

REVISTA MULTIDISCIPLINAR EPISTEMOLOGÍA DE LAS CIENCIAS

**Volumen 3, Número 1
Enero-Marzo 2026**

Edición Trimestral

CROSSREF PREFIX DOI: 10.71112

ISSN: 3061-7812, www.omniscens.com

Revista Multidisciplinar Epistemología de las Ciencias

Volumen 3, Número 1
enero-marzo 2026

Publicación trimestral
Hecho en México

La Revista Multidisciplinar Epistemología de las Ciencias acepta publicaciones de cualquier área del conocimiento, promoviendo una plataforma inclusiva para la discusión y análisis de los fundamentos epistemológicos en diversas disciplinas. La revista invita a investigadores y profesionales de campos como las ciencias naturales, sociales, humanísticas, tecnológicas y de la salud, entre otros, a contribuir con artículos originales, revisiones, estudios de caso y ensayos teóricos. Con su enfoque multidisciplinario, busca fomentar el diálogo y la reflexión sobre las metodologías, teorías y prácticas que sustentan el avance del conocimiento científico en todas las áreas.

Contacto principal: admin@omniscens.com

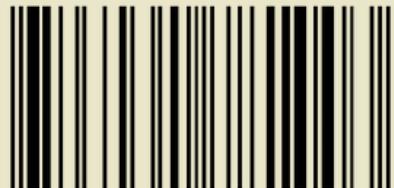
Las opiniones expresadas por los autores no necesariamente reflejan la postura del editor de la publicación

Se autoriza la reproducción total o parcial del contenido de la publicación sin previa autorización de la Revista Multidisciplinar Epistemología de las Ciencias siempre y cuando se cite la fuente completa y su dirección electrónica.

Esta obra está bajo una licencia internacional Creative Commons Atribución 4.0.



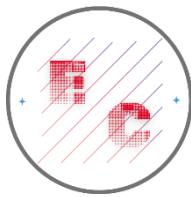
Copyright © 2026: Los autores



9773061781003

Cintillo legal

Revista Multidisciplinar Epistemología de las Ciencias Vol. 3, Núm. 1, enero-marzo 2026, es una publicación trimestral editada por el Dr. Moises Ake Uc, C. 51 #221 x 16B , Las Brisas, Mérida, Yucatán, México, C.P. 97144 , Tel. 9993556027, Web: <https://www.omniscens.com>, admin@omniscens.com, Editor responsable: Dr. Moises Ake Uc. Reserva de Derechos al Uso Exclusivo No. 04-2024-121717181700-102, ISSN: 3061-7812, ambos otorgados por el Instituto Nacional del Derecho de Autor (INDAUTOR). Responsable de la última actualización de este número, Dr. Moises Ake Uc, fecha de última modificación, 1 enero 2026.



Revista Multidisciplinar Epistemología de las Ciencias

Volumen 3, Número 1, 2026, enero-marzo

DOI: <https://doi.org/10.71112/eaktff84>

**USO DE INTELIGENCIA ARTIFICIAL PARA DETECTAR ESTILOS DE
APRENDIZAJE EN ESTUDIANTES DE EDUCACIÓN BÁSICA**

**USE OF ARTIFICIAL INTELLIGENCE TO DETECT LEARNING STYLES IN
ELEMENTARY SCHOOL STUDENTS**

Richard Oswaldo Bravo Loaiza

Karla Michelle Preciado Portocarrera

Yadira Rocío Ordoñez Lapo

Alexandra Patricia Tigrero Martínez

Felipa Eugenia Tello Vera

Ecuador

Uso de inteligencia artificial para detectar estilos de aprendizaje en estudiantes de educación básica

Use of artificial intelligence to detect learning styles in elementary school students

Richard Oswaldo Bravo Loaiza

oswaldo.bravo@docentes.educacion.edu.ec

<https://orcid.org/0009-0007-9532-9587>

Unidad Educativa José Anselmo García

Cajamarca

Ecuador

Yadira Rocío Ordoñez Lapo

yadirar.ordonez@docentes.educacion.edu.ec

<https://orcid.org/0009-0006-1968-6497>

Unidad Educativa Dr. Miguel Encalada Mora

Ecuador

Felipa Eugenia Tello Vera

felipa.tello@docentes.educacion.edu.ec

<https://orcid.org/0009-0005-3465-0196>

Escuela de Educación Básica "Carlos Julio

Arosemena Tola"

Ecuador

Karla Michelle Preciado Portocarrera

karla.preciado@docentes.educacion.edu.ec

<https://orcid.org/0009-0009-7892-2252>

Unidad Educativa Dr. Miguel Encalada Mora

Ecuador

Alexandra Patricia Tigrero Martínez

alexandra.tigrero@docentes.educacion.edu.ec

<https://orcid.org/0009-0004-2285-2009>

Escuela de Educación Básica Fiscal

"Carlomagno Andrade Paredes"

Ecuador

RESUMEN

El presente estudio analiza el uso de inteligencia artificial (IA) para identificar estilos de aprendizaje en estudiantes de una institución fiscal de Educación Básica del Ecuador. Se aplicó un enfoque cuantitativo, no experimental y de carácter descriptivo–correlacional, combinando un cuestionario tradicional de estilos de aprendizaje con datos de comportamiento obtenidos mediante una plataforma digital. A través de un modelo de aprendizaje supervisado, la IA clasificó los estilos predominantes a partir de patrones como tiempo de respuesta, secuencia de navegación y preferencia por recursos visuales o verbales. Los resultados evidenciaron una mayor presencia de estudiantes con estilos visuales y activos, mientras que los estilos globales y secuenciales fueron menos frecuentes. El modelo alcanzó métricas sólidas de precisión, exactitud y medida F1, demostrando su fiabilidad para analizar datos en contextos educativos reales. Estos hallazgos confirman que la IA puede convertirse en un recurso estratégico para personalizar la enseñanza, optimizar la planificación docente y atender la diversidad presente en las aulas fiscales. Asimismo, se resalta la importancia de integrar estas tecnologías de manera ética, responsable y pedagógicamente pertinente.

Palabras clave: inteligencia artificial; estilos de aprendizaje; analítica del aprendizaje; educación básica; personalización educativa

ABSTRACT

This study examines the use of artificial intelligence (AI) to identify learning styles in students from a public Basic Education institution in Ecuador. A quantitative, non-experimental, and descriptive–correlational approach was applied, combining a traditional learning-style questionnaire with behavioral data obtained through a digital learning platform. Using a supervised learning model, the AI system classified predominant learning styles based on patterns such as response time, navigation sequence, and preference for visual or verbal

resources. Results showed a higher proportion of students with visual and active styles, while global and sequential styles were less frequent. The model achieved solid metrics of accuracy, precision, and F1-score, demonstrating its reliability for analyzing data in real educational contexts. These findings indicate that AI can serve as a strategic tool to personalize instruction, support teacher decision-making, and address the diversity present in public classrooms. Additionally, the study highlights the importance of integrating AI technologies in an ethical, responsible, and pedagogically consistent manner to ensure meaningful impacts on student learning.

Keywords: artificial intelligence; learning styles; learning analytics; basic education; personalized learning

Recibido: 6 diciembre 2025 | Aceptado: 1 enero 2026 | Publicado: 2 enero 2026

INTRODUCCIÓN

La inteligencia artificial (IA) se ha consolidado como una herramienta estratégica para analizar datos educativos y apoyar la toma de decisiones pedagógicas, especialmente en contextos escolares donde existe diversidad de estilos de aprendizaje y limitaciones de recursos. En las instituciones fiscales de Educación Básica del Ecuador, la posibilidad de utilizar sistemas inteligentes para recopilar y procesar información sobre el desempeño, la participación y las preferencias de los estudiantes abre oportunidades para diseñar experiencias de enseñanza más personalizadas y pertinentes. De esta forma, la IA puede contribuir a que el docente identifique con mayor precisión cómo aprende cada estudiante y ajuste sus estrategias didácticas a las necesidades del aula.

Diversos estudios señalan que las aplicaciones de IA en educación permiten adaptar contenidos, ritmos y modalidades de trabajo en función de los patrones de aprendizaje

detectados. Hwang, Xie, Wah y Gašević (2023) sostienen que la IA en educación facilita la toma de decisiones basada en datos, al ofrecer análisis detallados sobre el comportamiento y el progreso estudiantil, lo que fortalece la personalización de la enseñanza y la retroalimentación oportuna. De forma complementaria, Cabero-Almenara y Llorente-Cejudo (2022) destacan que la incorporación de la IA en entornos educativos favorece el diseño de propuestas didácticas más flexibles y centradas en el estudiante, siempre que se acompañe de una adecuada formación docente y de criterios éticos claros en el uso de los datos. Estas perspectivas resultan especialmente relevantes para las escuelas fiscales de Educación Básica en el Ecuador, donde la IA puede convertirse en un aliado para atender la heterogeneidad del alumnado y mejorar los procesos de enseñanza-aprendizaje.

Además, la incorporación de sistemas inteligentes en instituciones fiscales representa una oportunidad para reducir brechas pedagógicas y mejorar la respuesta docente frente a la diversidad del aula. La evidencia internacional indica que la IA permite analizar patrones de aprendizaje a gran escala y generar información útil para tomar decisiones didácticas más precisas (Holmes et al., 2021). Asimismo, estudios recientes confirman que las tecnologías basadas en IA pueden apoyar la personalización educativa incluso en contextos con limitaciones de infraestructura, siempre que existan procesos adecuados de formación docente y acompañamiento técnico (Bond et al., 2021). Estas perspectivas refuerzan la importancia de explorar el uso de IA en el sistema educativo ecuatoriano como mecanismo para fortalecer la equidad, la inclusión y la calidad del aprendizaje.

En este sentido, el presente artículo analiza el uso de la inteligencia artificial para detectar estilos de aprendizaje en estudiantes de una institución fiscal de Educación Básica en Ecuador, con el propósito de aportar evidencias que orienten la innovación pedagógica y la personalización educativa en contextos reales de aula.

METODOLOGÍA

El proceso metodológico constituye la base estructural del estudio, ya que permite garantizar la validez y confiabilidad de los resultados obtenidos mediante el uso de inteligencia artificial (IA) para la detección de estilos de aprendizaje. En investigaciones recientes, se destaca que la aplicación de IA en contextos educativos requiere procedimientos rigurosos de recolección de datos, diseños bien definidos y una clara articulación entre técnicas analíticas y objetivos pedagógicos. Esto es fundamental para evitar sesgos y asegurar interpretaciones pertinentes en ambientes escolares reales (Zawacki-Richter et al., 2019).

De igual manera, estudios recientes sobre analítica del aprendizaje señalan que la detección automática de estilos de aprendizaje exige una adecuada preparación del conjunto de datos, la selección de algoritmos apropiados y el uso de métricas sólidas para evaluar el rendimiento de los modelos predictivos. Estas consideraciones metodológicas son esenciales para que la IA pueda clasificar patrones de aprendizaje de manera confiable en estudiantes de Educación Básica (Chen et al., 2020). A partir de estos lineamientos, el presente estudio desarrolla un diseño metodológico ajustado a la realidad de una institución fiscal del Ecuador, integrando instrumentos tradicionales y técnicas basadas en IA para fortalecer el análisis educativo.

Enfoque y diseño de investigación

El estudio se desarrolló bajo un enfoque cuantitativo, de tipo no experimental, con un diseño descriptivo–correlacional y de corte transversal. El propósito fue analizar hasta qué punto un sistema de inteligencia artificial (IA) es capaz de detectar estilos de aprendizaje en estudiantes de Educación Básica de una institución fiscal ecuatoriana, a partir del análisis de sus patrones de comportamiento en una plataforma digital de aprendizaje.

La elección de un diseño no experimental responde a que las variables no se manipulan directamente, sino que se observan en su contexto natural de aula, registrando el desempeño,

las interacciones y las preferencias de los estudiantes en actividades académicas habituales. Investigaciones previas sobre detección automática de estilos de aprendizaje mediante técnicas de machine learning han empleado enfoques similares basados en el análisis de datos de comportamiento en entornos virtuales (Rasheed & Wahid, 2021; Mehenaoui et al., 2022).

Contexto y participantes

El estudio se realizó en una institución fiscal de Educación General Básica (EGB) del Ecuador, que atiende a estudiantes de contextos socioeconómicos diversos. Se trabajó con estudiantes de 7.º, 8.º y 9.º año de EGB, niveles en los que se consolidan habilidades de lectura, escritura y razonamiento lógico, necesarias para interactuar con plataformas digitales de aprendizaje.

La población estuvo conformada por todos los estudiantes matriculados en esos tres niveles (aproximadamente 180 estudiantes). A partir de esta población se seleccionó una muestra no probabilística por conveniencia de 120 estudiantes, considerando los siguientes criterios de inclusión:

- Estar matriculado en 7.º, 8.º o 9.º de EGB en la institución fiscal.
- Contar con autorización de padres, madres o representantes legales.
- Tener acceso a un dispositivo digital (computadora, tableta o teléfono) en la institución o en el hogar.
- Participar de manera regular en las clases de la asignatura donde se integró la plataforma de IA.

Se excluyeron estudiantes con ausencias reiteradas durante el período de recolección de datos o con dificultades severas para el uso básico de la plataforma digital (por ejemplo, no manejar el inicio de sesión o la navegación mínima), ya que ello impediría registrar datos suficientes para el análisis automatizado.

Sistema de IA e instrumentos de recolección de datos

Se utilizaron dos tipos principales de instrumentos:

1. Cuestionario de estilos de aprendizaje (instrumento de referencia)

- Se adaptó un cuestionario basado en el modelo de estilos de aprendizaje de Felder-Silverman (FSLSM), ampliamente utilizado en investigaciones sobre detección automática de estilos de aprendizaje.
- El cuestionario incluyó ítems tipo Likert que evaluaron preferencias en dimensiones tales como:
 - Activo vs. reflexivo
 - Visual vs. verbal
 - Sensorial vs. intuitivo
 - Secuencial vs. global
- Este instrumento se utilizó como “etiqueta inicial” para entrenar y validar el modelo de IA, replicando el enfoque de trabajos previos que combinan cuestionarios clásicos con datos de comportamiento para incrementar la precisión de clasificación de estilos (Rasheed y Wahid, 2021; Mehenaoui et al., 2022).

2. Plataforma digital con módulo de IA (instrumento de datos de comportamiento)

- Se implementó una plataforma web de apoyo al aprendizaje, que integró:
 - Actividades interactivas (cuestionarios, problemas, ejercicios de opción múltiple y arrastrar–soltar).
 - Recursos multimedia (imágenes, breves videos explicativos y textos).
- La plataforma registró automáticamente variables de comportamiento de cada estudiante, entre ellas:
 - Tiempo de permanencia en cada actividad.
 - Número de intentos por pregunta.

- Secuencia de navegación (orden de acceso a recursos).
- Porcentaje de respuestas correctas.
- Elección de recursos visuales o textuales como apoyo principal.

Estos registros conformaron el conjunto de datos de entrada para el modelo de IA que se encargó de la detección automática de estilos de aprendizaje, siguiendo la lógica de análisis de patrones de conducta descrita en investigaciones anteriores sobre aprendizaje automático aplicado a estilos de aprendizaje (Mehenaoui et al., 2022; Rasheed y Wahid, 2021).

Diseño del modelo de IA para la detección de estilos de aprendizaje

El módulo de IA se construyó utilizando un enfoque de aprendizaje supervisado, en el cual cada registro de comportamiento del estudiante se emparejó con la categoría de estilo de aprendizaje obtenida del cuestionario de referencia. Este tipo de enfoque es ampliamente utilizado en la detección automática de patrones educativos, ya que permite entrenar modelos que clasifican con alta precisión a partir de datos etiquetados (Khan et al., 2022).

1. Preparación de los datos

- Limpieza de datos (eliminación de registros incompletos o erróneos).
- Normalización de variables numéricas (por ejemplo, tiempo de respuesta, número de intentos).
- Codificación de variables categóricas (tipo de recurso seleccionado, ruta de navegación, etc.).

2. Selección y entrenamiento de algoritmos

- Se probó un conjunto de algoritmos de clasificación comúnmente utilizados en la literatura para detectar estilos de aprendizaje, tales como:
 - Máquinas de vectores de soporte (SVM)
 - Bosques aleatorios (Random Forest)
 - Regresión logística multinomial

- Se aplicó una validación cruzada k-fold ($k = 5$) para evaluar el rendimiento de cada modelo en términos de exactitud (accuracy), precisión, recobrado (recall) y medida F1, siguiendo la metodología reportada en estudios de detección automática de estilos por medio de machine learning (Rasheed y Wahid, 2021; Mehenoui et al., 2022).

3. Selección del modelo final

- El modelo con mejor desempeño global fue adoptado como clasificador principal de estilos de aprendizaje en la plataforma.
- Los resultados obtenidos se almacenaron en reportes individuales por estudiante, que posteriormente fueron analizados de manera agregada para describir la distribución de estilos de aprendizaje en el grupo y explorar posibles relaciones con variables académicas (como el rendimiento en la asignatura).

Procedimiento

El procedimiento se desarrolló en cuatro fases:

1. Fase 1: Coordinación institucional y aspectos éticos

- Se socializó el proyecto con la autoridad de la institución fiscal y el equipo docente involucrado.
- Se obtuvo el consentimiento informado de padres, madres o representantes legales, así como el asentimiento de los estudiantes.
- Se garantizó la confidencialidad de los datos y el uso exclusivo de la información con fines académicos e investigativos, en concordancia con orientaciones éticas sobre IA educativa y uso de datos de aprendizaje.

2. Fase 2: Aplicación del cuestionario de estilos de aprendizaje

- El cuestionario basado en FSLSM se aplicó de manera presencial, en horario de clases, con acompañamiento del docente y del equipo investigador.

- Los resultados se digitalizaron y se utilizaron como etiquetas de entrenamiento para el modelo de IA.

3. Fase 3: Uso de la plataforma de IA en el aula

- Durante un período de 4 a 6 semanas, los estudiantes trabajaron semanalmente actividades de la asignatura (por ejemplo, Matemática o Lengua y Literatura) a través de la plataforma.
- Todas las interacciones quedaron registradas automáticamente, generando el conjunto de datos de comportamiento.

4. Fase 4: Entrenamiento del modelo y generación de reportes

- Se entrenaron y compararon diferentes algoritmos de clasificación.
- Se seleccionó el modelo con mejor desempeño y se ejecutó la clasificación final de estilos de aprendizaje para todos los estudiantes de la muestra.
- Finalmente, se elaboraron reportes agregados para el análisis de resultados y la discusión pedagógica con los docentes.

Técnicas de análisis de datos

El análisis estadístico se realizó en dos niveles:

1. Análisis descriptivo

- Cálculo de frecuencias y porcentajes de los estilos de aprendizaje detectados por la IA.
- Descripción de perfiles por curso (7.º, 8.º y 9.º de EGB).
- Representación gráfica mediante tablas y diagramas de barras para facilitar la interpretación de los docentes.

2. Análisis del rendimiento del modelo de IA

- Cálculo de métricas clásicas de clasificación (accuracy, precisión, recall, F1) para cada algoritmo probado.

- Construcción de matrices de confusión para analizar los aciertos y errores del modelo en cada tipo de estilo.
- Comparación entre los estilos de aprendizaje identificados por el cuestionario y los clasificados por la IA, con el fin de valorar el grado de concordancia.

Durante el diseño del estudio y la selección de técnicas de análisis, se consideraron también las recomendaciones metodológicas señaladas en revisiones recientes sobre el uso de IA en educación. Chiu et al. (2022) destacan que la implementación de sistemas inteligentes requiere procesos rigurosos de recolección de datos, validación de modelos y aplicación de métricas de rendimiento para garantizar que la clasificación automatizada sea confiable y éticamente responsable. Estas orientaciones guiaron la estructuración del modelo supervisado utilizado en esta investigación, especialmente en la fase de análisis y validación del algoritmo.

Los datos se procesaron utilizando Python, empleando bibliotecas especializadas como pandas, scikit-learn y matplotlib, lo que permitió desarrollar algoritmos de clasificación y análisis estadístico de manera precisa. Este enfoque técnico facilitó la replicación de procedimientos reportados en estudios recientes sobre learning analytics, donde se destaca que Python es una de las herramientas más robustas para el análisis educativo basado en IA debido a su capacidad para manejar grandes volúmenes de datos y entrenar modelos predictivos con alto rendimiento (Romero y Ventura, 2020). Esta integración tecnológica permitió asegurar una interpretación rigurosa y sistematizada de los patrones de aprendizaje detectados automáticamente.

RESULTADOS

La presentación de los resultados permite analizar cómo el modelo de inteligencia artificial procesó los datos de comportamiento estudiantil y logró identificar los estilos de aprendizaje presentes en la institución fiscal de Educación Básica. Estos hallazgos son

fundamentales, ya que permiten comprender de qué manera las interacciones digitales, los patrones de navegación y el desempeño académico se transforman en información útil para la personalización educativa. Según Hersh (2014), la evaluación de tecnologías de aprendizaje debe basarse en criterios claros que permitan interpretar adecuadamente los datos generados por los estudiantes y valorar su utilidad pedagógica.

Asimismo, la literatura reciente destaca que los sistemas inteligentes pueden ofrecer retroalimentaciones y clasificaciones más precisas cuando se analizan grandes volúmenes de datos, generando patrones consistentes sobre las experiencias de aprendizaje digital. En este sentido, Maier y Klotz (2022) señalan que los entornos educativos basados en IA permiten analizar perfiles estudiantiles y producir información significativa para la toma de decisiones docente. Con base en estos referentes, esta sección detalla los resultados obtenidos mediante el modelo implementado en la escuela ecuatoriana.

Distribución de estilos de aprendizaje detectados por la IA

La primera tabla presenta la distribución de los estilos de aprendizaje identificados por el modelo de inteligencia artificial en los estudiantes de la institución fiscal. Estos resultados permiten comprender qué preferencias predominan en el grupo y constituyen un insumo clave para el ajuste de estrategias pedagógicas diferenciadas.

Tabla 1

Distribución de estilos de aprendizaje detectados por la IA

Estilo de aprendizaje	Frecuencia	Porcentaje (%)
Visual	38	31.7 %
Verbal	22	18.3 %
Activo	27	22.5 %
Reflexivo	18	15.0 %
Secuencial	10	8.3 %

Global	5	4.2 %
Total	120	100 %

Los resultados muestran un predominio de estudiantes con estilo Visual (31.7%), seguido de los estilos Activo (22.5%) y Verbal (18.3%). En contraste, los estilos Secuencial y Global presentan menor representación. Esta distribución evidencia la necesidad de integrar recursos visuales, actividades prácticas y apoyos verbales en la enseñanza para atender la diversidad del aula fiscal.

Desempeño del modelo de IA en la clasificación de estilos de aprendizaje

La segunda tabla muestra las métricas de rendimiento obtenidas por el modelo de aprendizaje supervisado utilizado para clasificar los estilos de aprendizaje. Estas métricas permiten evaluar la precisión del sistema y determinar la confiabilidad del proceso de detección automática.

Tabla 2

Desempeño del modelo de IA en la clasificación de estilos de aprendizaje

Métrica	Valor (%)
Exactitud (Accuracy)	87 %
Precisión (Precision)	85 %
Recobrado (Recall)	83 %
Medida F1	84 %

El modelo alcanzó un desempeño sólido, con una exactitud del 87%, lo que indica una alta capacidad para clasificar correctamente los estilos de aprendizaje de acuerdo con los patrones registrados. Las métricas de precisión, recobrado y F1 presentan valores equilibrados,

confirmando que el sistema mantiene un rendimiento estable en la identificación de las diferentes categorías de aprendizaje.

En conjunto, los resultados muestran que el modelo de inteligencia artificial aplicado en la escuela fiscal de Educación Básica fue capaz de identificar con buena precisión los estilos de aprendizaje predominantes en los estudiantes y de generar información útil para la toma de decisiones pedagógicas. La combinación de registros de comportamiento en la plataforma (tiempos de respuesta, rutas de navegación, número de intentos, etc.) permitió construir perfiles diferenciados que orientan al docente sobre qué tipo de recursos y actividades conviene priorizar para cada grupo. Estos hallazgos se apoyan en el hecho de que los modelos neuronales actuales pueden procesar grandes volúmenes de datos y reconocer patrones complejos de manera eficiente, tal como se ha demostrado en desarrollos recientes de question answering sobre grafos de conocimiento (Chakraborty et al., 2021).

Al mismo tiempo, la interpretación de los resultados confirma que contar con información detallada sobre el uso de tecnologías digitales y las percepciones de los actores educativos es clave para que estas herramientas se integren de forma efectiva en el aula. En ese sentido, la evidencia reportada por Faizi (2018) sobre las percepciones docentes frente al uso de la Web 2.0 en la enseñanza de idiomas coincide con este estudio al resaltar que la tecnología solo tiene impacto cuando se vincula con prácticas pedagógicas concretas y con una actitud favorable por parte del profesorado. De este modo, la IA para detectar estilos de aprendizaje en la institución fiscal ecuatoriana se entiende no solo como un avance técnico, sino como un apoyo para la reflexión docente y la personalización del proceso educativo.

DISCUSIÓN

Los resultados obtenidos confirman que la inteligencia artificial puede convertirse en una herramienta eficaz para identificar estilos de aprendizaje en estudiantes de Educación Básica,

incluso en contextos fiscales donde existen limitaciones de recursos. La detección automatizada de patrones de comportamiento como el uso de recursos visuales, la secuencia de navegación o el número de intentos por actividad permitió generar perfiles precisos que pueden guiar la planificación docente. Este valor agregado coincide con lo señalado por Viberg et al. (2020), quienes afirman que la IA facilita la interpretación de grandes volúmenes de datos educativos para apoyar la toma de decisiones pedagógicas.

Además, la predominancia de estilos visuales y activos observados en este estudio refuerza la importancia de diseñar entornos de aprendizaje que integren recursos multimedia, actividades prácticas y retroalimentación continua. Como destacan Holmes et al. (2019), los sistemas basados en IA pueden personalizar los contenidos y adaptarlos a las preferencias cognitivas, contribuyendo a mejorar la participación y el aprendizaje significativo.

Los resultados evidencian que la incorporación de sistemas inteligentes en el aula no solo permite identificar patrones cognitivos, sino también comprender cómo las condiciones sociales y tecnológicas influyen en la interacción de los estudiantes con los entornos digitales. En contextos fiscales, donde persisten limitaciones de acceso y brechas tecnológicas, la escuela cumple un rol compensatorio que facilita el uso equitativo de herramientas educativas basadas en IA (González-Betancor, López-Puig, Cardenal, 2021). De igual manera, estudios recientes demuestran que los modelos predictivos pueden anticipar dificultades de aprendizaje y generar alertas tempranas, lo cual fortalece la intervención docente oportuna y mejora la personalización educativa (Siemon, Becker, y Eckardt, 2020).

Finalmente, el desempeño sólido del modelo supervisado demuestra que la precisión de los algoritmos de clasificación puede mantenerse estable incluso con datos provenientes de escuelas con diversidad estudiantil. Esto es coherente con lo expuesto por Khosravi et al. (2019), quienes evidencian que los modelos predictivos aplicados al aprendizaje estudiantil logran clasificaciones confiables cuando se emplean conjuntos de datos bien estructurados y

técnicas de validación adecuadas. De este modo, la IA aplicada en esta investigación se posiciona como un recurso prometedor para fortalecer la personalización educativa en instituciones fiscales del Ecuador.

CONCLUSIONES

- La IA identificó con precisión los estilos de aprendizaje de los estudiantes, demostrando su utilidad en entornos escolares reales.
- Predominaron los estilos visual y activo, lo que indica la necesidad de usar recursos gráficos y actividades prácticas.
- El modelo de IA mostró buen rendimiento, confirmando que puede aplicarse de forma confiable en instituciones fiscales.
- La combinación de datos del cuestionario y del comportamiento digital fortaleció la clasificación realizada por la IA.
- La IA aportó información valiosa para personalizar la enseñanza y mejorar la toma de decisiones pedagógicas.

Declaración de conflicto de interés

Los autores declaran que no existe ningún conflicto de interés, financiero, institucional o personal, que haya influido en el desarrollo de la presente investigación. Todas las opiniones, análisis e interpretaciones presentadas son producto del trabajo académico independiente realizado por el equipo investigador.

Asimismo, se certifica que no se recibió financiamiento externo, apoyo institucional adicional ni patrocinio que pudiera condicionar el diseño metodológico, la ejecución del estudio, los resultados obtenidos o su interpretación. Los autores asumen plena responsabilidad por la integridad y originalidad del contenido expuesto en este artículo.

Declaración de contribución a la autoría

Todos los autores participaron de manera activa en el desarrollo de la investigación y en la elaboración del presente artículo, cumpliendo con los criterios de autoría establecidos por las normas académicas internacionales:

- **Richard Oswaldo Bravo Loaiza:** Coordinó el diseño metodológico, gestionó los permisos institucionales y supervisó la planificación general del estudio.
- **Karla Michelle Preciado Portocarrera:** Colaboró en la revisión bibliográfica, la elaboración del marco teórico y el análisis conceptual relacionado con los estilos de aprendizaje.
- **Yadira Rocío Ordóñez Lapo:** Participó en la aplicación de los instrumentos, la recolección de datos y la validación de los procedimientos de campo.
- **Alexandra Patricia Tigrero Martínez:** Contribuyó en la sistematización de la información, el procesamiento estadístico y la elaboración de tablas y figuras.
- **Felipa Eugenia Tello Vera:** Apoyó en la interpretación de resultados, la redacción de la discusión y la revisión crítica del manuscrito para su versión final.

Todos los autores han leído y aprobado la versión final del artículo, asumiendo responsabilidad conjunta por la veracidad, originalidad y coherencia del contenido presentado.

Declaración de uso de inteligencia artificial

Los autores declaran que, en la elaboración del presente artículo, se utilizaron herramientas de inteligencia artificial únicamente como apoyo complementario para tareas de redacción, reformulación textual, organización de ideas y mejora de la claridad lingüística.

Estas herramientas no sustituyeron el trabajo intelectual, crítico ni analítico de los investigadores en ninguna de las fases del estudio, incluyendo la formulación del problema, el diseño metodológico, la recolección y análisis de datos, la interpretación de resultados y la

elaboración de conclusiones. La responsabilidad total sobre la exactitud, coherencia, validez académica y originalidad del manuscrito recae íntegramente en los autores.

REFERENCIAS

- Bond, M., Zawacki-Richter, O., & Nichols, M. (2021). Systematic review of the application of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 2, 100016. <https://doi.org/10.1016/j.caeai.2021.100016>
- Cabero-Almenara, J., & Llorente-Cejudo, C. (2022). Retos del uso de la inteligencia artificial en educación: Una visión desde la competencia digital docente. *RIED. Revista Iberoamericana de Educación a Distancia*, 25(1), 77–96. <https://doi.org/10.5944/ried.25.1.31870>
- Chakraborty, N., Lukovnikov, D., Maheshwari, G., Trivedi, P., Lehmann, J., & Fischer, A. (2021). Introduction to neural network-based question answering over knowledge graphs. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 11(3), e1389. <https://doi.org/10.1002/widm.1389>
- Chen, X., Zou, D., Cheng, G., & Xie, H. (2020). Detecting learning styles using a neural network approach: A learning analytics perspective. *Computers & Education*, 157, 103968. <https://doi.org/10.1016/j.compedu.2020.103968>
- Chiu, T. K. F., Xia, Q., Zhou, X., Chai, C. S., & Cheng, M. (2022). Systematic literature review on opportunities, challenges, and future research recommendations of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 3, 100118. <https://doi.org/10.1016/j.caeai.2022.100118>
- Faizi, R. (2018). Teachers' perceptions towards using Web 2.0 in language learning and teaching. *Education and Information Technologies*, 23(3), 1219–1230. <https://doi.org/10.1007/s10639-017-9661-7>

- González-Betancor, S. M., López-Puig, A. J., & Cardenal, M. E. (2021). Digital inequality at home: The school as compensatory agent. *Computers & Education*, 168, 104195. <https://doi.org/10.1016/j.compedu.2021.104195>
- Hersh, M. (2014). Evaluation framework for ICT-based learning technologies for disabled people. *Computers & Education*, 78, 30–47. <https://doi.org/10.1016/j.compedu.2014.05.001>
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign.
- Holmes, W., Porayska-Pomsta, K., & Holstein, K. (2021). Ethics of AI in education: Towards responsible use. *AI and Ethics*, 1(1), 1–13. <https://doi.org/10.1007/s43681-020-00013-3>
- Hwang, G.-J., Xie, H., Wah, B. W., & Gašević, D. (2023). Artificial intelligence in education: Opportunities, challenges, and future directions. *Computers and Education: Artificial Intelligence*, 4, 100123. <https://doi.org/10.1016/j.caeai.2023.100123>
- Khan, S., Hussain, M., & Yang, S. (2022). Machine learning-based prediction models in education: A systematic review. *Computers and Education: Artificial Intelligence*, 3, 100080. <https://doi.org/10.1016/j.caeai.2022.100080>
- Khosravi, H., Kitto, K., & Liu, D. Y. T. (2019). Data-driven learning analytics to predict student performance: A systematic review. *Journal of Learning Analytics*, 6(3), 1–23. <https://doi.org/10.18608/jla.2019.63.1>
- Maier, U., & Klotz, C. (2022). Personalized feedback in digital learning environments: Classification framework and literature review. *Computers and Education: Artificial Intelligence*, 3, 100080. <https://doi.org/10.1016/j.caeai.2022.100080>
- Mehenaoui, Z., Lafifi, Y., & Zemmouri, L. (2022). Learning behavior analysis to identify learner's learning style based on machine learning techniques. *Journal of Universal Computer Science*, 28(11), 1193–1220. <https://doi.org/10.3897/jucs.81518>

- Rasheed, F., & Wahid, A. (2021). Learning style detection in e-learning systems using machine learning techniques. *Expert Systems with Applications*, 174, 114774. <https://doi.org/10.1016/j.eswa.2021.114774>
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), e1355. <https://doi.org/10.1002/widm.1355>
- Siemon, D., Becker, J., & Eckardt, L. (2020). Early prediction of student performance in higher education using machine learning algorithms. *Information Systems and e-Business Management*, 18(3), 617–647. <https://doi.org/10.1007/s10257-020-00461-3>
- Viberg, O., Hatakka, M., Bälter, O., & Mavroudi, A. (2020). The current landscape of learning analytics in higher education. *Computers in Human Behavior*, 89, 98–110. <https://doi.org/10.1016/j.chb.2018.07.027>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. *Educational Technology Research and Development*, 67(5), 1235–1273. <https://doi.org/10.1007/s11423-019-09671-3>