenes de datos y generar predicciones con rapidez, el proceso educativo sigue siendo profundamente humano. Un modelo adaptativo útil debe complementar la labor docente, no sustituirla. El docente conserva un papel esencial en la interpretación pedagógica de los resultados, en la toma de decisiones contextualizadas y en el acompañamiento emocional y académico del estudiante. Por ello, los sistemas adaptativos más pertinentes son aquellos que integran la inteligencia artificial como apoyo a la enseñanza, manteniendo al profesor como mediador principal del proceso formativo (Alfredo et al., 2024; Wang et al., 2024).

La analítica del aprendizaje constituye otro fundamento central dentro de estos modelos. Su función consiste en recopilar, procesar e interpretar datos generados por los estudiantes en plataformas digitales, con el propósito de mejorar el aprendizaje y la enseñanza. A diferencia de una simple medición del rendimiento, la analítica del aprendizaje permite observar trayectorias, detectar dificultades tempranas y generar información útil para la intervención pedagógica. En un modelo adaptativo, esta analítica puede alimentar paneles de control, alertas tempranas, sistemas de recomendación y mecanismos de retroalimentación personalizada (Muslim et al., 2023; Paulsen &

Lindsay, 2024). De esta manera, los datos dejan de ser registros pasivos y se convierten en insumos estratégicos para la mejora educativa.

Un aspecto relevante es que la adaptación no ocurre de manera aislada, sino dentro de una arquitectura tecnológica compuesta por varios elementos. En primer lugar, se requiere una capa de recolección de datos, encargada de capturar la interacción del estudiante con el entorno virtual. En segundo lugar, se necesita una capa de procesamiento, donde los datos son limpiados, organizados y transformados. En tercer lugar, interviene una capa algorítmica, en la que los modelos de *machine learning* analizan la información y generan predicciones o recomendaciones. Finalmente, se encuentra una capa de intervención, donde el sistema adapta contenidos, actividades, evaluaciones o alertas para docentes y estudiantes. Esta estructura permite comprender que el aprendizaje adaptativo no depende de un único algoritmo, sino de la integración coherente entre datos, modelos, interfaces y decisiones pedagógicas.

Dentro de las técnicas más utilizadas se encuentran los modelos predictivos, los sistemas de recomendación y los algoritmos de clasificación. Los modelos predictivos permiten anticipar el desempeño académico o el riesgo de abandono, lo cual facilita la intervención temprana. Los sistemas de recomendación, por su parte, sugieren recursos, actividades o rutas de aprendizaje según el perfil del estudiante. Los algoritmos de clasificación ayudan a agrupar estudiantes según niveles de dominio, estilos de interacción o necesidades de apoyo. Más recientemente, el aprendizaje profundo y el procesamiento de lenguaje natural han ampliado estas posibilidades, permitiendo analizar respuestas escritas, interacciones discursivas y trayectorias complejas de aprendizaje (Lin et al., 2025; Tan et al., 2025).

Sin embargo, la literatura también muestra que la personalización educativa basada en inteligencia artificial enfrenta desafíos significativos. Uno de ellos es la calidad de los datos. Si los datos son incompletos, sesgados o poco representativos, los modelos pueden producir recomendaciones inadecuadas o reforzar desigualdades existentes. Otro desafío es la explicabilidad de los algoritmos, ya que docentes y estudiantes necesitan comprender por qué el sistema sugiere una determinada ruta, actividad o intervención. Además, existen preocupaciones éticas relacionadas con la privacidad, la seguridad de la información y el uso responsable de los datos educativos (Alfredo et al., 2024; Wang et al., 2024). Por tanto, un modelo adaptativo no puede evaluarse únicamente por su precisión técnica, sino también por su transparencia, pertinencia pedagógica y aceptación por parte de los usuarios.

Desde una mirada humanizada, el aprendizaje adaptativo debe orientarse a mejorar la experiencia del estudiante, no solo a incrementar métricas de rendimiento. Esto implica reconocer que detrás de cada dato existe una persona con dificultades, intereses, emociones y contextos particulares. El tiempo de conexión, por ejemplo, no siempre refleja compromiso; puede indicar también problemas de acceso, cansancio o falta de comprensión. Una baja calificación no necesariamente expresa falta de capacidad, sino quizá una ruta de aprendizaje mal ajustada o una retroalimentación insuficiente. Por ello, el análisis de datos educativos debe complementarse con una interpretación pedagógica sensible al contexto.

En este sentido, el valor del *machine learning* aplicado a la educación no está en reemplazar la mirada humana, sino en ampliarla. Los algoritmos pueden ayudar a detectar señales tempranas que pasarían desapercibidas en grupos numerosos, ofrecer recursos diferenciados y apoyar decisiones más informadas. No obstante, la decisión final debe considerar criterios pedagógicos, éticos y contextuales. Un sistema verdaderamente adaptativo no es aquel que automatiza todo el proceso, sino aquel que ayuda a construir una enseñanza más cercana, oportuna y justa para cada estudiante.

Por tanto, el marco teórico de esta investigación se sustenta en la convergencia entre aprendizaje adaptativo, *machine learning*, analítica del aprendizaje e inteligencia artificial centrada en el ser humano. Esta convergencia permite comprender cómo los sistemas inteligentes pueden contribuir a la optimización de los procesos de enseñanza mediante la personalización de contenidos, la predicción de dificultades, la recomendación de recursos y la retroalimentación automatizada. No obstante, también exige asumir una postura crítica: la tecnología debe estar al servicio del aprendizaje y no convertirse en un fin en sí misma. Desde esta perspectiva, el modelo de aprendizaje adaptativo propuesto debe integrar eficiencia computacional, fundamento pedagógico, transparencia algorítmica y acompañamiento docente.

En síntesis, el aprendizaje adaptativo basado en *machine learning* representa una alternativa prometedora para transformar los procesos de enseñanza en entornos digitales y presenciales mediados por tecnología. Su principal aporte radica en la posibilidad de pasar de una enseñanza uniforme a una enseñanza personalizada, basada en evidencia y orientada a las necesidades reales del estudiante. Sin embargo, su implementación requiere una visión integral que combine conocimientos informáticos, criterios educativos y principios éticos. Solo de esta manera será posible diseñar modelos adaptativos que no solo optimicen procesos, sino que también fortalezcan la calidad, equidad y humanidad de la educación.

3. METODOLOGÍA

La presente investigación se desarrolló mediante una revisión sistemática de literatura orientada a identificar, seleccionar, analizar y sintetizar evidencia científica reciente sobre modelos de aprendizaje adaptativo basados en *machine learning* para la optimización de los procesos de enseñanza. La metodología se estructuró siguiendo las recomendaciones de la declaración PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), la cual propone una guía de 27 ítems para mejorar la transparencia, trazabilidad y calidad del reporte en revisiones sistemáticas. Asimismo, se tomó como referencia el diagrama de flujo PRISMA 2020, que permite representar de forma clara el tránsito de los registros desde la identificación inicial hasta la inclusión final de los estudios analizados.

3.1 Diseño de la revisión

El estudio se planteó como una revisión bibliográfica de tipo sistemática, con enfoque cualitativo y alcance descriptivo-analítico. Este diseño permitió examinar investigaciones publicadas en revistas científicas, congresos académicos y editoriales especializadas, con énfasis en los aportes informáticos relacionados con inteligencia artificial, aprendizaje automático, analítica del aprendizaje, minería de datos educativos, sistemas de recomendación, plataformas adaptativas y personalización del aprendizaje.

La revisión no se limitó a recopilar referencias, sino que buscó analizar críticamente los componentes tecnológicos y pedagógicos presentes en los estudios seleccionados. Por ello, se consideraron tanto los métodos computacionales utilizados como su contribución a la mejora de los procesos de enseñanza, la toma de decisiones docentes y la experiencia de aprendizaje del estudiante. La revisión se orientó a responder la siguiente pregunta principal:

¿Cómo se han aplicado los modelos de aprendizaje adaptativo basados en *machine learning* para optimizar los procesos de enseñanza en entornos educativos mediados por tecnología?

3.2 Fuentes de información

La búsqueda bibliográfica se realizó en bases de datos académicas y repositorios científicos reconocidos por su cobertura en informática, educación, inteligencia artificial y tecnologías aplicadas al aprendizaje. Las fuentes consideradas fueron: Scopus, Web of Science, IEEE Xplore, ACM Digital Library, SpringerLink, ScienceDirect, ERIC, Google Scholar, MDPI, Frontiers. Estas fuentes fueron seleccionadas porque concentran literatura relevante para el campo de la informática educativa, particularmente en temas de inteligencia artificial aplicada, minería de datos educativos, sistemas inteligentes de tutoría, analítica del aprendizaje y plataformas adaptativas.

3.3 Estrategia de búsqueda

La búsqueda se delimitó al período 2021–2026, con el propósito de recuperar evidencia actualizada y pertinente frente al rápido desarrollo de la inteligencia artificial y del *machine learning* en educación. Se utilizaron combinaciones de palabras clave en inglés y español, debido a que la mayor parte de la producción científica indexada en bases de alto impacto se encuentra en inglés. Las principales cadenas de búsqueda fueron: “adaptive learning” AND “machine learning” AND education “artificial intelligence” AND “adaptive learning systems”

3.4 Criterios de inclusión y de exclusión

Se incluyeron estudios publicados entre 2021 y 2026, en inglés o español, correspondientes a artículos científicos, revisiones sistemáticas, revisiones de alcance, capítulos académicos o estudios empíricos relacionados con aprendizaje adaptativo, *machine learning*, inteligencia artificial educativa, analítica del aprendizaje, minería de datos educativos, personalización del aprendizaje, recomendación educativa, predicción del rendimiento, evaluación adaptativa, retroalimentación o sistemas inteligentes de tutoría, siempre que contaran con acceso al resumen, metodología y resultados, y describieran aplicaciones, modelos, arquitecturas, algoritmos, plataformas o estrategias educativas apoyadas en datos.

Se excluyeron documentos duplicados, trabajos anteriores a 2021, publicaciones sin revisión por pares salvo preprints altamente pertinentes, estudios sin sustento metodológico, documentos con información insuficiente para el análisis, investigaciones sin relación directa con educación o enseñanza, publicaciones sobre inteligencia artificial sin vínculo claro con aprendizaje adaptativo y estudios centrados únicamente en aspectos administrativos institucionales, como gestión financiera, matrícula o infraestructura, cuando no aportaban al aprendizaje del estudiante ni a la optimización de la enseñanza.

3.5 Proceso de selección de estudios según PRISMA

El proceso de búsqueda y selección de estudios se representó mediante el diagrama de flujo PRISMA 2020. Inicialmente se identificaron 440 registros, de los cuales se eliminaron 82 duplicados. Posteriormente, 358 registros fueron sometidos a cribado mediante lectura de título y resumen, excluyéndose 213 por no cumplir los criterios de inclusión. Luego, 145 documentos fueron evaluados a texto completo, de los cuales 103 fueron excluidos por baja pertinencia, ausencia de información metodológica suficiente o escasa relación con modelos adaptativos basados en *machine learning*. Finalmente, 42 estudios fueron incluidos en la síntesis cualitativa y 25 estudios conformaron la base principal del análisis.

A continuación, se presenta el diagrama de flujo correspondiente al proceso de identificación, cribado, elegibilidad e inclusión de los estudios seleccionados, elaborado con base en la metodología PRISMA 2020



Figura 1. Diagrama de flujo PRISMA 2020 del proceso de selección de estudios

Fuente: Elaboración propia con base en PRISMA 2020.

4. RESULTADOS

El análisis de los estudios seleccionados permitió identificar que el aprendizaje adaptativo basado en *machine learning* se ha consolidado como una línea relevante dentro de la informática educativa, especialmente por su capacidad para transformar datos del estudiante en decisiones pedagógicas personalizadas. Los hallazgos muestran que los sistemas adaptativos actuales no se limitan a presentar contenidos diferenciados, sino que integran modelos predictivos, analítica del aprendizaje, sistemas de recomendación, procesamiento de lenguaje natural y técnicas de inteligencia artificial para ajustar dinámicamente la experiencia formativa.

De manera general, los estudios revisados coinciden en que la optimización de los procesos de enseñanza ocurre cuando el sistema logra identificar el estado actual del estudiante, anticipar posibles dificultades y proponer intervenciones oportunas. Sin embargo, también se evidenció que la efectividad de estos modelos depende de la calidad de los datos, la selección adecuada de algoritmos y la participación del docente en la interpretación de los resultados.

4.1 Caracterización general de los estudios incluidos

Los estudios analizados se agruparon según su orientación principal. Se observó una mayor concentración de investigaciones enfocadas en inteligencia artificial educativa, aprendizaje adaptativo personalizado, analítica del aprendizaje y minería de datos educativos.

Tabla 1. Caracterización temática de los estudios incluidos en la revisión

Categoría temática	Número de estudios analizados	Enfoque principal	Aporte al artículo
Aprendizaje adaptativo e inteligencia artificial	8	Personalización de contenidos, rutas y actividades mediante IA	Fundamenta el concepto de sistemas adaptativos inteligentes
<i>Machine learning</i> aplicado a datos educativos	6	Predicción de rendimiento, clasificación de estudiantes y detección de riesgo	Sustenta el componente algorítmico del modelo
Analítica del aprendizaje	5	Seguimiento, visualización e interpretación de datos educativos	Aporta la dimensión de monitoreo y toma de decisiones
Sistemas de recomendación educativa	3	Sugerencia automática de recursos, actividades o rutas	Apoya la personalización de la experiencia de aprendizaje
Procesamiento de lenguaje natural y modelos generativos	2	Análisis de respuestas, retroalimentación automatizada y tutoría inteligente	Enriquece la adaptación comunicativa y semántica
Ética, explicabilidad y enfoque humano	1	Transparencia, privacidad, sesgo y aceptación del usuario	Fortalece la dimensión crítica y humanizada del modelo

Los resultados muestran que el aprendizaje adaptativo basado en *machine learning* se estructura alrededor de cuatro componentes principales: datos educativos, modelos algorítmicos, mecanismos de adaptación e intervención pedagógica. Esta relación es importante porque permite comprender que la calidad del sistema no depende únicamente del algoritmo, sino de la forma en que los datos son interpretados y convertidos en acciones educativas significativas.

4.2 Técnicas de *machine learning* identificadas

Una de las tendencias más evidentes en la literatura es el uso de modelos predictivos para anticipar el desempeño académico o detectar estudiantes en riesgo. Estas técnicas permiten que docentes y plataformas intervengan antes de que el estudiante fracase o abandone el proceso formativo. Los algoritmos de clasificación y regresión aparecen con frecuencia en estudios de minería de datos educativos, mientras que los sistemas de recomendación y el aprendizaje profundo se emplean en modelos más avanzados de personalización.

Tabla 2. Técnicas de *machine learning* aplicadas al aprendizaje adaptativo y su contribución a la enseñanza

Técnica identificada	Uso principal en aprendizaje adaptativo	Datos utilizados con mayor frecuencia	Contribución a la enseñanza
Árboles de decisión	Clasificación de estudiantes según rendimiento o riesgo	Calificaciones, asistencia, intentos, participación	Facilita reglas comprensibles para intervención docente
Random Forest	Predicción de desempeño académico	Historial académico, interacción en LMS, actividades completadas	Mejora la precisión predictiva y reduce errores individuales
Máquinas de soporte vectorial	Clasificación de perfiles de aprendizaje	Resultados de pruebas, patrones de navegación, respuestas	Ayuda a diferenciar niveles de dominio
Redes neuronales	Predicción y modelado de trayectorias complejas	Secuencias de aprendizaje, interacciones, evaluaciones	Permite representar relaciones no lineales en el aprendizaje
Aprendizaje profundo	Análisis de grandes volúmenes de datos educativos	Datos longitudinales, texto, comportamiento digital	Favorece sistemas adaptativos más sofisticados
Agrupamiento	Segmentación de estudiantes	Ritmos de avance, comportamiento, desempeño	Permite crear grupos de apoyo o rutas diferenciadas
Sistemas de recomendación	Sugerencia de contenidos, actividades o recursos	Perfil del estudiante, preferencias, resultados previos	Personaliza la ruta de aprendizaje
Procesamiento de lenguaje natural	Análisis de respuestas abiertas y retroalimentación textual	Foros, tareas escritas, preguntas abiertas	Mejora la retroalimentación y la tutoría inteligente

El análisis permite inferir que no existe una técnica única que responda de manera integral a todas las necesidades del aprendizaje adaptativo, debido a que los procesos educativos son dinámicos, multidimensionales y altamente dependientes del contexto. Cada técnica de *machine*

learning cumple una función específica dentro del sistema: los algoritmos predictivos permiten anticipar riesgos académicos o bajo rendimiento; los modelos de clasificación ayudan a identificar perfiles o niveles de dominio; las técnicas de agrupamiento permiten segmentar estudiantes con comportamientos similares; los sistemas de recomendación sugieren recursos, actividades o rutas de aprendizaje; y la analítica del aprendizaje transforma los datos en información comprensible para la toma de decisiones docentes. Por ello, los modelos más robustos tienden a combinar varias técnicas de manera complementaria, integrando predicción, recomendación, seguimiento y retroalimentación en una misma arquitectura.

4.3 Variables educativas utilizadas para la adaptación

Los estudios revisados muestran que los modelos adaptativos se alimentan principalmente de datos generados por la interacción del estudiante con plataformas digitales. Estos datos permiten construir perfiles dinámicos y tomar decisiones sobre qué contenido presentar, qué actividad recomendar, cuándo intervenir o qué tipo de retroalimentación ofrecer.

Tabla 3. Variables educativas utilizadas para la adaptación en modelos de aprendizaje adaptativo

Variable educativa	Descripción	Uso dentro del modelo adaptativo
Rendimiento académico	Calificaciones, aciertos, errores, resultados de pruebas	Predicción de desempeño y ajuste de dificultad
Tiempo de interacción	Tiempo conectado, duración por actividad, permanencia en recursos	Detección de compromiso, dificultad o desmotivación
Número de intentos	Cantidad de veces que el estudiante realiza una actividad	Identificación de errores persistentes o necesidad de refuerzo
Progreso en la plataforma	Porcentaje de contenidos completados	Seguimiento de avance y recomendación de rutas
Participación	Intervención en foros, tareas, actividades colaborativas	Medición de implicación y aprendizaje social
Patrones de navegación	Secuencia de recursos visitados y rutas seguidas	Identificación de preferencias y estrategias de aprendizaje
Respuestas abiertas	Textos producidos en tareas, foros o evaluaciones	Análisis semántico mediante NLP
Perfil del estudiante	Conocimientos previos, estilo de aprendizaje, preferencias	Personalización inicial y ajustes posteriores
Retroalimentación recibida	Historial de comentarios, correcciones y recomendaciones	Mejora continua del acompañamiento personalizado

Un hallazgo importante es que muchos sistemas adaptativos todavía dependen de variables cuantitativas básicas, como calificaciones, tiempo de conexión o número de intentos. Aunque estos datos son útiles, no siempre explican adecuadamente la experiencia real del estudiante. Por ejemplo, un alto tiempo de conexión puede interpretarse como compromiso, pero también puede indicar dificultad, confusión o problemas de usabilidad. Por ello, la literatura más reciente propone enriquecer los modelos con datos contextuales, interacción textual, indicadores emocionales y participación docente.

4.4 Principales aportes de los estudios revisados

Los estudios incluidos muestran aportes relevantes para la construcción de un modelo de aprendizaje adaptativo basado en *machine learning*. Estos aportes pueden organizarse en cinco dimensiones: personalización, predicción, recomendación, retroalimentación y apoyo docente.

Tabla 4. Principales hallazgos e implicaciones para el modelo de aprendizaje adaptativo propuesto

Dimensión	Hallazgo principal	Implicación para el modelo propuesto
Personalización del aprendizaje	Los sistemas adaptativos permiten ajustar contenidos y actividades según el perfil del estudiante	El modelo debe construir perfiles dinámicos y actualizables
Predicción del desempeño	Los algoritmos de ML permiten anticipar bajo rendimiento o riesgo académico	El modelo debe incorporar alertas tempranas para intervención
Recomendación educativa	Los sistemas pueden sugerir recursos personalizados según necesidades detectadas	El modelo debe incluir un motor de recomendación
Retroalimentación inteligente	La IA puede generar respuestas más oportunas y diferenciadas	El modelo debe adaptar la retroalimentación al nivel del estudiante
Apoyo a la labor docente	La analítica del aprendizaje facilita decisiones pedagógicas informadas	El modelo debe incluir paneles interpretables para docentes
Evaluación adaptativa	Las actividades pueden ajustar su dificultad según el progreso	El modelo debe integrar mecanismos de evaluación continua
Ética y transparencia	La explicabilidad y privacidad son condiciones necesarias para la adopción	El modelo debe contemplar gobernanza de datos y explicabilidad

Estos hallazgos permiten sostener que el aprendizaje adaptativo no debe entenderse únicamente como una herramienta de automatización, sino como una estrategia tecnológica para mejorar la calidad de la enseñanza. El aporte más significativo de estos sistemas se encuentra en su capacidad para ofrecer información oportuna, personalizar la experiencia formativa y apoyar al docente en escenarios donde el seguimiento individualizado resulta difícil.

4.5 Beneficios reportados en la literatura

Los beneficios identificados se relacionan principalmente con la mejora del rendimiento académico, la participación estudiantil, la detección temprana de dificultades y la optimización de la gestión docente. Sin embargo, los estudios también muestran que estos beneficios son más consistentes cuando el sistema adaptativo se integra con estrategias pedagógicas claras y no se limita a operar como una plataforma automatizada.

El análisis sugiere que los beneficios más consolidados se encuentran en la predicción, la personalización y el seguimiento del aprendizaje. En cambio, beneficios como la motivación, la satisfacción o el desarrollo de competencias profundas requieren mayor evidencia empírica, debido a que dependen de factores contextuales, pedagógicos y emocionales que no siempre son capturados por los sistemas informáticos.

4.6 Síntesis de hallazgos para el modelo propuesto

A partir de los resultados revisados, se identifican cinco elementos que deberían integrarse en un modelo de aprendizaje adaptativo basado en *machine learning* para la optimización de la enseñanza.

Primero, el modelo debe iniciar con una capa de datos educativos, encargada de recopilar información sobre desempeño, interacción, progreso y participación del estudiante. Segundo, requiere una capa de procesamiento y análisis, donde los datos sean limpiados, organizados e interpretados. Tercero, debe incorporar una capa algorítmica, compuesta por modelos predictivos, sistemas de recomendación y técnicas de clasificación o agrupamiento. Cuarto, necesita una capa pedagógica de adaptación, responsable de traducir las predicciones en acciones formativas concretas. Finalmente, debe incluir una capa de visualización y control docente, que permita interpretar los resultados, validar recomendaciones y tomar decisiones contextualizadas.

Tabla 5. Componentes funcionales del modelo de aprendizaje adaptativo basado en *machine learning*

Componente del modelo	Función	Resultado esperado
Recolección de datos	Capturar información académica y conductual del estudiante	Perfil inicial y dinámico del estudiante
Preprocesamiento	Limpiar, integrar y transformar datos educativos	Datos confiables para el análisis
Modelo predictivo	Anticipar desempeño, riesgo o necesidades de apoyo	Alertas tempranas
Motor de recomendación	Sugerir recursos, actividades o rutas personalizadas	Aprendizaje individualizado
Módulo de retroalimentación	Ofrecer orientación según errores y progreso	Acompañamiento oportuno
Panel docente	Visualizar indicadores y recomendaciones	Decisiones pedagógicas informadas
Módulo ético-explicable	Proteger datos y explicar decisiones algorítmicas	Confianza, transparencia y responsabilidad

Los resultados demuestran que el aprendizaje adaptativo basado en *machine learning* puede optimizar los procesos de enseñanza cuando se diseña como un ecosistema integrado, en el que convergen datos educativos, algoritmos inteligentes, criterios pedagógicos, interfaces de visualización y participación del docente. Esta integración es fundamental porque la tecnología, por sí sola, no garantiza mejores aprendizajes ni transforma automáticamente la calidad educativa. Su valor aparece cuando los algoritmos se articulan con objetivos pedagógicos claros, datos confiables, estrategias de intervención oportunas y una interpretación humana contextualizada.

En este sentido, un sistema adaptativo no debe limitarse a procesar información o generar recomendaciones automáticas, sino que debe convertirse en una herramienta de apoyo para

comprender mejor las necesidades del estudiante, anticipar dificultades, personalizar rutas formativas y fortalecer la toma de decisiones docentes.

5. DISCUSIÓN

Los resultados de esta revisión permiten sostener que el aprendizaje adaptativo basado en *machine learning* representa una de las líneas más prometedoras para la transformación de los procesos de enseñanza mediados por tecnología. No obstante, su valor no debe entenderse únicamente desde la automatización, sino desde la posibilidad de construir sistemas educativos más sensibles a las diferencias individuales de los estudiantes. En este sentido, la discusión debe superar la idea de que la inteligencia artificial “resuelve” por sí sola los problemas educativos. Más bien, el aporte real de estos modelos se encuentra en su capacidad para ampliar la mirada del docente, anticipar dificultades y proponer rutas de aprendizaje más pertinentes.

En concordancia con lo anterior, Ersozlu et al. (2024) destacan que los métodos de *machine learning* aplicados a datos educativos permiten clasificar estudiantes, predecir rendimiento, identificar patrones de comportamiento y apoyar decisiones académicas. Este aporte confirma que el *machine learning* no debe verse como un componente accesorio, sino como el núcleo analítico de los sistemas adaptativos contemporáneos. Sin embargo, nuestro análisis permite agregar que la precisión algorítmica no es suficiente para garantizar calidad educativa. Un modelo puede predecir correctamente que un estudiante está en riesgo, pero si no ofrece una intervención comprensible, oportuna y pedagógicamente adecuada, su utilidad práctica será limitada.

Alfredo et al. (2024) proponen una mirada centrada en el ser humano para la analítica del aprendizaje y la inteligencia artificial educativa. Esta perspectiva es especialmente pertinente, porque recuerda que los sistemas inteligentes no deben desplazar la agencia de docentes y estudiantes. Nuestro criterio coincide con esta visión: el aprendizaje adaptativo debe diseñarse como una herramienta de apoyo, no como un sistema de control absoluto. El estudiante no debe quedar reducido a un conjunto de datos, ni el docente a un ejecutor de recomendaciones algorítmicas. La dimensión humana del aprendizaje exige que las decisiones automatizadas sean revisables, explicables y contextualizadas.

Lin et al. (2025) señalan que las técnicas de aprendizaje profundo han ampliado las posibilidades de la minería de datos educativos, especialmente al permitir modelar relaciones complejas y trayectorias de aprendizaje más dinámicas. Este avance es significativo para el campo informático, ya que abre la puerta a sistemas adaptativos más precisos y sensibles a patrones no lineales. Sin embargo, desde una mirada crítica, el aprendizaje profundo también introduce problemas de interpretabilidad. Mientras más complejo es el modelo, más difícil puede resultar

explicar por qué se generó una recomendación específica. Por ello, el uso de modelos avanzados debe ir acompañado de mecanismos de inteligencia artificial explicable.

Tan et al. (2025) afirman que las plataformas adaptativas habilitadas por inteligencia artificial están incorporando progresivamente modelos más sofisticados para personalizar experiencias de aprendizaje. Este hallazgo permite reconocer que el campo se encuentra en una etapa de expansión tecnológica. No obstante, nuestro análisis sugiere que la sofisticación técnica no siempre se traduce en mejora pedagógica. Un sistema puede integrar algoritmos avanzados, procesamiento de lenguaje natural o modelos generativos, pero si no responde a objetivos de aprendizaje claros, su impacto educativo será limitado. Por tanto, la innovación tecnológica debe estar subordinada al propósito formativo.

Ezzaim et al. (2025) analizan la detección de estilos de aprendizaje mediante inteligencia artificial en sistemas adaptativos. Su contribución es útil porque muestra cómo los modelos pueden inferir preferencias o patrones de aprendizaje a partir de datos. No obstante, desde nuestro criterio, la noción de “estilos de aprendizaje” debe manejarse con prudencia, ya que puede derivar en clasificaciones rígidas del estudiante. Más que etiquetar a una persona como visual, auditiva o kinestésica, los sistemas deberían identificar necesidades situacionales y preferencias cambiantes. La adaptatividad debe ser dinámica, no una categorización permanente.

Ouyang y Zhang (2024) señalan que la inteligencia artificial aplicada a la analítica del aprendizaje colaborativo puede apoyar la comprensión de interacciones grupales y procesos sociales de aprendizaje. Este aporte es importante porque muchos modelos adaptativos se concentran en el individuo y descuidan la dimensión colectiva del aprendizaje. Desde nuestro punto de vista, un modelo verdaderamente integral debería considerar no solo el rendimiento individual, sino también la participación en comunidades de aprendizaje, la colaboración, la co-construcción de conocimiento y la interacción entre pares.

A partir de estas contribuciones, se puede afirmar que el aprendizaje adaptativo basado en *machine learning* optimiza la enseñanza mediante tres procesos articulados: predicción, personalización e intervención. La predicción permite anticipar dificultades; la personalización adapta recursos y actividades; y la intervención orienta acciones docentes o automatizadas para mejorar el aprendizaje. Sin embargo, estos procesos deben integrarse dentro de una arquitectura pedagógica clara. La tecnología solo genera valor cuando sus salidas algorítmicas se convierten en decisiones comprensibles y útiles para el proceso educativo.

La discusión también permite reconocer que el diseño de un modelo adaptativo para la optimización de la enseñanza debe integrar, al menos, cinco dimensiones. La primera es la

dimensión técnica, asociada con los algoritmos, la arquitectura del sistema y la calidad de los datos. La segunda es la dimensión pedagógica, relacionada con los objetivos de aprendizaje, la retroalimentación y la secuencia formativa. La tercera es la dimensión analítica, vinculada con indicadores, visualización y toma de decisiones. La cuarta es la dimensión ética, centrada en privacidad, sesgo, transparencia y explicabilidad. La quinta es la dimensión humana, orientada a preservar la agencia del estudiante y el rol profesional del docente.

Finalmente, el aporte central de esta revisión es sostener que el aprendizaje adaptativo basado en *machine learning* debe concebirse como un ecosistema sociotécnico. Esto significa que no basta con diseñar algoritmos precisos; es necesario construir sistemas comprensibles, pedagógicamente pertinentes y humanamente responsables. La optimización de la enseñanza no debe medirse únicamente por eficiencia o rendimiento, sino también por la capacidad del sistema para promover aprendizajes más justos, personalizados y significativos.

6. CONCLUSIONES

El aprendizaje adaptativo basado en *machine learning* representa una alternativa relevante para la optimización de los procesos de enseñanza, especialmente en entornos educativos mediados por tecnología. A partir de la revisión realizada, se evidencia que estos modelos permiten avanzar desde una enseñanza uniforme hacia experiencias formativas más personalizadas, dinámicas y centradas en las necesidades reales del estudiante. Su principal valor radica en la capacidad de analizar datos educativos, identificar patrones de comportamiento, anticipar dificultades y proponer intervenciones oportunas que favorezcan el aprendizaje.

Los hallazgos permiten concluir que el *machine learning* cumple un papel estratégico dentro de los sistemas adaptativos, ya que facilita la predicción del rendimiento académico, la detección temprana de estudiantes en riesgo, la segmentación de perfiles de aprendizaje y la recomendación personalizada de recursos, actividades o rutas formativas. Sin embargo, la efectividad de estos modelos no depende únicamente de la precisión algorítmica, sino también de la calidad de los datos, la pertinencia pedagógica de las decisiones automatizadas y la capacidad del sistema para integrarse de manera comprensible en la práctica docente.

Asimismo, se concluye que la analítica del aprendizaje constituye un componente esencial para transformar los datos generados por los estudiantes en información útil para la toma de decisiones. Los paneles de visualización, las alertas tempranas y los indicadores de progreso pueden fortalecer el acompañamiento docente, siempre que sean diseñados de forma clara, interpretable y orientada a la acción pedagógica. En este sentido, el docente mantiene un rol fundamental como mediador, intérprete y responsable de contextualizar las recomendaciones generadas por el sistema.

La revisión también permite afirmar que los modelos de aprendizaje adaptativo deben concebirse como ecosistemas sociotécnicos, donde convergen algoritmos, plataformas digitales, criterios pedagógicos, principios éticos y participación humana. La tecnología, por sí sola, no garantiza una mejora en la enseñanza. Su impacto depende de cómo se articula con los objetivos formativos, las características del contexto educativo y las necesidades de estudiantes y docentes. Por ello, un modelo adaptativo no debe limitarse a automatizar procesos, sino contribuir a una enseñanza más justa, flexible, oportuna y humanizada.

Entre los principales desafíos identificados se encuentran la privacidad de los datos educativos, el sesgo algorítmico, la explicabilidad de los modelos, la interoperabilidad entre plataformas y la aceptación por parte de los usuarios. Estos aspectos deben ser considerados desde las primeras etapas de diseño e implementación, ya que condicionan la confianza, la transparencia y la sostenibilidad de los sistemas adaptativos. La optimización de la enseñanza no puede separarse de una gestión responsable de los datos ni de una visión ética de la inteligencia artificial aplicada a la educación.

En consecuencia, se concluye que el diseño de un modelo de aprendizaje adaptativo basado en *machine learning* debe integrar al menos cinco componentes fundamentales: recolección y procesamiento de datos educativos, construcción dinámica del perfil del estudiante, aplicación de modelos predictivos, generación de recomendaciones personalizadas y visualización comprensible para la toma de decisiones docentes. Estos componentes deben operar de manera articulada para favorecer intervenciones pedagógicas oportunas y mejorar la calidad del proceso de enseñanza-aprendizaje.

Finalmente, el aprendizaje adaptativo basado en *machine learning* se proyecta como una línea de investigación y desarrollo con alto potencial para la informática educativa. Su implementación puede contribuir a mejorar el rendimiento académico, fortalecer el seguimiento individualizado, optimizar el uso de recursos digitales y apoyar la labor docente en escenarios cada vez más complejos. No obstante, su consolidación requiere investigaciones empíricas más amplias, modelos explicables, validaciones en contextos reales y propuestas que mantengan al ser humano en el centro del proceso educativo. Desde esta perspectiva, la inteligencia artificial debe entenderse como un medio para potenciar la enseñanza y no como un sustituto de la relación pedagógica.

FINANCIACIÓN

Los autores no recibieron financiación para el desarrollo de la presente investigación

CONFLICTO DE INTERESES

Los Autores declaran que no existe conflicto de intereses, o lo que corresponda.

CONTRIBUCIÓN DE AUTORÍA

En concordancia con la taxonomía establecida internacionalmente para la asignación de créditos a autores de artículos científicos (<https://credit.niso.org/>). Los autores declaran sus contribuciones en la siguiente matriz:

	Autor 1.	Autor 2.	Autor 3.	Autor 4.
Participar activamente en:				
Conceptualización	X	X	X	X
Análisis formal	X	X	X	
Adquisición de fondos	X	X		X
Investigación		X	X	X
Metodología	X		X	X
Administración del proyecto	X	X	X	
Recursos	X	X		X
Redacción –borrador original		X	X	X
Redacción –revisión y edición	X		X	X
La discusión de los resultados	X	X	X	X
Revisión y aprobación de la versión final del trabajo.	X	X	X	X

REFERENCIAS BIBLIOGRÁFICAS

- Alfredo, R., Echeverria, V., Jin, Y., Yan, L., Swiecki, Z., Gasevic, D., & Martinez-Maldonado, R. (2024). *Human-centred learning analytics and AI in education: A systematic literature review*. *Computers and Education: Artificial Intelligence*, 6, 100215. <https://doi.org/10.1016/j.caeai.2024.100215>
- Almalawi, A., Soh, B., Li, A., & Samra, H. (2024). Predictive models for educational purposes: A systematic review. *Big Data and Cognitive Computing*, 8(12), 187. <https://doi.org/10.3390/bdcc8120187>
- Bayly-Castaneda, K., Ramirez-Montoya, M.-S., & Morita-Alexander, A. (2024). Crafting personalized learning paths with AI for lifelong learning: A systematic literature review. *Frontiers in Education*, 9, 1424386. <https://doi.org/10.3389/educ.2024.1424386>
- du Plooy, E., Casteleijn, D., & Franzsen, D. (2024). Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement. *Heliyon*, 10, e39630. <https://doi.org/10.1016/j.heliyon.2024.e39630>
- Ersozlu, Z., Taheri, S., & Koch, I. (2024). A review of machine learning methods used for educational data. *Education and Information Technologies*, 29, 22125–22145. <https://doi.org/10.1007/s10639-024-12704-0>
- Ezzaim, A., Dahbi, A., Aqqal, A., & Haidine, A. (2025). AI-based learning style detection in adaptive learning systems: A systematic literature review. *Journal of Computers in Education*, 12, 731–769. <https://doi.org/10.1007/s40692-024-00328-9>
- Farhood, H., Nyden, M., Beheshti, A., & Muller, S. (2025). Artificial intelligence-based personalised learning in education: A systematic literature review. *Discover Artificial Intelligence*, 5, 331. <https://doi.org/10.1007/s44163-025-00598-x>
- Gligorea, I., Cioca, M., Oancea, R., Gorski, A.-T., Gorski, H., & Tudorache, P. (2023). Adaptive learning using artificial intelligence in e-learning: A literature review. *Education Sciences*, 13(12), 1216. <https://doi.org/10.3390/educsci13121216>

- Hariyanto, Kristianingsih, F. X. D., & Maharani, R. (2025). Artificial intelligence in adaptive education: A systematic review of techniques for personalized learning. *Discover Education*, 4, 458. <https://doi.org/10.1007/s44217-025-00908-6>
- Kabudi, T., Pappas, I., & Olsen, D. H. (2021). AI-enabled adaptive learning systems: A systematic mapping of the literature. *Computers and Education: Artificial Intelligence*, 2, 100017. <https://doi.org/10.1016/j.caeai.2021.100017>
- Lin, Y., Chen, H., Xia, W., Lin, F., Wang, Z., & Liu, Y. (2025). A comprehensive survey on deep learning techniques in educational data mining. *Data Science and Engineering*, 10, 564–590. <https://doi.org/10.1007/s41019-025-00303-z>
- Muslim, A., Chatti, M. A., & Guesmi, M. (2023). *Open learning analytics: A systematic literature review and future perspectives*. arXiv. <https://arxiv.org/abs/2303.12395>
- Ouyang, F., & Zhang, L. (2024). AI-driven learning analytics applications and tools in computer-supported collaborative learning: A systematic review. *Educational Research Review*, 44, 100616. <https://doi.org/10.1016/j.edurev.2024.100616>
- Paulsen, L., & Lindsay, E. (2024). Learning analytics dashboards are increasingly becoming about learning and not just analytics: A systematic review. *Education and Information Technologies*, 29, 12355–12390. <https://doi.org/10.1007/s10639-023-12401-4>
- Sachete, A. dos S., Loiola, A. V. de S. de F., & Gomes, R. S. (2024). AdaptiveGPT: Towards intelligent adaptive learning. *Multimedia Tools and Applications*, 83, 89461–89477. <https://doi.org/10.1007/s11042-024-20144-8>
- Sghir, N., Adadi, A., & Lahmer, M. (2023). Recent advances in predictive learning analytics: A decade systematic review (2012–2022). *Education and Information Technologies*, 28, 8299–8333. <https://doi.org/10.1007/s10639-022-11536-0>
- Tan, L. Y., Hu, S., Yeo, D. J., & Cheong, K. H. (2025). Artificial intelligence-enabled adaptive learning platforms: A review. *Computers and Education: Artificial Intelligence*, 9, 100429. <https://doi.org/10.1016/j.caeai.2025.100429>
- Vemula, S. R., & Moraes, M. (2024). *Learning analytics dashboards for advisors: A systematic literature review*. arXiv. <https://arxiv.org/abs/2402.01671>
- Wang, S., Wang, F., Zhu, Z., Wang, J., Tran, T., & Du, Z. (2024). Artificial intelligence in education: A systematic literature review. *Expert Systems with Applications*, 252, 124167. <https://doi.org/10.1016/j.eswa.2024.124167>
- Lin, Y., Chen, H., Xia, W., Lin, F., Wang, Z., & Liu, Y. (2023). *A comprehensive survey on deep learning techniques in educational data mining*. arXiv. <https://arxiv.org/abs/2309.04761>