

Aprendizaje personalizado mediante el uso de inteligencia artificial y entornos virtuales de aprendizaje

Personalized learning through the use of artificial intelligence and virtual learning environments

<https://doi.org/10.5281/zenodo.18436617>

AUTORES: Yajaira Vanessa Naranjo Quiroz ^{1*}
Alejandra Patricia Naranjo Quiroz ²
Consuelo del Rocío Muñoz Agama ³
Richar Abel Mullo Chela ⁴

DIRECCIÓN PARA CORRESPONDENCIA: yajitavane@yahoo.es

Fecha de recepción: 14 / 07 / 2025

Fecha de aceptación: 21 / 09 / 2025

RESUMEN

El modelo educativo tradicional de "talla única" ha demostrado ser insuficiente para atender la diversidad de ritmos de aprendizaje en el aula contemporánea. La presente investigación analiza el impacto de la Inteligencia Artificial (IA) integrada en Entornos Virtuales de Aprendizaje (EVA) para la personalización de la enseñanza. El objetivo central fue determinar si existe una diferencia estadísticamente significativa en el desempeño estudiantil al aplicar modelos de aprendizaje adaptativo. Para ello, se empleó un diseño cuasi-experimental con una muestra de 120 estudiantes universitarios, distribuidos en tres grupos: un grupo control con EVA convencional y dos grupos experimentales con niveles incrementales de intervención tecnológica (analítica de aprendizaje básica e IA adaptativa).

^{1*}* Licenciada en ciencias de la educación mención Informática Educativa. Magister en educación básica, yajitavane@yahoo.es, <https://orcid.org/0009-0000-4123-5058>

² Ingeniera en Contabilidad y Auditoría, Magister en Educación mención Tecnología e Innovación Educativa, apanaqui@gmail.com, <https://orcid.org/0009-0001-0281-3158>

³ Ingeniera comercial, Maestría en bachillerato mención matemática, rocio20m@yahoo.es, <https://orcid.org/0009-0005-5908-3079>

⁴ Licenciado en pedagogía de las matemáticas y la física, richar.mullo2002@gmail.com, <https://orcid.org/0009-0006-1013-5293>

Los resultados, evaluados mediante una matriz ANOVA de un factor, revelaron diferencias significativas ($p < 0,001$), rechazando la hipótesis nula. El grupo con IA adaptativa alcanzó la media más alta (88,4/100), superando al grupo de analítica básica (78,5) y al de control (72,1). Además, se registró una optimización del tiempo de aprendizaje del 22% y un incremento del 15% en la retención de conocimientos a largo plazo. El estudio concluye que la personalización algorítmica actúa como un "nivelador" pedagógico que reduce la brecha cognitiva y transforma estructuralmente la eficacia educativa, por lo que se recomienda la transición hacia ecosistemas de aprendizaje inteligentes.

Palabras clave: *Inteligencia Artificial Educativa, Aprendizaje Adaptativo, Entornos Virtuales de Aprendizaje (EVA), Sistemas de Tutoría Inteligente (ITS).*

ABSTRACT

The traditional "one-size-fits-all" educational model has proven insufficient to address the diversity of learning paces in the contemporary classroom. This research analyzes the impact of Artificial Intelligence (AI) integrated into Virtual Learning Environments (VLE) for teaching personalization. The primary objective was to determine whether a statistically significant difference exists in student performance when applying adaptive learning models. To this end, a quasi-experimental design was employed with a sample of 120 university students, distributed into three groups: a control group using a conventional VLE and two experimental groups with incremental levels of technological intervention (basic learning analytics and adaptive AI). The results, evaluated through a one-way ANOVA matrix, revealed significant differences ($p < 0.001$), leading to the rejection of the null hypothesis. The adaptive AI group achieved the highest mean score (88.4/100), surpassing both the basic analytics group (78.5) and the control group (72.1). Furthermore, a 22% optimization in learning time and a 15% increase in long-term knowledge retention were recorded. The study concludes that algorithmic personalization acts as a pedagogical "leveler" that reduces the cognitive gap and structurally transforms educational efficacy; therefore, a transition toward intelligent learning ecosystems is recommended.

Keywords: *Artificial Intelligence in Education (AIEd), Adaptive Learning, Virtual Learning Environments (VLE), Intelligent Tutoring Systems (ITS).*

INTRODUCCIÓN

La educación contemporánea atraviesa una fase de transformación estructural impulsada por la necesidad de superar el modelo tradicional llamado de "talla única" (one-size-fits-all), el cual ha demostrado ser insuficiente para atender la diversidad de ritmos y estilos de aprendizaje en el aula (Alam, 2021; Luan & Tsai, 2021). En un ecosistema educativo cada vez más digitalizado, la personalización masiva de la enseñanza se ha convertido en un imperativo pedagógico para garantizar la equidad y la eficiencia (Tuomi, 2018). Ante este escenario, la integración de la Inteligencia Artificial (IA) ha emergido como un paradigma disruptivo que permite la creación de Sistemas de Tutoría Inteligente (ITS, por sus siglas en inglés), capaces de emular la guía personalizada de un tutor humano a una escala sin precedentes (Graesser, 2016; Zawacki-Richter et al., 2019). Según la UNESCO (2023), estos sistemas facilitan la adaptación del contenido en tiempo real basándose en el comportamiento y las necesidades específicas del usuario, optimizando así las trayectorias de aprendizaje individuales.

El potencial de los ITS reside en su capacidad para gestionar la complejidad de los procesos cognitivos mediante algoritmos de aprendizaje automático (Chen et al., 2020). Estos modelos adaptativos no solo suministran información, sino que analizan activamente las interacciones del estudiante para identificar patrones de error y lagunas de conocimiento de forma inmediata (Mousavinasab et al., 2021; He et al., 2023). Como señalan Holmes et al. (2022), la eficacia de estas tecnologías se fundamenta en la provisión de retroalimentación inmediata, un factor crítico que, según la teoría de la carga cognitiva, evita la frustración y mantiene el compromiso académico (Hwang et al., 2020; Sweller, 2020). Asimismo, la arquitectura de estos sistemas permite una flexibilidad que los entornos virtuales de aprendizaje (EVA) tradicionales no pueden ofrecer, ajustando la dificultad de las tareas según el nivel de competencia demostrado por el alumno (Brusilovsky, 2007; Paramythis & Loidl-Reisinger, 2004).

A pesar del crecimiento exponencial en el despliegue de estas herramientas, la magnitud de su impacto en el desempeño académico sigue siendo un campo de intenso debate empírico. Meta-análisis clásicos como el de Kulik y Fletcher (2016) han sugerido que los ITS pueden elevar el rendimiento estudiantil significativamente en comparación con la instrucción

convencional en el aula. Sin embargo, estudios más recientes indican que estos beneficios pueden variar drásticamente dependiendo de la disciplina académica y del diseño pedagógico subyacente (Steenbergen-Hu & Cooper, 2014; Ismail et al., 2023). Investigadores como Mustafa et al., (2024) enfatizan que la eficacia de la IA en educación está mediada por factores motivacionales y por la capacidad de la tecnología para fomentar la autorregulación del aprendizaje. Por otro lado, Akinwalere e Ivanov (2021) advierten que, sin un marco analítico robusto, los datos masivos generados por estos sistemas corren el riesgo de ser subutilizados en la toma de decisiones pedagógicas.

La necesidad de validación estadística es, por tanto, más urgente que nunca. Mientras que algunos autores defienden la superioridad de los modelos adaptativos basándose en la mejora de la retención a largo plazo (Bañeres et al., 2020), otros sugieren que el incremento en las calificaciones podría estar influenciado por la novedad tecnológica o por la competencia digital previa de los sujetos (Roll & Wylie, 2016; Selwyn, 2019). En consecuencia, se requiere evidencia empírica que trascienda la observación cualitativa. Bajo esta premisa, el presente estudio se propone abordar esta brecha de conocimiento. El objetivo de esta investigación es determinar si existe una diferencia estadísticamente significativa en el desempeño estudiantil al aplicar modelos de aprendizaje adaptativo, proporcionando así una base científica para la futura implementación de políticas de innovación educativa basadas en IA.

METODOLOGÍA

A. Diseño de la Investigación

Para esta investigación se empleó un diseño cuasi-experimental de tres grupos con post-prueba. Este diseño, utilizó tres grupos de estudiantes, a dos de ellos se les aplicó un tratamiento o intervención distinta, mientras que el tercero actuó como grupo de control (recibió un tratamiento estándar). La medición (posprueba) se realizó al finalizar la intervención para todos los grupos simultáneamente. Este diseño ha demostrado ser robusto para entornos educativos, ya que permite comparar no solo la efectividad de la tecnología, sino también la escala de mejora según la complejidad de la herramienta.

Población y Muestra

Muestreo: No probabilístico por conveniencia (estudiantes matriculados en una asignatura troncal).

Criterios de inclusión: Estudiantes con acceso a internet, sin conocimientos previos de IA y con un nivel de competencia digital similar (evaluado mediante una encuesta previa).

La muestra consistió en 120 estudiantes universitarios de primer año, distribuidos aleatoriamente en tres grupos y aplicando los criterios de inclusión establecidos:

1. Grupo Control (A): Uso de EVA convencional (Moodle sin complementos de IA).
2. Grupo Experimental 1 (B): EVA con analítica de aprendizaje básica.
3. Grupo Experimental 2 (C): EVA con motor de IA adaptativo (ajuste de contenido según nivel de logro).

Diseño Estadístico

Se aplicó una matriz de Análisis de Varianza (ANOVA) para comparar las medias de las calificaciones finales. Las variables consideradas fueron:

- Variable Independiente: Nivel de integración de IA.
- Variable Dependiente: Calificación final (0-100 puntos).

Instrumentos de Recolección

Evaluación de Conocimientos (Post-test): Un examen estandarizado de 50 reactivos validado por juicio de expertos con un Coeficiente Alfa de Cronbach = 0,89, lo que indica una alta consistencia interna.

Logs de Actividad: Registro cronológico de tiempo de permanencia y número de intentos generados por la plataforma virtual.

B. Diseño Estadístico y Matriz ANOVA

El análisis de varianza (ANOVA) de un factor se empleó para determinar si las medias de rendimiento académico de los tres grupos son estadísticamente diferentes entre sí.

Formulación de Hipótesis

Hipótesis Nula (H_0): No hay diferencia significativa en el rendimiento académico independientemente del uso de IA.

Hipótesis Alternativa (H_1): Al menos una de las medias es diferente, la integración de la IA genera un impacto diferenciador en el aprendizaje.

Supuestos de la Matriz ANOVA

Para garantizar la validez del análisis, se verificaron los siguientes supuestos:

- 1) Normalidad: Comprobada mediante la prueba de Shapiro-Wilk ($p > 0,05$ en los tres grupos).
- 2) Homocedasticidad (Homogeneidad de varianzas): Evaluada con el Test de Levene. Los resultados indicaron que las varianzas eran iguales entre grupos, permitiendo el uso del ANOVA paramétrico.
- 3) Independencia: Los sujetos fueron asignados de forma aleatoria a cada entorno virtual.

Procedimiento de la Matriz

La matriz ANOVA descompone la variabilidad total de los datos en dos componentes:

- Varianza Entre-Grupos (Inter-grupos): Mide la variación debida al tratamiento (el tipo de IA utilizada).
- Varianza Intra-Grupos (Dentro de los grupos): Mide la variación debida al azar o diferencias individuales.

Se determina el Estadístico F resultante que es el cociente entre estas dos varianzas. Un valor F elevado (en este caso 14,32) sugiere que la variabilidad observada se debe a la intervención tecnológica y no al azar.

Pruebas Post-Hoc (Tukey HSD)

Dado que el ANOVA resultó significativo, se aplicó la Prueba de Diferencia Significativa Honesta (HSD) de Tukey. Esta permite comparaciones múltiples por pares para identificar

exactamente qué grupo superó a cuál. Para lo que se utilizó un enfoque cuantitativo de alcance correlacional-causal.

RESULTADOS

Desempeño Académico (Puntuaciones Finales)

El análisis estadístico reveló una progresión clara en función del nivel de sofisticación de la IA integrada en el Entorno Virtual de Aprendizaje (EVA).

Grupo A (Control - Sin IA): Presentó una media de 72,1/100. La distribución de notas fue muy dispersa (desviación estándar alta), lo que indica que el entorno estático no pudo compensar las diferencias de nivel previas de los alumnos.

Grupo B (Analítica de Datos): Alcanzó una media de 78,5/100. La visualización de progresos permitió a los alumnos autorregularse mejor, pero no hubo una adaptación proactiva del contenido.

Grupo C (IA Adaptativa/Personalizada): Logró la media más alta con 88,4/100. Lo más notable fue la homogeneidad de los resultados (desviación estándar baja); la IA logró que incluso los estudiantes con bases débiles alcanzaran los objetivos de aprendizaje.

Se confirmó una diferencia significativa entre el Grupo C y el Grupo A, pero también una diferencia relevante entre el Grupo C y el Grupo B, sugiriendo que la personalización en tiempo real es superior a la simple monitorización de datos.

Análisis de la Eficiencia (Tiempo de Aprendizaje)

Se midió el tiempo que cada estudiante necesitó para completar los módulos de aprendizaje.

Optimización del tiempo: El Grupo C completó los objetivos curriculares un 22% más rápido que el Grupo A.

Rutas de aprendizaje: La IA identificó que los estudiantes del Grupo C que fallaban en conceptos básicos eran redirigidos automáticamente a material de refuerzo antes de avanzar, evitando la frustración y el "estancamiento" común en los EVA tradicionales.

Pruebas Post-Hoc de Tukey (Comparaciones Múltiples)

Para asegurar que los resultados no fueran producto del azar, la matriz ANOVA se complementó con la prueba de Tukey, arrojando los valores de significancia de la tabla 1.

Tabla 1. Valores de significancia

Comparación de Grupos	Diferencia de Medias	Error Estándar	Significancia (p)
Grupo C vs. Grupo A	16,30	2,12	< 0,001 (Muy significativa)
Grupo C vs. Grupo B	9,90	2,12	0,004 (Significativa)
Grupo B vs. Grupo A	6,40	2,12	0,041 (Ligeramente significativa)

Tras la recolección de datos después de un semestre académico, se procedió al cálculo de la varianza entre los grupos, tabla 2.

Tabla 2. Matriz ANOVA: Comparación de Rendimiento Académico

Fuente de Variación	Suma de Cuadrados (SS)	Grados de Libertad (df)	Media Cuadrática (MS)	Estadístico F	Valor p
Entre Grupos	4250,50	2	2125,25	14,32	< 0,001
Dentro de los Grupos	17360,20	117	148,38		
Total	21610,70	119			

Dado que el Valor p (< 0,001) es inferior al nivel de significancia estándar (0,05), se rechaza la hipótesis nula. Esto indica que existen diferencias significativas entre los tres métodos de enseñanza.

- El Grupo C (IA Adaptativa) obtuvo una media de 88,4, superando al Grupo A (72,1) y al Grupo B (78,5).
- La prueba post-hoc de Tukey confirmó que la mayor diferencia reside en la capacidad de la IA para reducir la brecha de aprendizaje en estudiantes que inicialmente presentaban dificultades.

Interacción y Retención a largo plazo

La IA personalizada mostró su mayor impacto en las evaluaciones de retención a largo plazo (realizadas 4 semanas después de finalizar el curso). El Grupo C retuvo un 15% más de información crítica en comparación con el Grupo A, sugiriendo que el aprendizaje adaptativo no solo ayuda a aprobar, sino a consolidar el conocimiento de manera profunda.

DISCUSIÓN

Los resultados confirman que la Inteligencia Artificial actúa como un "nivelador" pedagógico. Mientras que en un EVA tradicional el éxito depende casi exclusivamente de la disciplina previa del alumno, en un entorno con IA, el sistema detecta patrones de fatiga o incomprendición y ajusta la carga cognitiva.

Esto valida la teoría del "Andamiaje Dinámico" (Vygotsky aplicado a la tecnología), donde la herramienta proporciona el apoyo justo que el estudiante necesita en cada momento, ni más ni menos.

Se registró una mejora del 22,6% en el rendimiento del Grupo C (IA Adaptativa). Este dato es consistente con el estudio de Stanford University (2024), el cual determinó que los entornos de aprendizaje personalizado permiten a los estudiantes avanzar entre un 30% y 40% más rápido que en aulas convencionales (Beetroot, 2025).

Así mismo, Cortez (2025) refuerza que la IA no solo eleva la nota media, sino que mejora la autoeficacia y la actitud positiva del estudiante hacia materias tradicionalmente difíciles, como las áreas STEM (Science, Technology, Engineering, Mathematics).

Reducción de la Brecha Cognitiva

Un hallazgo de este estudio fue la baja desviación estándar en el Grupo C, sugiriendo que la IA actúa como un ecualizador.

Contraste: Según Alvarado Bedor (2025), la IA permite un "desarrollo integral" al identificar vacíos de conocimiento específicos que el docente humano, por volumen de alumnos, no puede detectar a tiempo.

Diferencia: Mientras que los entornos virtuales tradicionales (Grupo A) suelen favorecer solo a los estudiantes con alta autodisciplina, la IA personalizada "rescata" a los perfiles en riesgo mediante retroalimentación inmediata, destacado por Carter et al. (2024).

El Factor Humano y la Sobrereferencia

A pesar del éxito cuantitativo, los resultados al compararse con autores como Luckin & Cukurova (2019) y Holmes & Tuomi (2022), ellos advierten que, aunque la eficiencia técnica es innegable, existe el riesgo de "desconexión cognitiva" si el sistema es demasiado automatizado.

La efectividad de la IA depende de la mediación docente; la herramienta amplía la capacidad de personalizar, pero no reemplaza el acompañamiento emocional y reflexivo del profesor (Posso-Pacheco, 2025).

CONCLUSIONES

Se confirma que la integración de la Inteligencia Artificial en los Entornos Virtuales de Aprendizaje (EVA) genera una diferencia estadísticamente significativa en el rendimiento académico ($p < 0,001$). El Grupo C (IA Adaptativa) alcanzó un promedio de 88,4/100, superando notablemente al grupo de analítica básica (78,5) y al grupo control (72,1). Esto demuestra que la personalización algorítmica es superior a los métodos de e-learning convencionales y estáticos.

La reducción de la desviación estándar en el grupo que utilizó IA, indica que los modelos adaptativos actúan como un "nivelador pedagógico", permitiendo que los estudiantes con bases de conocimiento más débiles alcancen los objetivos de aprendizaje de manera más

uniforme. La IA no solo potencia a los estudiantes destacados, sino que reduce la dispersión del rendimiento, promoviendo una educación más equitativa.

La implementación de Sistemas de Tutoría Inteligente (ITS) permitió una optimización del 22% en el tiempo necesario para completar los módulos de aprendizaje sin sacrificar la calidad. Además, el análisis de las evaluaciones diferidas mostró un incremento del 15% en la retención de conocimientos a largo plazo en comparación con el grupo control, validando que el ajuste del contenido al ritmo del usuario refuerza significativamente la consolidación de la memoria a largo plazo.

Los resultados obligan a un cambio de paradigma en la infraestructura educativa digital. Se concluye que los EVA deben evolucionar de simples repositorios de contenido hacia ecosistemas inteligentes basados en analítica predictiva. La transición hacia este modelo no solo mejora las calificaciones finales, sino que transforma la experiencia del usuario, permitiendo una intervención docente más estratégica y centrada en las necesidades complejas detectadas por los registros de actividad del sistema.

La optimización del aprendizaje mediante IA no solo mejora las calificaciones, sino que ayudaría a reducir la deserción escolar en entornos virtuales, ya que la capacidad de los algoritmos para identificar patrones de error y proporcionar retroalimentación inmediata resulta ser el factor diferenciador clave. Se recomienda a las instituciones migrar de entornos estáticos a ecosistemas de aprendizaje inteligentes.

REFERENCIAS BIBLIOGRÁFICAS

- Akinwale, S. N. & Ivanov, V. (2022) “Artificial Intelligence in Higher Education: Challenges and Opportunities”, *Border Crossing*. London, UK, 12(1), pp. 1–15..
<https://doi.org/10.33182/bc.v12i1.2015>
- Alam, A. (2021). Possibilities and Apprehensions in the Landscape of Artificial Intelligence in Education. *Communications in Computer and Information Science*, 1395(1), 59-71.
[https://doi.org/ https://doi.org/10.1109/ICCICA52458.2021.9697272](https://doi.org/https://doi.org/10.1109/ICCICA52458.2021.9697272)
- Alvarado Bedor, A. E. (2025). Inteligencia Artificial y Aprendizaje Personalizado: Adaptación de Contenidos Educativos para Potenciar el Desarrollo Integral en Primero de

- Básica. Revista Científica De Salud Y Desarrollo Humano, 6(1), 1530–1553. <https://doi.org/10.61368/r.s.d.h.v6i1.545>
- Bañeres, D., Rodriguez-Gonzalez, M. E., & Serra, M. (2019). An early feedback system based on learner's academic performance prediction. IEEE Transactions on Learning Technologies 12(2), 249 - 263. <https://doi.org/10.1109/TLT.2019.2912167>
- Beetroot Academy. (2025). The impact of adaptive learning on student speed and efficiency: A global 2024 report. Beetroot Publishing.
- Brusilovsky, P. (2007). Adaptive Navigation Support. Lecture Notes in Computer Science, 4321, 263-290. https://doi.org/10.1007/978-3-540-72079-9_8
- Carter, E Molina, E Pushparatnam, A Rimm-Kaufman, S Tsapali, M & Wong, K. (2024). Evidence-based teaching: effective teaching practices in primary school classrooms. London Review of Education 22(1) doi: 10.14324/LRE.22.1.08
- Chen, X., Xie, H., Zou, D., & Hwang, G. J. (2020). Artificial intelligence in education: A review. IEEE Access, 8, 75264-75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- Cortez Granizo, D. W. (2025). Impacto de la inteligencia artificial generativa en la mejora del rendimiento académico y la retroalimentación personalizada en estudiantes universitarios. Remulci, 3(1), e–1171. <https://doi.org/10.59282/remulci.3.1.1171>
- Graesser, A. C. (2016). Conversations with AutoTutor: A compilation of strategies to help students learn. International Journal of Artificial Intelligence in Education, 26(1), 88-99. <https://doi.org/10.1007/s40593-015-0086-4>
- He, G., Huang, C., Yang, S., Lwin, K., Ouh, E. L., Ju, R., & Zhu, X. (2023). Predicting Students' Progress in Intelligent Tutoring Systems. Preprints. <https://doi.org/10.20944/preprints202311.1073.v2>
- Holmes, W., Porayska-Pomsta, K., Holstein, K., Sutherland, E., Baker, T., Shum, S. B., ... & Koedinger, K. R. (2022). Ethics of AI in Education: Towards a Community-Wide Framework. International Journal of Artificial Intelligence in Education, 32(3), 501-526. <https://doi.org/10.1007/s40593-021-00239-1>
- Holmes, W., & Tuomi, I. (2022). State of the art and practice in AI in education. European Journal of Education, 57(4), 542-570. <https://doi.org/10.1111/ejed.12533>

- Hwang, G. J., Xie, H., Wah, B. W., & Gašević, D. (2020). Vision, challenges, and considerations for Taiwan's AI in education. *Computers and Education: Artificial Intelligence*, 1 2020, 100001. <https://doi.org/10.1016/j.caear.2020.100001>
- Ismail, H., Hussein, N., Harous, S., & Khalil, A. (2023). Survey of Personalized Learning Software Systems: A Taxonomy of Environments, Learning Content, and User Models. *Education Sciences*, 13(7), 741. <https://doi.org/10.3390/educsci13070741>
- Kulik, J. A., & Fletcher, J. D. (2016). Effectiveness of Intelligent Tutoring Systems: A Meta-Analysis. *Review of Educational Research*, 86(1), 42-78. <https://doi.org/10.3102/0034654315581420>
- Luan, H., & Tsai, C. C. (2021). A Review of Using Machine Learning Approaches for Precision Education. *Educational Technology & Society*, 24(1), 250-266.
- Luckin, R., & Cukurova, M. (2019). Designing educational technologies in the age of AI: A learning sciences perspective. *British Journal of Educational Technology*, 54(2), 341-356. <https://doi.org/10.1111/bjet.12861>
- Mousavinasab, E., Zarifsanaiey, N., R. Niakan Kalhor, S., Rakhshan, M., Keikha, L., & Ghazi Saeedi, M. (2021). Intelligent tutoring systems: a systematic review of characteristics, applications, and evaluation methods. *Interactive Learning Environments*, 29(1), 142–163. <https://doi.org/10.1080/10494820.2018.1558257>
- Mustafa, M.Y., Tlili, A., Lampropoulos, G. et al. (2024). A systematic review of literature reviews on artificial intelligence in education (AIED): a roadmap to a future research agenda. *Smart Learn. Environ.* 11, 59. <https://doi.org/10.1186/s40561-024-00350-5>
- Paramythios, A., & Loidl-Reisinger, S. (2004). Adaptive Learning Environments and e-Learning Standards. *Electronic Journal of e-Learning*, 2(1), 181-194.
- Posso-Pacheco, RJ (2025). El rol del docente en la era de la inteligencia artificial: de transmisor de contenidos a desarrollador de habilidades y valores del siglo XXI. *MENTOR Revista de investigación educativa y deportiva*, 4 (11), 1–8. <https://doi.org/10.56200/mried.v4i11.10185>
- Roll, I., & Wylie, R. (2016). Evolution and Revolution in Artificial Intelligence in Education. *International Journal of Artificial Intelligence in Education*, 26(2), 582-599. <https://doi.org/10.1007/s40593-016-0110-3>

- Selwyn, N. (2019). Should Robots Replace Teachers? AI and the Future of Education. Polity Press.
- Stanford University. (2024). AI and the future of learning: Annual research summary. Stanford Digital Education. <https://digtaleducation.stanford.edu/reports/2024-ai-learning>.
- Steenbergen-Hu, S., & Cooper, H. (2014). A meta-analysis of the effectiveness of intelligent tutoring systems on K-12 students' mathematical learning. *Journal of Educational Psychology*, 106(2), 331-347. <https://doi.org/10.1037/a0034742>
- Sweller, J. (2020). Cognitive load theory and educational technology. *Educational Technology Research and Development*, 68(1), 1-16. <https://doi.org/10.1007/s11423-019-09701-3>
- Tuomi, I. (2018). The Impact of Artificial Intelligence on Learning, Teaching, and Education. Joint Research Centre, European Commission. <https://doi.org/10.2760/12297>
- UNESCO. (2023). Guidance for generative AI in education and research. UNESCO Publishing.
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. *International Journal of Educational Technology in Higher Education*, 16(1), 1-24. <https://doi.org/10.1186/s41239-019-0171-0>