



INTELIGENCIA ARTIFICIAL Y PERSONALIZACIÓN DEL APRENDIZAJE: IMPACTO EN LA TOMA DE DECISIONES PEDAGÓGICAS EN EDUCACIÓN SUPERIOR

Damian Esteban Cabascango ¹
ORCID: 0009-0004-1531-6857

Diana Carolina Cáceres Chuquizala ²
ORCID: 0009-0002-0915-3612

Karen Andreina Ortega Rentería³
ORCID: 0000-0002-1216-8404

¹ Investigador, Escuela Superior Politécnica de Chimborazo. Correo: damian.cabascango@esPOCH.edu.ec

² Investigadora, Universidad Bolivariana del Ecuador. Correo: dcchuquizalae@ube.edu.ec

³ Investigadora, Universidad de Cantabria. Correo: kor319@alumnos.unican.es

RESUMEN

La creciente diversidad de estilos y ritmos de aprendizaje en la educación superior evidenció la necesidad de incorporar estrategias que favorecieran una enseñanza más personalizada y sustentada en el análisis de datos. El presente estudio tuvo como objetivo analizar el impacto de la inteligencia artificial (IA) en la personalización del aprendizaje y su contribución a la toma de decisiones pedagógicas en el contexto universitario. Se desarrolló una investigación con enfoque cuantitativo y alcance explicativo en una muestra de 80 estudiantes de una universidad pública ecuatoriana, distribuidos en un grupo con metodología tradicional y otro apoyado por herramientas basadas en IA. Se analizaron variables relacionadas con la participación, la interacción con recursos digitales, el tiempo de permanencia en plataformas virtuales y el desempeño académico mediante técnicas de estadística descriptiva e inferencial, incluyendo análisis de correlación y la prueba *t* de Welch para muestras independientes. Los resultados evidenciaron diferencias estadísticamente significativas entre los grupos ($p < 0,05$). Además, las herramientas basadas en IA permitieron identificar perfiles de aprendizaje con una precisión predictiva cercana al 85 %, mientras que se observó una correlación positiva entre la interacción digital y el rendimiento académico ($r = 0,71$). Se concluyó que la incorporación de la inteligencia artificial fortaleció la toma de decisiones pedagógicas al proporcionar evidencia objetiva para el seguimiento, la retroalimentación y la personalización del proceso educativo, contribuyendo al mejoramiento de la calidad del aprendizaje en la educación superior.

Palabras clave: Analítica Del Aprendizaje; Educación Superior; Inteligencia Artificial.

ABSTRACT

The growing diversity of learning styles and learning paces in higher education highlighted the need to incorporate strategies that promoted more personalized teaching supported by data-driven decision-making. This study aimed to analyze the impact of artificial intelligence (AI) on personalized learning and its contribution to pedagogical decision-making in the university context. A quantitative research design with an explanatory scope was conducted involving a sample of 80 students from a public Ecuadorian university, divided into a traditional teaching group and an experimental group supported by AI-based educational tools. Variables related to student participation, interaction with digital resources, time spent on virtual learning platforms, and academic performance were analyzed using descriptive and inferential statistical techniques, including correlation analysis and Welch's *t*-test for independent samples. The results revealed statistically significant differences between the two groups ($p < 0.05$). Furthermore, AI-based tools identified differentiated learning profiles with a predictive accuracy of approximately 85%, while a positive correlation was found between digital interaction and academic performance ($r = 0.71$). It was concluded that the integration of artificial intelligence strengthened pedagogical decision-making by providing objective evidence for monitoring, feedback, and personalization of the teaching-learning process, thereby contributing to the improvement of educational quality in higher education.

Keywords: Artificial Intelligence; Higher Education; Learning Analytics.

INTRODUCCIÓN

La transformación digital ha modificado de manera significativa los procesos de enseñanza, aprendizaje y evaluación en la educación superior. En este escenario, la inteligencia artificial (IA) adquiere relevancia por su capacidad para analizar grandes volúmenes de datos, identificar patrones de comportamiento académico y generar información útil para apoyar la toma de decisiones pedagógicas. Estas posibilidades han impulsado el desarrollo de modelos educativos más flexibles, adaptativos y centrados en el estudiante, especialmente en contextos donde se requiere responder a diferentes ritmos, estilos y necesidades de aprendizaje (UNESCO, 2023; Crompton & Burke, 2023; Bond et al., 2024).

A pesar de estos avances, en muchas instituciones universitarias todavía predominan metodologías tradicionales basadas en la transmisión homogénea de contenidos, lo que limita el seguimiento individualizado del estudiante y dificulta la detección temprana de problemas de rendimiento. Esta situación plantea la necesidad de incorporar herramientas que permitan no solo mejorar los resultados académicos, sino también comprender cómo aprende el estudiante, cómo interactúa con los recursos educativos y qué tipo de apoyo requiere durante el proceso formativo. Desde esta perspectiva, la IA y la analítica del aprendizaje ofrecen alternativas para transformar los datos educativos en información pertinente para la planificación, la retroalimentación y la intervención docente (Chen et al., 2020; Khosravi et al., 2022; Zawacki-Richter et al., 2019).

La personalización del aprendizaje constituye uno de los principales aportes de la inteligencia artificial en educación superior. Mediante el análisis de variables como la participación, el uso de recursos digitales, el tiempo de interacción y el desempeño académico, los sistemas inteligentes permiten construir perfiles de aprendizaje y orientar estrategias pedagógicas diferenciadas. Esto resulta especialmente importante porque la enseñanza universitaria no puede sostenerse únicamente en evaluaciones finales, sino en procesos de seguimiento continuo que ayuden al docente a identificar necesidades, anticipar dificultades y ajustar sus decisiones pedagógicas con base en evidencia (Siemens & Baker, 2012; Baker & Inventado, 2014; Khosravi et al., 2022).

En América Latina y, particularmente, en Ecuador, aún son limitadas las investigaciones experimentales que analizan el impacto de herramientas basadas en IA en la personalización del aprendizaje y en la toma de decisiones pedagógicas dentro de escenarios reales de educación superior. Aunque existen estudios sobre modelos predictivos y rendimiento académico, todavía se requiere evidencia que explique cómo dichos modelos pueden apoyar la práctica docente y contribuir a una enseñanza más contextualizada. Por ello, este estudio se justifica en la necesidad de aportar evidencia empírica sobre el uso de IA como recurso pedagógico para fortalecer el seguimiento académico y la personalización del aprendizaje universitario.

A partir de esta problemática, el presente estudio tiene como objetivo general analizar el impacto de la inteligencia artificial en la personalización del aprendizaje y su contribución a la toma de decisiones pedagógicas en el contexto de la educación superior. Para ello, se plantean tres objetivos específicos: comparar los resultados obtenidos mediante una metodología tradicional y una metodología apoyada por herramientas de inteligencia artificial; identificar la relación entre interacción digital, participación y desempeño académico; y evaluar la contribución de la IA en la toma de decisiones pedagógicas mediante indicadores académicos y de aprendizaje. La investigación parte de la hipótesis de que la implementación de herramientas basadas en inteligencia artificial mejora significativamente la personalización del aprendizaje y fortalece la toma de decisiones pedagógicas en comparación con las metodologías tradicionales.

ESTADO DEL ARTE

El estudio de la inteligencia artificial aplicada a la educación superior muestra un crecimiento sostenido en áreas como la predicción del rendimiento académico, la analítica del aprendizaje, los sistemas tutoriales inteligentes y la personalización de experiencias educativas. La literatura señala que la IA permite procesar datos académicos, identificar patrones de comportamiento estudiantil y anticipar dificultades en el aprendizaje, lo que favorece el seguimiento docente y la toma de decisiones pedagógicas basadas en evidencia (Chen et al., 2020; Khosravi et al., 2022; Waheed et al., 2020). En este campo, los modelos predictivos constituyen una de las aplicaciones más utilizadas, debido a que permiten estimar el desempeño académico a partir de variables como calificaciones previas, participación, uso de plataformas digitales, interacción con recursos educativos y tiempo dedicado al estudio (Hellas et al., 2018; Waheed et al., 2020).

El avance actual del campo no se limita a la predicción del rendimiento académico, sino que se orienta cada vez más hacia el uso pedagógico de los datos. Desde esta perspectiva, la analítica del aprendizaje permite transformar registros educativos dispersos en indicadores útiles para comprender el progreso del estudiante, ajustar estrategias didácticas y ofrecer retroalimentación diferenciada (Siemens & Baker, 2012; Baker & Inventado, 2014). Estudios recientes sostienen que la inteligencia artificial favorece la construcción de perfiles de aprendizaje más precisos, ya que integra información académica y comportamental para orientar intervenciones personalizadas, adaptar recursos y fortalecer el acompañamiento del estudiante durante el proceso formativo (Crompton & Burke, 2023; Bond et al., 2024; Khosravi et al., 2022).

Pese a estos avances, todavía existe la necesidad de profundizar en investigaciones experimentales que analicen el impacto pedagógico de la IA más allá de la predicción del desempeño. En América Latina y Ecuador predominan estudios conceptuales o de revisión, mientras que son más limitadas las investigaciones desarrolladas en escenarios reales de educación superior que comparen metodologías tradicionales con estrategias apoyadas por IA. Además, organismos internacionales advierten que estas tecnologías deben emplearse bajo principios de equidad, transparencia, protección de datos y responsabilidad docente, evitando que las decisiones educativas sean delegadas completamente a sistemas automatizados (OECD, 2019; UNESCO, 2023). En este contexto, el presente estudio aporta evidencia empírica al analizar cómo la IA contribuye a la personalización del aprendizaje y a la toma de decisiones pedagógicas en estudiantes universitarios.

MARCO TEÓRICO

La inteligencia artificial aplicada a la educación superior comprende el uso de sistemas computacionales capaces de analizar datos, identificar patrones y generar información útil para fortalecer los procesos de enseñanza y aprendizaje. En este campo, la IA permite procesar información académica y comportamental de los estudiantes, facilitando la detección de dificultades, la predicción del desempeño y el seguimiento del progreso formativo (Chen et al., 2020; Khosravi et al., 2022). Desde esta perspectiva, su valor no se limita a la automatización de tareas, sino que se relaciona con la posibilidad de transformar los datos educativos en evidencia para orientar la planificación docente, la retroalimentación y la mejora continua del proceso educativo (UNESCO, 2023).


La personalización del aprendizaje se entiende como la adaptación de contenidos, actividades, recursos y evaluaciones a las características, necesidades y ritmo de aprendizaje de cada estudiante. En educación superior, este enfoque adquiere relevancia porque los estudiantes presentan diferencias en conocimientos previos, participación, competencias digitales y formas de interacción con los recursos educativos. La IA fortalece esta personalización al integrar variables como desempeño académico, uso de plataformas, participación y tiempo de estudio, permitiendo construir perfiles de aprendizaje más precisos

y orientar estrategias pedagógicas diferenciadas (Luckin et al., 2016; Crompton & Burke, 2023; Bond et al., 2024).

La toma de decisiones pedagógicas basada en datos se refiere al uso de información objetiva para planificar, ajustar y evaluar las estrategias de enseñanza. En este proceso, la analítica del aprendizaje cumple un papel central, ya que permite recopilar e interpretar los datos generados durante las actividades educativas para comprender el comportamiento del estudiante y optimizar su acompañamiento (Siemens & Baker, 2012; Baker & Inventado, 2014). Integrada con modelos de inteligencia artificial, esta analítica facilita la identificación de estudiantes en riesgo, la generación de alertas tempranas y el diseño de intervenciones oportunas. Por ello, la IA no reemplaza el criterio docente, sino que lo complementa mediante información contextualizada que favorece una enseñanza más personalizada, ética y sustentada en evidencia (OECD, 2019; Khosravi et al., 2022; UNESCO, 2023). Esta relación entre la inteligencia artificial, la personalización del aprendizaje y la toma de decisiones pedagógicas se sintetiza en la Figura 1.

Figura 1

Modelo conceptual de la relación entre la inteligencia artificial, la personalización del aprendizaje y la toma de decisiones pedagógicas.



Nota. Elaboración propia a partir de Chen et al. (2020), Khosravi et al. (2022), UNESCO (2023), Crompton y Burke (2023) y Bond et al. (2024).

METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo, con alcance explicativo y un diseño experimental pretest-posttest con grupo control y grupo experimental. Se comparó una metodología tradicional de enseñanza con una estrategia educativa apoyada por herramientas de inteligencia artificial, con el propósito de analizar su impacto en la personalización del aprendizaje y en la toma de decisiones pedagógicas. La comparación consideró el desempeño académico, la participación, la interacción con recursos digitales y los indicadores generados durante el proceso formativo.

El estudio se llevó a cabo en la Escuela Superior Politécnica de Chimborazo, Ecuador, con estudiantes de primer nivel de la carrera de Administración de Empresas. La muestra estuvo conformada por 80 estudiantes seleccionados mediante muestreo no probabilístico por conveniencia, de acuerdo con su disponibilidad y el cumplimiento de los criterios de inclusión establecidos. Una vez incorporados al

estudio, los participantes fueron asignados aleatoriamente al grupo control o al grupo experimental mediante un procedimiento de sorteo basado en denominaciones numéricas. Cada estudiante recibió una denominación numérica y, mediante el sorteo, se determinó su pertenencia a uno de los dos grupos, hasta conformar 40 participantes en cada condición. Este procedimiento buscó reducir el sesgo de selección en la asignación a las condiciones experimentales.

El grupo control, integrado por 40 estudiantes, trabajó mediante una metodología tradicional, mientras que el grupo experimental, también conformado por 40 estudiantes, participó en una intervención educativa apoyada por herramientas de inteligencia artificial. La intervención tuvo una duración de dos semanas, con una intensidad de ocho horas académicas semanales. Como criterios de inclusión se consideraron matrícula activa, asistencia regular, acceso a dispositivos digitales con conexión a Internet y aceptación voluntaria mediante consentimiento informado. La variable independiente correspondió a la metodología de enseñanza, diferenciada entre metodología tradicional y metodología apoyada por inteligencia artificial. Las variables dependientes fueron el desempeño académico, la participación académica, la interacción con recursos digitales, el tiempo de permanencia en la plataforma virtual y la percepción del proceso de aprendizaje.

Para fortalecer la validez interna del estudio, antes de la intervención se aplicó una evaluación diagnóstica a ambos grupos con el propósito de establecer su nivel inicial de conocimientos. Los resultados iniciales mostraron valores próximos entre el grupo control y el grupo experimental, lo que permitió disponer de una línea base para valorar los cambios posteriores a la intervención. Ambos grupos trabajaron durante el mismo periodo, con una carga académica equivalente y sobre los mismos contenidos de aprendizaje, utilizando instrumentos de evaluación comunes. La asignación aleatoria posterior a la selección de la muestra buscó disminuir la influencia de diferencias individuales preexistentes. No obstante, debido a que la selección inicial de los participantes fue no probabilística por conveniencia, no puede descartarse completamente la influencia de variables no controladas; por ello, los resultados deben interpretarse dentro del contexto y población estudiados.

La intervención del grupo experimental se desarrolló durante dos semanas, con una intensidad de ocho horas académicas semanales, y se estructuró mediante actividades orientadas al aprendizaje activo, la interacción con recursos digitales, la evaluación formativa y el seguimiento del progreso académico. Su diseño pedagógico integró principalmente principios cognitivistas y conectivistas, considerando tanto el procesamiento y organización de la información por parte del estudiante como la utilización de entornos tecnológicos para acceder, relacionar y aplicar conocimientos mediante diferentes recursos digitales.

La intervención integró distintas herramientas digitales y recursos de inteligencia artificial con funciones específicas dentro del proceso de aprendizaje. Google Classroom se utilizó para organizar los contenidos y facilitar el acceso a las actividades, mientras que Quizizz permitió realizar evaluaciones formativas, ofrecer retroalimentación inmediata y registrar indicadores de participación y desempeño. También se emplearon Leonardo IA, Labster, Runway ML y Wolfram Alpha como recursos interactivos para apoyar la exploración y comprensión de los contenidos. Los asistentes virtuales y las herramientas de IA generativa sirvieron como apoyo para resolver dudas, ampliar explicaciones y profundizar en los temas trabajados. Por su parte, el panel desarrollado con Google Colab y Visual Studio Code fue utilizado únicamente por el docente para revisar y organizar los indicadores académicos y de interacción generados durante la intervención; los estudiantes no tuvieron acceso directo a esta herramienta. En conjunto, estos recursos complementaron el trabajo docente y facilitaron el seguimiento de los estudiantes, sin sustituir la orientación pedagógica ni la responsabilidad del profesor.

Como instrumento de evaluación de conocimientos se utilizó un cuestionario estructurado de 20 ítems de opción múltiple, que incluyó contenidos relacionados con constructivismo, conectivismo, integración pedagógica de la tecnología mediante el modelo TPACK, niveles de incorporación tecnológica del modelo SAMR, aprendizaje social, chatbots educativos y mediación pedagógica con inteligencia

artificial. Su aplicación permitió obtener información sobre el aprendizaje alcanzado y complementar los indicadores registrados durante la intervención.

Paralelamente, los datos académicos y de interacción obtenidos durante el proceso fueron organizados para su posterior análisis. Google Colab se utilizó como entorno computacional para el procesamiento de la información y la implementación de los modelos de aprendizaje automático considerados en el estudio —regresión logística, árbol de decisión y redes neuronales artificiales—. De esta manera, el componente de inteligencia artificial comprendió tanto recursos utilizados durante el proceso educativo como técnicas analíticas aplicadas posteriormente para reconocer patrones asociados con el aprendizaje y apoyar la toma de decisiones pedagógicas.

Para el análisis predictivo se tomó como variable objetivo el rendimiento final de los estudiantes. A partir de esta variable, el modelo buscó diferenciar niveles de desempeño académico mediante una salida binaria. Como variables predictoras se utilizaron los principales indicadores académicos y de interacción registrados durante el proceso, entre ellos la calificación de la evaluación diagnóstica, las calificaciones obtenidas durante la intervención, la frecuencia de acceso a la plataforma, el tiempo promedio de estudio, el número de actividades completadas y la participación en recursos digitales. Para el entrenamiento de los modelos, la base de datos se dividió aleatoriamente en dos conjuntos: 80 % de los registros se destinó al entrenamiento y el 20 % restante a la prueba, con el fin de comprobar su desempeño con datos que no habían sido utilizados durante el ajuste.

La red neuronal se desarrolló en Python mediante TensorFlow y Keras. Se utilizó una arquitectura secuencial formada por dos capas ocultas de 16 y 8 neuronas, ambas con función de activación ReLU, y una capa de salida con una neurona y activación sigmoide para realizar la clasificación binaria del rendimiento académico. El entrenamiento se llevó a cabo durante 100 épocas, con lotes de 10 registros, utilizando el optimizador Adam y la función de pérdida de entropía cruzada binaria. Además, se destinó el 20 % de los datos de entrenamiento a la validación interna del modelo, lo que permitió observar su comportamiento durante el proceso de ajuste. Debido al tamaño de la muestra, los resultados predictivos se interpretaron con cautela, considerando la posibilidad de sobreajuste como una de las limitaciones del análisis.

El docente mantuvo la responsabilidad pedagógica durante toda la intervención. Su función comprendió la organización de las actividades, la orientación de los estudiantes, el seguimiento del desarrollo de las tareas, la interpretación de los indicadores obtenidos y la provisión de retroalimentación. Para este seguimiento utilizó el panel desarrollado con apoyo de Google Colab y Visual Studio Code, al cual los estudiantes no tuvieron acceso directo. El panel permitió organizar y visualizar información relacionada con el desempeño, la participación y la interacción registrada durante la intervención. En consecuencia, las herramientas de inteligencia artificial no realizaron decisiones académicas de manera autónoma, sino que proporcionaron información complementaria para apoyar el acompañamiento y la retroalimentación educativa.

La recolección de datos se realizó mediante evaluaciones académicas, registros de actividad digital y una encuesta estructurada. El desempeño académico fue medido mediante una evaluación diagnóstica inicial y una evaluación final, ambas calificadas sobre diez puntos. La participación, el uso de recursos y el tiempo de interacción fueron obtenidos a partir de los registros generados por las plataformas digitales. Además, se aplicó una encuesta de veinte preguntas orientada a valorar aspectos relacionados con inteligencia artificial aplicada a la docencia, aprendizaje constructivista, conectivismo, modelo TPACK, modelo SAMR, aprendizaje social, chatbots educativos y mediación pedagógica con IA.

El procedimiento se desarrolló en cuatro fases. En la primera fase se aplicó una evaluación diagnóstica para establecer el nivel inicial de conocimientos de ambos grupos. En la segunda fase se ejecutó la intervención educativa. El grupo control trabajó mediante clases magistrales, actividades convencionales, recursos impresos y evaluaciones tradicionales. El grupo experimental utilizó herramientas

digitales e inteligencia artificial, entre ellas Google Classroom, Quizizz con analítica, simuladores y recursos interactivos como Leonardo IA, Labster, Runway ML y Wolfram Alpha, asistentes virtuales y recursos de IA generativa. El seguimiento de los indicadores se realizó mediante un panel desarrollado con Google Colab y Visual Studio Code, utilizado exclusivamente por el docente.

En la tercera fase se recopilaron los resultados de las evaluaciones, los registros de actividad y las respuestas de la encuesta aplicada a los estudiantes. En la cuarta fase se procesó la información obtenida con el fin de comparar los resultados entre grupos, identificar patrones de aprendizaje y valorar la contribución de la inteligencia artificial en la toma de decisiones pedagógicas.

Los datos fueron organizados en Microsoft Excel y procesados mediante Google Colab y RStudio. Se aplicó estadística descriptiva mediante medias, frecuencias y porcentajes. Para comparar el desempeño académico entre el grupo control y el grupo experimental se utilizó la prueba *t* de Welch para muestras independientes, con un nivel de significancia de $\alpha = 0,05$. También se calculó el tamaño del efecto mediante el coeficiente *d* de Cohen y se realizó un análisis de correlación para examinar la relación entre la interacción digital y el rendimiento académico. Como complemento al análisis estadístico, se utilizaron tres modelos de aprendizaje automático: regresión logística, árbol de decisión y redes neuronales artificiales. Su aplicación permitió comparar la capacidad de cada algoritmo para clasificar el rendimiento académico de los estudiantes a partir de los datos recogidos durante la intervención. El desempeño de los modelos se evaluó mediante las métricas de exactitud (*accuracy*), precisión (*precision*), sensibilidad (*recall*) y F1-score, con el propósito de contar con diferentes criterios para valorar la calidad de las predicciones obtenidas.

La investigación se desarrolló respetando los principios éticos aplicables a estudios con participantes humanos. Los estudiantes fueron informados sobre los objetivos y procedimientos del estudio, participaron de forma voluntaria y sus datos fueron anonimizados antes del procesamiento. La información fue utilizada exclusivamente con fines académicos y científicos, garantizando confidencialidad, privacidad y uso responsable de los datos educativos.

RESULTADOS

Los resultados del desempeño académico se presentan a partir de la comparación entre el grupo control, que trabajó con metodología tradicional, y el grupo experimental, que participó en una intervención apoyada por herramientas de inteligencia artificial. En la evaluación diagnóstica inicial, ambos grupos presentaron promedios similares: el grupo control obtuvo 6,5 puntos, mientras que el grupo experimental alcanzó 6,4 puntos. Luego de la intervención, el grupo control obtuvo un promedio final de 7,2 puntos, mientras que el grupo experimental alcanzó 8,3 puntos.

Tabla 1

Comparación del rendimiento académico entre el grupo control y el grupo experimental

Grupo	Promedio inicial	Promedio final	Mejora porcentual
Grupo control: metodología tradicional	6,5	7,2	10,7 %
Grupo experimental: metodología apoyada en IA	6,4	8,3	29,7 %

Nota. Elaboración propia con base en los resultados del estudio.

La diferencia entre los promedios finales fue de 1,1 puntos a favor del grupo experimental. La mejora porcentual registrada fue de 10,7 % en el grupo control y de 29,7 % en el grupo experimental. Estos resultados muestran un incremento mayor en el grupo que trabajó con herramientas de inteligencia artificial.

Para determinar la significancia estadística de la diferencia observada entre ambos grupos, se aplicó la prueba *t* de Welch para muestras independientes. Los resultados evidenciaron diferencias

estadísticamente significativas entre el grupo control y el grupo experimental, $t(74,73) = -11,29$, $p < 0,001$. El intervalo de confianza al 95 % para la diferencia de medias fue $[-1,29; -0,91]$. Además, el tamaño del efecto calculado mediante el coeficiente d de Cohen fue de 2,52, valor que corresponde a un efecto grande.

Además del rendimiento académico, se analizaron indicadores asociados con la participación, el desarrollo de actividades y el uso de recursos educativos. Estos indicadores permitieron observar diferencias entre el grupo control y el grupo experimental en relación con la interacción académica durante la intervención.

Tabla 2

Comparación de indicadores de interacción académica entre grupos

Indicador	Grupo control	Grupo experimental
Actividades desarrolladas	65 %	88 %
Uso de recursos educativos	60 %	92 %
Participación académica	70 %	90 %

Nota. Elaboración propia con base en los registros de actividad del estudio.

Los resultados muestran que el grupo experimental alcanzó porcentajes superiores en los tres indicadores analizados. En actividades desarrolladas, el grupo experimental obtuvo 88 %, frente al 65 % del grupo control. En el uso de recursos educativos, el grupo experimental alcanzó 92 %, mientras que el grupo control registró 60 %. En cuanto a la participación académica, el grupo experimental obtuvo 90 %, en comparación con el 70 % del grupo control.

Además de comparar los resultados entre ambos grupos, se examinó la relación entre la interacción digital y el rendimiento académico. Se encontró una correlación positiva ($r = 0,71$), lo que muestra que los estudiantes que interactuaron con mayor frecuencia con los recursos digitales también tendieron a obtener mejores resultados académicos. Este comportamiento permite observar una asociación entre el nivel de participación en las actividades digitales y el desempeño alcanzado durante la intervención, aunque no permite afirmar que una variable sea la causa directa de la otra.

El análisis predictivo se realizó mediante tres algoritmos de aprendizaje automático: regresión logística, árbol de decisión y redes neuronales artificiales. Los modelos se utilizaron para clasificar el rendimiento académico final a partir de los indicadores académicos y de interacción registrados durante el proceso formativo. Para comparar su desempeño se consideraron las métricas de exactitud, precisión, sensibilidad (*recall*) y F1-score, cuyos resultados se presentan en la Tabla 3.

Tabla 3

Métricas de desempeño de los modelos predictivos

Modelo	Exactitud	Precisión	Sensibilidad	F1-score
Regresión logística	82 %	80 %	79 %	79 %
Árbol de decisión	83 %	81 %	80 %	80 %
Redes neuronales	85 %	83 %	82 %	82 %

Nota. Elaboración propia con base en el procesamiento de los modelos predictivos.

El modelo de redes neuronales obtuvo el mejor desempeño general, con una exactitud del 85 %, una precisión del 83 %, un *recall* del 82 % y un *F1-score* del 82 %. El árbol de decisión alcanzó una exactitud del 83 %, mientras que la regresión logística obtuvo una exactitud del 82 %. Estos resultados

muestran que los tres modelos presentaron capacidad predictiva, aunque el modelo basado en redes neuronales obtuvo los valores más altos en todas las métricas evaluadas.

El análisis de las variables consideradas en el modelo permitió identificar los factores con mayor influencia en la predicción del desempeño académico y en la caracterización de perfiles de aprendizaje. Las variables con mayor peso fueron las evaluaciones previas y la participación académica, seguidas por el uso de recursos educativos y el tiempo dedicado al estudio.

Estos resultados permitieron organizar la información académica de los estudiantes en función de su nivel de desempeño, participación e interacción con los recursos educativos. A partir de estos indicadores, fue posible reconocer diferencias entre los estudiantes con mayor y menor nivel de avance, lo que aportó información útil para orientar procesos de seguimiento, retroalimentación y toma de decisiones pedagógicas durante la intervención educativa.

DISCUSIÓN

Los resultados evidencian que la incorporación de herramientas basadas en inteligencia artificial favorece la personalización del aprendizaje y fortalece la toma de decisiones pedagógicas en educación superior. El promedio final fue de 8,3 puntos en el grupo experimental y de 7,2 en el grupo control, con diferencias estadísticamente significativas ($p < 0,001$) y un tamaño del efecto elevado ($d = 2,52$). Este resultado podría estar relacionado con la forma en que se desarrolló la intervención, en la que se combinaron actividades interactivas, evaluación formativa, retroalimentación inmediata y seguimiento continuo del progreso de los estudiantes. Estas condiciones facilitaron una atención más cercana a las necesidades de aprendizaje y permitieron realizar ajustes durante el proceso. Sin embargo, el tamaño del efecto debe interpretarse con cautela, debido a que la intervención tuvo una duración de apenas dos semanas. En un periodo tan corto, factores como la novedad de las herramientas, el interés inicial de los estudiantes o una mayor motivación hacia el uso de recursos digitales también pudieron influir en los resultados.

Estos resultados coinciden con Chen et al. (2020), quienes señalan que la inteligencia artificial aplicada a la educación permite optimizar los procesos de enseñanza mediante el análisis de datos, la automatización de tareas académicas y la generación de modelos predictivos orientados a mejorar el desempeño estudiantil. De forma similar, Khosravi et al. (2022) sostienen que la analítica del aprendizaje puede contribuir a detectar dificultades de forma temprana y facilitar intervenciones pedagógicas oportunas. En el presente estudio, no obstante, resulta necesario considerar que la mejora observada no puede atribuirse únicamente al uso de inteligencia artificial. La intervención incluyó también recursos digitales, actividades interactivas, mecanismos de evaluación formativa y un seguimiento más frecuente por parte del docente. Por ello, los resultados parecen responder al efecto conjunto de estos elementos, más que a una sola herramienta tecnológica.

Las diferencias entre los indicadores de interacción también permiten comprender mejor el efecto de la intervención. El cambio más marcado se observó en el uso de recursos educativos, con un 92 % en el grupo experimental frente al 60 % del grupo control, lo que representa una diferencia de 32 puntos porcentuales. Este resultado es coherente con las características de la intervención, ya que los estudiantes del grupo experimental tuvieron un contacto más frecuente con plataformas, asistentes virtuales y otros recursos digitales. En las actividades desarrolladas, la diferencia fue de 23 puntos porcentuales, mientras que en la participación académica fue de 20 puntos. Esta última mostró una variación menor, probablemente porque la participación no depende únicamente de la disponibilidad de tecnología, sino también de aspectos como la motivación, la autonomía, los conocimientos previos y la disposición de cada estudiante para involucrarse en las actividades. Esto permite entender por qué los indicadores más

directamente relacionados con el uso de recursos digitales mostraron cambios más notorios que aquellos vinculados con conductas académicas más complejas.

El modelo predictivo basado en redes neuronales alcanzó una exactitud del 85 %, por encima del árbol de decisión y de la regresión logística. Este resultado evidencia que la información obtenida a partir del desempeño y de la interacción de los estudiantes puede ser útil para reconocer patrones y anticipar posibles dificultades. Sin embargo, una mayor exactitud del modelo no implica, por sí sola, una mejora del aprendizaje. Su valor pedagógico depende de la manera en que el docente interprete esa información y la utilice para orientar el seguimiento, la retroalimentación o la adaptación de las actividades. En este sentido, los resultados coinciden con Siemens y Baker (2012) y Baker e Inventado (2014), al considerar que la analítica del aprendizaje adquiere sentido cuando los datos se convierten en información útil para apoyar las decisiones docentes.

No obstante, el uso de IA en educación debe analizarse dentro de un marco pedagógico más amplio. Estas herramientas no garantizan por sí mismas mejores aprendizajes, sino que requieren objetivos claros, acompañamiento docente y un uso responsable de la información generada. En esta línea, la OECD (2019) y la UNESCO (2023) señalan la importancia de considerar principios de transparencia, equidad, privacidad y responsabilidad. Entre las principales limitaciones del estudio se encuentra su aplicación en una sola institución, con una muestra específica y durante un periodo reducido. La duración de dos semanas no permite determinar si las mejoras encontradas se mantendrían a mediano o largo plazo, ni descartar completamente la influencia de factores asociados con la novedad tecnológica. Por esta razón, sería conveniente que futuros estudios incorporen intervenciones más prolongadas, estudiantes de otras carreras y variables relacionadas con la motivación, la autonomía y la retención del aprendizaje.

CONCLUSIONES

La implementación de herramientas basadas en inteligencia artificial contribuye a la personalización del aprendizaje en educación superior, al permitir un seguimiento más preciso del desempeño académico, la participación estudiantil y la interacción con los recursos educativos. Los resultados respaldan la hipótesis planteada, debido a que el grupo experimental obtuvo un promedio final superior al grupo control, con diferencias estadísticamente significativas y un tamaño del efecto grande. Estos hallazgos muestran un efecto favorable de la intervención apoyada en IA sobre el proceso formativo, aunque deben interpretarse considerando la corta duración de la intervención y las características específicas de la muestra.

La inteligencia artificial fortalece la toma de decisiones pedagógicas al transformar los datos educativos en información útil para planificar, retroalimentar y ajustar las estrategias de enseñanza. Los indicadores de participación, uso de recursos y desempeño predictivo muestran que estas herramientas no solo inciden en la calificación final, sino también en la forma en que los estudiantes se involucran con el aprendizaje. En este sentido, el modelo basado en redes neuronales mostró capacidad para identificar tendencias de desempeño y aportar información complementaria para el seguimiento académico.

La IA debe asumirse como un recurso de apoyo al docente y no como sustituto de su criterio profesional. Su efectividad depende de una integración pedagógica adecuada, del acompañamiento del profesor y del uso responsable de los datos. Como limitación, el estudio se desarrolla en una sola institución y con una muestra específica, por lo que futuras investigaciones deberían ampliar la población, incluir otras carreras y analizar variables como motivación, autonomía, retención del aprendizaje y percepción estudiantil frente al uso de inteligencia artificial.

REFERENCIAS

- Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. En J. A. Larusson & B. White (Eds.), *Learning analytics: From research to practice* (pp. 61–75). Springer. https://doi.org/10.1007/978-1-4614-3305-7_4
- Bond, M., Khosravi, H., De Laat, M., Bergdahl, N., Negrea, V., Oxley, E., Pham, P., Chong, S. W., & Siemens, G. (2024). A meta systematic review of artificial intelligence in higher education: A call for increased ethics, collaboration, and rigour. *International Journal of Educational Technology in Higher Education*, 21, Article 4. <https://doi.org/10.1186/s41239-023-00436-z>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal of Educational Technology in Higher Education*, 20, Article 22. <https://doi.org/10.1186/s41239-023-00392-8>
- Hellas, A., Ithantola, P., Petersen, A., Ajanovski, V. V., Gutica, M., Hynninen, T., Knutas, A., Leinonen, J., Messom, C., & Liao, S. N. (2018). Predicting academic performance: A systematic literature review. En *Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education* (pp. 175–199). Association for Computing Machinery. <https://doi.org/10.1145/3293881.3295783>
- Khosravi, H., Buckingham Shum, S., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Gašević, D. (2022). Explainable artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 3, Article 100074. <https://doi.org/10.1016/j.caeai.2022.100074>
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson.
- OECD. (2019). *Artificial intelligence in society*. OECD Publishing. <https://doi.org/10.1787/eedfee77-en>
- Siemens, G., & Baker, R. S. J. d. (2012). Learning analytics and educational data mining: Towards communication and collaboration. En *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (pp. 252–254). Association for Computing Machinery. <https://doi.org/10.1145/2330601.2330661>
- UNESCO. (2023). *Guidance for generative AI in education and research*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000386693>
- Waheed, H., Hassan, S. U., Aljohani, N. R., Hardman, J., Alelyani, S., & Nawaz, R. (2020). Predicting academic performance of students from VLE big data using deep learning models. *Computers in Human Behavior*, 104, Article 106189. <https://doi.org/10.1016/j.chb.2019.106189>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education: Where are the educators? *International Journal of Educational Technology in Higher Education*, 16, Article 39. <https://doi.org/10.1186/s41239-019-0171-0>