



Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), Noviembre-Diciembre 2025,
Volumen 9, Número 6.

https://doi.org/10.37811/cl_rcm.v9i6

EFFECTOS DE LA INTELIGENCIA ARTIFICIAL EN COMPETENCIAS DE EDUCACIÓN BÁSICA Y SU CORRELACIÓN CON INDICADORES DE ÉXITO EN INGENIERÍA

**EFFECTS OF ARTIFICIAL INTELLIGENCE ON BASIC EDUCATION
COMPETENCIES AND THEIR CORRELATION WITH SUCCESS INDICATORS IN
ENGINEERING**

Wendy Daniel Martínez

Universidad Politécnica Metropolitana de Hidalgo, México

Luis Alejandro Santana Valadez

Instituto Tecnológico de Pachuca, México

Faride Hernández Pérez

Universidad Politécnica Metropolitana de Hidalgo, México

José Alberto Zarazúa Sánchez

Universidad Politécnica Metropolitana de Hidalgo, México

Carlos Alberto Carrillo Santos

Universidad Politécnica Metropolitana de Hidalgo, México

Andrea Genoveva Rojas Ponciano

Universidad Politécnica Metropolitana de Hidalgo, México

DOI: https://doi.org/10.37811/cl_rcm.v9i6.20835

Efectos de la Inteligencia Artificial en Competencias de Educación Básica y su Correlación con Indicadores de Éxito en Ingeniería

Wendy Daniel Martínez¹

wdaniel@upmh.edu.mx

<https://orcid.org/0000-0002-4455-940X>

Universidad Politécnica Metropolitana de Hidalgo, México

Faride Hernández Pérez

fahernandez@upmh.edu.mx

<https://orcid.org/0000-0001-9426-4944>

Universidad Politécnica Metropolitana de Hidalgo, México

Carlos Alberto Carrillo Santos

ccarrillo@upmh.edu.mx

<https://orcid.org/0000-0001-6866-8558>

Universidad Politécnica Metropolitana de Hidalgo, México

Luis Alejandro Santana Valadez

luis.sv@pachuca.tecnm.mx

<https://orcid.org/0000-0003-1561-020X>

Instituto Tecnológico de Pachuca, México

José Alberto Zarazúa Sánchez

jzarazua@upmh.edu.mx

<https://orcid.org/0009-0006-3355-8404>

Universidad Politécnica Metropolitana de Hidalgo, México

Andrea Genoveva Rojas Ponciano

arojas@upmh.edu.mx

<https://orcid.org/0009-0004-9641-0377>

Universidad Politécnica Metropolitana de Hidalgo, México

RESUMEN

Este estudio analiza la relación entre el uso pedagógico de la inteligencia artificial en la educación básica y el desempeño inicial en programas de ingeniería. Se implementó una intervención en secundaria técnica basada en tutorización inteligente, verificación de procedimientos mediante visión por computadora y analítica de aprendizaje obtenida de dispositivos conectados. El diseño experimental, organizado por escuelas e incorporado de forma escalonada, permitió estimar los efectos en competencias científicas y matemáticas fundamentales, tales como la precisión experimental, la argumentación en informes, la resolución de problemas y la autorregulación. Posteriormente, se examinó su correlación con indicadores académicos del primer año universitario: aprobación de Cálculo y Física, avance de créditos y persistencia al segundo semestre. El análisis combinó modelos multinivel y enfoques de diferencias en diferencias, incorporando estimaciones de heterogeneidad según contexto urbano-rural, nivel de conectividad y presencia de necesidades educativas específicas. Los resultados muestran que mayores niveles de práctica guiada y retroalimentación inmediata en la educación básica se asocian con mejoras significativas en el desempeño experimental y, posteriormente, con trayectorias iniciales más favorables en ingeniería. Estos hallazgos aportan evidencia para la actualización de las planeaciones didácticas, el fortalecimiento de la formación docente y la orientación de políticas educativas que promuevan una adopción responsable y equitativa de la inteligencia artificial desde los niveles básicos.

Palabras clave: inteligencia artificial educativa; analítica del aprendizaje, educación básica, educación en ingeniería, desempeño académico temprano

¹Autor principal

Correspondencia: wdaniel@upmh.edu.mx

Effects of Artificial Intelligence on Basic Education Competencies and Their Correlation with Success Indicators in Engineering

ABSTRACT

This study analyzes the relationship between the pedagogical use of artificial intelligence in basic education and early performance in engineering programs. An intervention was implemented in technical secondary school based on intelligent tutoring, procedure verification through computer vision, and learning analytics obtained from connected devices. The experimental design, organized by schools and introduced in a staggered manner, allowed the estimation of effects on fundamental scientific and mathematical competencies such as experimental accuracy, report-based argumentation, problem-solving, and self-regulation. Subsequently, the correlation of these competencies with first-year university academic indicators was examined, including the approval of Calculus and Physics courses, credit advancement, and persistence into the second semester. The analysis combined multilevel models and difference-in-differences approaches, incorporating heterogeneity estimates by urban–rural context, connectivity level, and specific educational needs. Results show that higher levels of guided practice and immediate feedback during basic education are associated with significant improvements in experimental performance and, subsequently, with more favorable early trajectories in engineering. These findings provide evidence to update instructional planning, strengthen teacher training, and inform educational policy decisions that promote the responsible and equitable adoption of artificial intelligence from the earliest educational levels.

Keywords: artificial intelligence in education; learning analytics, basic education; engineering education, early academic performance

Artículo recibido: 15 octubre 2025

Aceptado para publicación: 18 noviembre 2025



INTRODUCCIÓN

En la última década, la integración pedagógica de la inteligencia artificial (IA) en la educación básica ha pasado de experiencias piloto a ecosistemas que combinan tutoría inteligente, verificación automatizada de procedimientos y analítica del aprendizaje. Los marcos internacionales señalan que, cuando su adopción se acompaña de lineamientos claros, protección de datos y desarrollo profesional docente, la IA puede reconfigurar las prácticas de enseñanza y evaluación desde las primeras etapas escolares (UNESCO, 2021, 2023).

En términos empíricos, la evidencia sugiere que los sistemas adaptativos con retroalimentación inmediata elevan el rendimiento al ajustar el nivel de desafío, acortar los ciclos de práctica–error–corrección y atender la heterogeneidad del aula (Banerjee, Cole, Duflo, & Linden, 2007; Muralidharan, Singh, & Ganimian, 2019). En el campo de las ciencias, los laboratorios remotos y virtuales, apoyados por dispositivos conectados y verificación mediante visión por computadora, amplían las oportunidades de práctica auténtica incluso en escuelas con infraestructura limitada. Cuando el diseño instruccional cuida la interacción, la guía y la calidad del feedback, estos entornos logran resultados comparables a las experiencias presenciales (Heradio, de la Torre, & Dormido, 2016; Achuthan, Raghavan, & Shankar, 2021). De forma complementaria, la analítica del aprendizaje utilizada con fines formativos produce señales procesables sobre el progreso, los errores y los patrones de estudio, lo que fortalece la autorregulación y el razonamiento basado en evidencias (Black & Wiliam, 1998; Ifenthaler & Yau, 2020).

Este panorama adquiere relevancia particular en la transición hacia los programas de ingeniería. La literatura en educación STEM documenta que el desempeño del primer año, en especial en cursos troncales como Cálculo y Física, predice la permanencia temprana y el avance de créditos (Graham, Frederick, Byars-Winston, Hunter, & Handelsman, 2013). Si la escuela básica mediada por IA promueve prácticas experimentales frecuentes, con verificación automatizada y retroalimentación puntual, es razonable esperar efectos que se proyecten en la etapa universitaria inicial. Asimismo, la motivación académica y las percepciones de disciplina al inicio de la universidad se han vinculado con decisiones de persistencia, lo que refuerza la importancia de experiencias formativas de calidad desde la educación básica (Hsu & Dudley, 2022).



Persisten, sin embargo, vacíos que limitan la comprensión integral del fenómeno. En primer lugar, buena parte de los estudios sobre IA en educación básica reporta resultados de corto plazo, sin seguimiento longitudinal hacia la educación superior. En segundo lugar, la verificación automatizada, por ejemplo, la visión por computadora que constata el montaje o los pasos de una práctica, rara vez se estudia como un componente pedagógico con efectos medibles. En tercer lugar, los análisis de equidad (urbano–rural, conectividad, necesidades educativas específicas) no siempre estiman diferencias de efecto o condiciones de implementación, aun cuando las brechas de acceso e infraestructura condicionan los resultados (UNESCO, 2021, 2023). En conjunto, estas limitaciones justifican estudios que conecten trazas finas de aprendizaje en educación básica con indicadores verificables de éxito temprano en ingeniería, bajo diseños que capturen la variación entre escuelas y a lo largo del tiempo.

El presente artículo se sitúa en ese cruce. Se implementó en una secundaria técnica una intervención con tres componentes: (a) tutoría inteligente con retroalimentación inmediata para tareas de ciencias y matemáticas; (b) verificación de procedimientos mediante visión por computadora para asegurar la correcta ejecución de las prácticas; y (c) analítica del aprendizaje basada en dispositivos conectados que registran intentos, tiempos y precisión de las mediciones. El diseño por escuelas, con incorporación escalonada, permite estimar efectos en competencias científicas y matemáticas básicas (precisión experimental, argumentación en informes, resolución de problemas y autorregulación) y analizar su correlación con tres indicadores de éxito temprano en ingeniería: aprobación de Cálculo y Física, avance de créditos y persistencia al segundo semestre.

Metodológicamente, el estudio combina modelos jerárquicos para datos anidados (estudiantes en aulas y escuelas) con estrategias de comparación temporal que controlan tendencias previas y factores inobservados estables. Además, se estiman efectos diferenciales por contexto urbano–rural, condiciones de conectividad y necesidades educativas específicas, a fin de identificar para quiénes y en qué condiciones la intervención resulta más beneficiosa. Todo ello se realizó bajo lineamientos éticos para el trabajo con población menor de edad: consentimiento informado de tutores, minimización y seudonimización de datos, y control de acceso por roles.



La contribución del estudio es doble. En primer lugar, vincula evidencia sobre práctica científica auténtica y autorregulación en la educación básica con resultados verificables del primer año universitario en ingeniería, ofreciendo un puente empírico entre niveles educativos que pocas veces se documenta. En segundo lugar, provee un marco replicable para los sistemas escolares interesados en escalar el uso de la IA con criterios de calidad, equidad y gobernanza de datos, en sintonía con las recomendaciones internacionales más recientes (UNESCO, 2021, 2023). Con ello, se busca aportar insumos para actualizar las planeaciones didácticas, fortalecer la formación docente y orientar decisiones de política educativa que favorezcan la adopción responsable y equitativa de la IA desde los niveles básicos.

METODOLOGÍA

Enfoque y diseño del estudio

Se trabajó con un diseño por escuelas con incorporación escalonada: todas las secundarias técnicas participaron en la intervención, pero cada plantel inició en un momento distinto. Este formato permitió comparar la evolución dentro de cada escuela (antes y después) y entre escuelas que aún no habían iniciado, manteniendo la factibilidad operativa y el principio de que ninguna quedara sin intervención. La lógica del diseño es coherente con la motivación pedagógica y ética planteada en la introducción (personalización mediante IA, retroalimentación inmediata y monitoreo formativo), así como con el interés de documentar efectos que posteriormente se correlacionen con indicadores tempranos en ingeniería.

Participantes y contexto

Participaron secundarias técnicas públicas de dos entidades con diversidad urbano–rural y distintos niveles de conectividad. Los criterios de inclusión fueron: (a) consentimiento informado de tutores y autorización directiva; (b) conectividad mínima o, en su caso, sincronización diferida; (c) al menos dos grupos por grado para calendarizar las rondas de implementación de incorporación. Se excluyeron los planteles que atravesaban reformas curriculares mayores durante el mismo periodo.



Intervención

Los tres componentes integrados que se implementaron son los siguientes:

Tutoría inteligente en actividades de ciencias y matemáticas, con retroalimentación inmediata y andamiaje progresivo para guiar la práctica y la resolución de problemas, en línea con la evidencia sobre los beneficios de la instrucción adaptativa (Banerjee et al., 2007; Muralidharan, Singh, & Ganimian, 2019).

Verificación mediante visión por computadora del montaje y procedimiento en las prácticas (por ejemplo, conexiones, calibración y pasos críticos). La literatura sobre laboratorios remotos y virtuales respalda que, con un buen diseño instruccional y feedback de calidad, los resultados pueden ser comparables a los de entornos presenciales (Heradio, de la Torre, & Dormido, 2016; Achuthan, Raghavan, & Shankar, 2021).

Analítica del aprendizaje a partir de dispositivos conectados (intentos, tiempos, latencias, precisión de mediciones), con un uso formativo tanto para estudiantes como para docentes, favoreciendo la autorregulación y la toma de decisiones instruccionales (Ifenthaler & Yau, 2020; Black & Wiliam, 1998).

Cada escuela recibió entre 8 y 12 horas de formación docente, un manual de implementación (con secuencias, rúbricas y listas de verificación de fidelidad) y soporte técnico. Las rondas de implementación de incorporación se activaron cada dos meses hasta cubrir la totalidad de los planteles.

Variables e instrumentos

Exposición / proceso (educación básica): sesiones completadas; iteraciones por práctica; tiempo en tarea y latencia; alertas de verificación; precisión (error medio).

Resultados intermedios (educación básica):

- Precisión experimental: rúbrica 0–4 por criterio; coherencia procedimiento-dato.
- Argumentación en informes: calidad de evidencia y conclusiones.
- Resolución de problemas: ítems de transferencia breve.
- Autorregulación: escala corta (planificar – monitorear–ajustar).



Resultados principales (educación superior):

- Aprobación en Cálculo I y Física I: variable dicotómica (0/1).
- Créditos aprobados: total acumulado al cierre del primer año.
- Persistencia al segundo semestre: variable dicotómica (0/1).

Las rúbricas se pilotearon en dos escuelas y se capacitó a evaluadores externos que calificaron una submuestra a ciegas, con un acuerdo interjueces ≥ 0.80 .

Procedimiento de recolección y enlace

Las plataformas registraron automáticamente las trazas de uso. Los informes de práctica se entregaron en el repositorio institucional y se calificaron mediante rúbricas. Los datos del primer año universitario (aprobación, créditos y persistencia) se obtuvieron mediante convenios con las instituciones de educación superior (IES) receptoras; se seudonimizaron y se enlazaron mediante claves seguras para preservar la confidencialidad (UNESCO, 2021, 2023).

Plan de análisis

Adopción y fidelidad: descripción por escuela y por ronda de implementación; verificación de tendencias previas comparables.

Efectos en educación básica: modelos multinivel (estudiantes anidados en aulas y escuelas) para precisión, argumentación, resolución y autorregulación.

Resultados en educación superior: enfoques de diferencias en diferencias con efectos fijos por escuela y periodo; modelos logísticos para aprobación y persistencia, y lineales para créditos.

Mediación: prueba de la ruta *mejoras en precisión/autorregulación (educación básica) → resultados universitarios*.

Heterogeneidad: interacciones por contexto urbano–rural, conectividad y necesidades educativas específicas.

Datos faltantes: imputación múltiple por cadenas de ecuaciones (MICE) y análisis de sensibilidad *complete-case* (Azur, Stuart, Frangakis, & Leaf, 2011).



Este plan es consistente con la finalidad del estudio: conectar trazas finas de aprendizaje en la educación básica con indicadores verificables del inicio en ingeniería, así como promover el uso responsable de los datos educativos (UNESCO, 2023; Ifenthaler & Yau, 2020).

Consideraciones éticas y de gobernanza

Se obtuvo consentimiento informado por parte de los tutores y la autorización correspondiente de la dirección institucional. Los datos fueron tratados bajo principios de minimización, seudonimización y control de acceso por rol. La intervención se desarrolló en concordancia con las orientaciones internacionales sobre el uso ético, responsable y centrado en la persona de la inteligencia artificial en educación, con especial énfasis en la seguridad, transparencia y equidad (UNESCO, 2021, 2023).

RESULTADOS

Los resultados se organizan en cuatro apartados: adopción y fidelidad de implementación, efectos en educación básica, resultados en el primer año de ingeniería, y análisis de heterogeneidad y mediación. Las cifras y evidencias son coherentes con el diseño metodológico descrito previamente.

Adopción y fidelidad de implementación

La adopción del programa mostró un incremento sostenido en cada ronda de implementación. Se reporta la proporción de estudiantes con al menos tres prácticas completas, el número promedio de iteraciones por práctica y la entrega oportuna de informes en la plataforma. En términos generales, la adopción se estabilizó conforme avanzaron las rondas, indicando una apropiación progresiva del modelo por parte de los participantes. (véase Figura 1 y Tabla 1)

Figura 1. Tasa de adopción por ronda de implementación (≥ 3 prácticas)




Tabla 1. Descriptivos basales por escuela y ronda de implementación.

escuela	ronda de implementación	n estudiantes	% mujeres	urbano/rural	conectividad (mbps)	promedio matemáticas (previo)	promedio ciencias (previo)	ausentismo (%)	nee (%)
Esc-01	1	172	51.2	Urbana	25.3	66.1	69.4	6.6	7.1
Esc-01	2	189	49.0	Urbana	26.2	65.3	66.9	6.8	6.3
Esc-02	1	164	52.4	Rural	10.1	64.8	66.0	8.1	5.2
Esc-02	2	177	45.7	Rural	10.9	65.9	67.1	7.6	5.9
Esc-03	3	201	47.6	Urbana	29.1	63.7	66.5	7.0	6.2
Esc-04	4	156	50.3	Rural	11.7	65.1	66.9	7.9	6.5
Esc-05	2	188	48.1	Urbana	23.6	67.0	68.3	6.4	6.8
Esc-06	3	171	52.0	Urbana	26.8	64.5	65.8	6.9	5.7
Esc-07	1	159	44.8	Rural	8.9	63.9	65.3	8.5	6.1
Esc-08	4	195	53.2	Urbana	27.4	66.7	67.6	6.2	6.9



Efectos en competencias de educación básica

Se estimaron efectos sobre la precisión experimental, la argumentación en informes, la resolución de problemas y la autorregulación, mediante modelos multinivel con efectos de tiempo y controles. Se observaron mejoras posteriores a la intervención, especialmente en los contextos con mayor número de iteraciones por práctica. El uso de mecanismos de verificación por visión y la retroalimentación inmediata se asoció con un aumento en la frecuencia de iteraciones y una reducción en los errores. (véase Figura 2 y Tabla 2)

Figura 2. precisión experimental: Pre vs. Post




Tabla 2. efectos en básica (modelos multinivel)

Variable	Coe	EE	IC95	IC95	p	Efectoest	Var	Var	Var	N	N	N
	f.		%	%		and.	alum	aul	escue	alumn	aul	escuel
			inf	sup			no	a	la	os	as	as
Precisión	0.1	0.0	0.1	0.2	0.00	0.32	0.42	0.1	0.1	103	41	8
experimental	8	4	02	58	02			8	1	2		
Argumentaciónen in	0.2	0.0	0.1	0.3	0.00	0.38	0.39	0.1	0.1	101	39	8
formes	2	5	22	18	01			6		7		
Resolución de	0.1	0.0	0.0	0.2	0.00	0.26	0.45	0.1	0.1	108	43	8
problemas	4	4	62	18	1			9	2	9		
Autorregulación	0.1	0.0	0.0	0.1	0.00	0.24	0.36	0.1	0.0	974	35	8
	2	3	61	79	2			4	9			



Resultados en el primer año de ingeniería

Se analizaron las tasas de aprobación en Cálculo I y Física I, los créditos aprobados al cierre del primer año y la persistencia al segundo semestre, utilizando un esquema de diferencias en diferencias con efectos fijos por escuela y periodo (véase Figura 3 y Tabla 3).

Figura 3. estudio de eventos: Aprobación Cálculo I (DID)




Tabla 3. resultados en educación superior (DID)

Indicador	β DID	EE	IC95 % inf	IC95% sup	p	Fxfijos	Controles	N cohortes	N estudiantes
Aprobación Cálculo I	0.05 8	0.01 8	0.0 23	0.093	0.0 02	Escuela× Periodo	Línea base, conectivid ad, sexo, NEE	4	1100
Aprobación Física I	0.04 1	0.01 7	0.0 07	0.075	0.0 13	Escuela× Periodo	Línea base, conectivid ad, sexo, NEE	4	1100
Créditos apr obados (1er. año)	6.8	2.1	2.6 84	10.916	0.0 03	Escuela× Periodo	Línea base, conectivid ad, sexo, NEE	4	1100



Persistencia al 2do. semestre	0.04	0.01	0.0	0.076	0.0	Escuela× Periodo	Línea base, conectividad, sexo, NEE	4	1100
-------------------------------	------	------	-----	-------	-----	---------------------	--	---	------

Heterogeneidad y análisis de medición

Los efectos fueron más pronunciados en escuelas urbanas y con alta conectividad. En contextos rurales, asegurar un número mínimo de iteraciones por práctica y una retroalimentación oportuna elevó los resultados. La precisión experimental y la autorregulación mediaron parte del efecto sobre la aprobación y la persistencia (véanse Tablas 4 y 5).

Tabla 4. heterogeneidad de efectos

Subgrupo	Moderadora	β interacción	EE	IC95% inf	IC95% sup	p
Urbana	Urbano/Rural	0.028	0.012	0.004	0.052	0.021
Rural	Urbano/Rural	-0.031	0.014	-0.058	-0.003	0.034
Conectividad alta	Conectividad (terciles)	0.036	0.013	0.01	0.062	0.007
Conectividad baja	Conectividad (terciles)	-0.022	0.011	-0.043	-0.001	0.055
NEE sí	NEE	-0.015	0.01	-0.034	0.004	0.112
NEE no	NEE	0.019	0.01	-0.001	0.039	0.062

Tabla 5. mediación (proceso → resultado)

Mediador	Coef. a	Coef. b	Efecto indirecto ab	IC95% inf	IC95% sup	p
Precisión experimental	0.19	0.21	0.0399	0.018	0.065	0.001
Autorregulación	0.14	0.16	0.0224	0.008	0.041	0.012



Síntesis de resultados

En educación básica, los tamaños de efecto estandarizados oscilaron entre 0.24 y 0.38, con mayor impacto en argumentación y precisión experimental. En nivel superior, se estimaron incrementos de 4 a 6 puntos porcentuales en aprobación, +6.8 créditos en el primer año y +4.5 puntos en persistencia. La conectividad y la constancia en las iteraciones explican parte de la variación entre escuelas.

DISCUSIÓN

Hallazgos principales y su sentido pedagógico

Los resultados indican que la integración pedagógica de la inteligencia artificial en la secundaria técnica —a través de tutoría inteligente, verificación por visión y analítica de aprendizaje con propósito formativo— se asocia con mejoras sustantivas en precisión experimental y argumentación en informes. Estas ganancias se vinculan con un mejor desempeño inicial en ingeniería, reflejado en la aprobación de Cálculo I y Física I, el avance de créditos y la persistencia temprana.

El patrón se alinea con dos ideas consolidadas: (i) la retroalimentación oportuna y específica acelera los ciclos de práctica–error–corrección y fortalece el juicio basado en evidencia (Black & Wiliam, 1998); y (ii) los entornos prácticos mediados por tecnología pueden igualar o complementar las experiencias presenciales cuando el diseño instruccional enfatiza la interacción y la guía (Heradio, de la Torre & Dormido, 2016; Achuthan, Raghavan & Shankar, 2021).

Coherencia con la literatura y mecanismos plausibles

La mejora en competencias de educación básica coincide con la evidencia sobre instrucción adaptativa y personalización en contextos de recursos heterogéneos (Banerjee et al., 2007; Muralidharan, Singh & Ganimian, 2019). En este estudio, la tutoría inteligente ajustó el nivel de desafío y ofreció pistas graduadas; la verificación por visión redujo errores procedimentales; y la analítica aportó señales de progreso para estudiantes y docentes.

Estos componentes convergen en un mecanismo común: mayor práctica deliberada con retroalimentación inmediata, lo que explica las ganancias en precisión y argumentación, y su transferencia posterior hacia los cursos troncales del primer año de ingeniería.



La asociación positiva con los indicadores universitarios se relaciona con dos líneas previas: (a) la evidencia de que el primer año en STEM condiciona la persistencia (Graham et al., 2013), y (b) los estudios de learning analytics que muestran cómo el uso formativo de trazas de aprendizaje favorece la autorregulación y la toma de decisiones (Ifenthaler & Yau, 2020). El análisis de mediación respalda esta interpretación, al mostrar que parte del efecto sobre aprobación y persistencia se explica por la mejora en precisión y autorregulación durante la secundaria.

Equidad y condiciones de implementación

Los efectos fueron mayores en escuelas urbanas y con mejor conectividad; sin embargo, los planteles rurales mostraron avances cuando se aseguraron mínimos de iteraciones por práctica y retroalimentación docente estable. Esto sugiere que la calidad de la implementación —más que la disponibilidad tecnológica— constituye el factor decisivo.

Desde una perspectiva de política pública, la lección práctica es doble: (a) priorizar la formación docente enfocada en el uso pedagógico y la evaluación formativa, y (b) acompañar con infraestructura suficiente o soluciones de sincronización diferida para evitar la profundización de brechas. Estas conclusiones son coherentes con las orientaciones de adopción responsable y centrada en la persona propuestas por la UNESCO (2021, 2023).

Aportes y relevancia para el tránsito a ingeniería

El estudio articula niveles educativos al demostrar que fortalecer competencias científicas en la secundaria técnica (mediante prácticas apoyadas por IA) se asocia con trayectorias iniciales más sólidas en ingeniería.

En términos aplicados, propone un marco replicable: secuencias de práctica con verificación automatizada, rúbricas de argumentación y uso formativo de trazas de aprendizaje, acompañadas de desarrollo docente y gobernanza de datos.

Para los programas de ingeniería, los hallazgos respaldan la creación de puentes curriculares con la educación secundaria, compartiendo criterios de precisión experimental, estándares de reporte y repertorios de problemas transferibles a laboratorios universitarios.



Limitaciones

Tres aspectos acotan la interpretación de los hallazgos. Primero, aunque el diseño con incorporación escalonada y diferencias en diferencias (DID) atenúa sesgos, no equivale a un ensayo controlado aleatorizado (ECA), por lo que no descarta completamente factores no observados. Segundo, algunos resultados universitarios pueden depender de criterios institucionales de acreditación que varían entre instituciones. Tercero, la medición de autorregulación se basó en una escala breve; futuras aplicaciones podrían combinar autorreporte con indicadores conductuales (tiempos efectivos y patrones de intento) para mejorar la validez.

Líneas futuras

Se propone: (i) extender el seguimiento longitudinal más allá del primer año; (ii) evaluar variantes de dosificación para determinar el umbral óptimo de iteraciones y tipo de retroalimentación; (iii) estimar la costo-efectividad de cada componente (tutoría, visión, analítica); y (iv) analizar la transferencia a otras áreas de ingeniería (programación, diseño, manufactura) para comprobar la consistencia del patrón observado.

Implicaciones prácticas

Para sistemas escolares: asegurar estándares mínimos de implementación (número de prácticas, uso de rúbricas, retroalimentación oportuna) y acompañar con formación docente situada. Para instituciones de educación superior: diseñar módulos de articulación que reconozcan la experiencia previa del estudiantado y capitalicen el trabajo desarrollado en secundaria, utilizando criterios compartidos de precisión y argumentación. Para tomadores de decisión: sostener la adopción de IA en educación básica bajo lineamientos éticos, protección de datos y financiamiento escalonado, priorizando planteles con mayor rezago.

Cuando la IA se inserta con sentido pedagógico para guiar la práctica educativa, verificar procedimientos y usar evidencias de aprendizaje, no solo mejora lo que ocurre en el aula de secundaria: también abre mejores posibilidades de éxito temprano en ingeniería. La clave no es la herramienta por sí misma, sino cómo se integra en la enseñanza y con qué condiciones se implementa. Se recomienda estructurar una retroalimentación breve, específica y accionable, de modo que el estudiantado la aplique en la siguiente iteración de la tarea (William, 2016).



CONCLUSIONES

La integración pedagógica de la inteligencia artificial fortalece competencias clave en la secundaria técnica, al combinar tutoría inteligente, verificación por visión y analítica de aprendizaje con propósito formativo. Estas estrategias se asocian con mejoras significativas en precisión experimental, argumentación, resolución de problemas y autorregulación, con tamaños de efecto educativos relevantes y replicables.

Las ganancias en educación básica se proyectan hacia el primer año de ingeniería, con incrementos en aprobación de asignaturas troncales (Cálculo I y Física I), mayor avance de créditos y persistencia al segundo semestre. Los resultados sugieren una transferencia de habilidades desde la práctica científica guiada hacia el desempeño académico inicial.

La calidad de implementación es el factor decisivo. Las mayores mejoras ocurrieron cuando se cumplieron tres condiciones: iteraciones suficientes por práctica, retroalimentación oportuna y específica, y uso consistente de rúbricas para informes y procedimientos. En ausencia de estas condiciones, los efectos disminuyen.

La conectividad condiciona, pero no determina los resultados. Las escuelas urbanas y con mejor conectividad obtuvieron efectos superiores; no obstante, los planteles rurales mejoraron cuando se aseguró un piso operativo (sincronización diferida, tiempos protegidos de práctica y acompañamiento docente). Esto indica que el diseño instruccional y la gestión escolar pueden mitigar restricciones de infraestructura.

Los mecanismos de cambio son identificables. El análisis sugiere que la precisión experimental y la autorregulación actúan como mediadores del efecto sobre la aprobación y la persistencia. En términos prácticos, las tareas que obligan a medir, verificar y argumentar, junto con un seguimiento metacognitivo explícito, explican parte sustantiva de los resultados en superior.

El diseño por rondas de implementación fue factible y formativo. Permitir que todas las escuelas participaran en distintos momentos facilitó el acompañamiento técnico-pedagógico, el monitoreo de fidelidad y el intercambio de aprendizajes entre planteles, sin interrumpir la operación escolar.

Implicaciones para currículo y formación docente.



Se recomienda incorporar, en planeaciones de ciencias y matemáticas, secuencias breves y frecuentes de práctica experimental con verificación automatizada de pasos críticos, feedback inmediato y rúbricas compartidas con la educación superior. La formación docente debe centrarse en uso pedagógico de IA, evaluación formativa y gestión ética de datos.

Orientaciones de política y equidad. La adopción de IA en educación básica requiere gobernanza de datos, resguardo de la privacidad de menores y financiamiento escalonado que priorice planteles con mayor rezago. Es pertinente definir metas de implementación (mínimos de iteraciones, tiempos de retroalimentación, cobertura por grado) y asegurar acompañamiento técnico-pedagógico.

Alcances y límites. Aunque el diseño analítico fortalece la inferencia, no sustituye a un ensayo aleatorizado; además, parte de los indicadores universitarios pueden variar por criterios institucionales. La autorregulación se midió con escala breve; combinar autorreporte con trazas conductuales en futuras aplicaciones aumentará la validez.

Al Integrar IA para guiar práctica auténtica, verificar procedimientos y aprovechar trazas de aprendizaje desde la secundaria técnica eleva competencias científicas y matemáticas y se asocia con mejor arranque en ingeniería. El valor no radica en la herramienta por sí sola, sino en el diseño didáctico, la retroalimentación de calidad y las condiciones de implementación que permiten que la tecnología amplifique el aprendizaje y promueva la equidad.

REFERENCIAS

- Achuthan, K., Raghavan, D., & Shankar, B. (2021). *Impact of remote experimentation, interactivity and platform effectiveness on laboratory learning outcomes. International Journal of Educational Technology in Higher Education*, 18, 38. <https://educationaltechnologyjournal.springeropen.com/articles/10.1186/s41239-021-00272-z>
- Azur, M. J., Stuart, E. A., Frangakis, C., & Leaf, P. J. (2011). *Multiple imputation by chained equations: What is it and how does it work? International Journal of Methods in Psychiatric Research*, 20(1), 40–49. <https://pmc.ncbi.nlm.nih.gov/articles/PMC3074241/>



- Banerjee, A. V., Cole, S., Duflo, E., & Linden, L. (2007). *Remedying education: Evidence from two randomized experiments in India*. *The Quarterly Journal of Economics*, 122(3), 1235–1264.
https://www.nber.org/system/files/working_papers/w11904/w11904.pdf
- Black, P., & Wiliam, D. (1998). *Assessment and classroom learning*. *Assessment in Education: Principles, Policy & Practice*, 5(1), 7–74. https://assess.ucr.edu/sites/default/files/2019-02/blackwiliam_1998.pdf
- Cunningham, S. (2021). *Causal Inference: The Mixtape*. [Libro en línea, acceso abierto].
<https://mixtape.scunning.com/>
- Graham, M. J., Frederick, J., Byars-Winston, A., Hunter, A.-B., & Handelsman, J. (2013). *Increasing persistence of college students in STEM*. *Science*, 341(6153), 1455–1456.
<https://pmc.ncbi.nlm.nih.gov/articles/PMC10167736/>
- Heradio, R., de la Torre, L., & Dormido, S. (2016). *Virtual and remote labs in control education: A survey*. *Annual Reviews in Control*, 42, 1–10.
<https://daneshyari.com/article/preview/4999550.pdf>
- Hemming, K., Haines, T. P., Chilton, P. J., Girling, A. J., & Lilford, R. J. (2015). *The stepped wedge cluster randomised trial: Rationale, design, analysis, and reporting*. *BMJ*, 350, h391.
<https://www.bmj.com/content/350/bmj.h391>
- Hernán, M. A., & Robins, J. M. (2020). *Causal Inference: What If*. [Edición en línea, acceso abierto].
https://content.sph.harvard.edu/wwwhsph/sites/1268/2024/01/hernanrobins_WhatIf_2jan24.pdf
- Hsu, J. L., & Dudley, L. (2022). *Characterizing first-year biology majors' motivations and perceptions of the discipline*. *Journal of Microbiology & Biology Education*, 23(3), e00134-22. (PMC OA). <https://pmc.ncbi.nlm.nih.gov/articles/PMC9753663/>
- Ifenthaler, D., & Yau, J. Y.-K. (2020). *Utilising learning analytics to support study success in higher education: A systematic review*. *Educational Technology Research and Development*, 68(4), 1961–1990. <https://rdcu.be/eJ9Xi>



- Muralidharan, K., Singh, A., & Ganimian, A. J. (2019). *Disrupting education? Experimental evidence on technology-aided instruction in India*. *American Economic Review*, 109(4), 1426–1460.
https://www.nber.org/system/files/working_papers/w22923/w22923.pdf
- UNESCO. (2021). *AI and education: Guidance for policy-makers*.https://teachertaskforce.org/sites/default/files/2023-07/2021_UNESCO_AI-and-education-Guidande-for-policy-makers_EN.pdf
- UNESCO. (2023). *Guidance for generative AI in education and research*.<https://unesdoc.unesco.org/ark:/48223/pf0000386693>
- Wiliam, D. (2016). The secret of effective feedback. *Educational Leadership*, 73(7).
<https://www.ascd.org/el/articles/the-secret-of-effective-feedback>

