CCM Correo Científico Médico
Centro Provincial de Información de Ciencias Médicas de Holguín

Artículo de original

Impacto de módulo de Inteligencia artificial en Moodle sobre retención y engagement en médicos de familia

The influence of an artificial intelligence module in Moodle on retention and engagement among family physicians

Carlos Lázaro Jiménez-Puerto [1 *]
Miguel Angel Amaró Garrido [2]
Jim Alex González Consuegra [3]
Eliecer González Valdéz [4]

[1] Universidad José Martí Pérez. Sancti Spíritus. Cuba.

[2] Universidad de Ciencias Médicas de Sancti Spíritus. Facultad de Ciencias Médicas Faustino Pérez Hernández. Policlínico Universitario Juana Naranjo León de Sancti Spíritus. Cuba.

[3] Universidad de Ciencias Médicas de Sancti Spíritus. Facultad de Ciencias Médicas Faustino Pérez Hernández. Dirección General de Salud de Fomento. Sancti Spíritus. Cuba.

[4] Universidad de Ciencias Médicas de Sancti Spíritus. Facultad de Ciencias Médicas Faustino Pérez Hernández. Hospital General Provincial Camilo Cienfuegos. Sancti Spíritus. Cuba.

[*]Autor para la correspondencia. Correo electrónico: carloslazaro1989@gmail.com

Recibido: 4 de noviembre 2025.
Aprobado: 29 de octubre 2026.
Editor: Yasnay Jorge Sainz.
Aprobado: Silvio Emilio Niño Escofet.

RESUMEN

Introducción: La educación virtual enfrenta altas tasas de abandono en la formación médica continua, debido a factores como la carga laboral y la limitada interacción docente-estudiante.

Objetivo: Evaluar el impacto de un módulo de inteligencia artificial en la plataforma Moodle sobre la retención y engagement de médicos de familia en el curso extracurricular Gestión de la Información.

Métodos: Se realizó un estudio cuasi-experimental con 30 médicos distribuidos en Grupo Control (GC, edición 2024, n=15) y Grupo Experimental (GE, edición 2025, n=15). Al GE se le implementó en Moodle un módulo de IA con tres componentes: un predictor de riesgo (algoritmo Random Forest), un sistema de alertas automatizadas y un chatbot para intervenciones. La retención se midió como culminación exitosa del curso y el engagement mediante un índice compuesto de métricas de actividad. Se utilizó regresión logística para la retención y un ANCOVA no paramétrico (prueba de Quade) para el engagement, controlando los valores basales.

Resultados: La retención fue mayor en el GE (86,7 %) frente al GC (60,0 %) (OR=6,00; p=0,016). El engagement también mostró diferencias significativas a favor del GE (p=0,022), con un tamaño del efecto grande (η^2=0,18), según los criterios de Cohen. El sistema generó 42 alertas y 67 intervenciones automatizadas, con una tasa de respuesta del 78,3 %.

Conclusiones: La integración del módulo de inteligencia artificial demostró ser una estrategia efectiva para incrementar la retención y el compromiso académico, lo que valida el uso de un modelo híbrido escalable para entornos de educación médica continua.

ABSTRACT

Introduction: Online education faces high dropout rates in continuing medical education due to factors such as heavy workloads and limited teacher-student interaction.

Objective: To evaluate the impact of an artificial intelligence module, on the Moodle platform, regarding retention and engagement among family physicians in the extracurricular course “Information Management.”

Methods: A quasi-experimental study was conducted with 30 physicians divided into a Control Group (CG, 2024 cohort, n=15) and an Experimental Group (EG, 2025 cohort, n=15). An AI module with three components was implemented on Moodle for the EG: a risk predictor (Random Forest algorithm), an automated alert system, and a chatbot for interventions. Retention was measured as successful completion of the course, and engagement was measured using a composite index of activity metrics. Logistic regression was used for retention, and a nonparametric ANCOVA (Quade’s test) was used for engagement, controlling for baseline values.

Results: Retention was higher in the EG (86.7%) than in the CG (60.0%) (OR=6.00; p=0.016). Engagement also showed significant differences in favor of the EG (p=0.022), with a large effect size (η^2=0.18), according to Cohen’s criteria. The system generated 42 alerts and 67 automated interventions, with a response rate of 78.3%.

Conclusions: The integration of the artificial intelligence module proved to be an effective strategy for increasing retention and academic engagement, validating the use of a scalable hybrid model for continuing medical education settings.

Keywords: artificial intelligence, continuous medical education, retention, academic engagement, Moodle

Palabras Clave: inteligencia artificial, educación médica continua, retención, compromiso académico, Moodle

Introducción

La educación superior transita de forma progresiva hacia una digitalización definitiva, donde los Entornos Virtuales de Aprendizaje (EVA) se han consolidado como pilares fundamentales. En este escenario, los Sistemas de Gestión del Aprendizaje (LMS, por sus siglas en inglés) de código abierto, entre los cuales Moodle destaca por su flexibilidad y adaptabilidad, han tenido amplia adopción a nivel global. No obstante, este crecimiento acelerado ha evidenciado un desafío estructural persistente: las elevadas tasas de abandono académico por profesionales en la modalidad virtual, un fenómeno multifactorial que conlleva serias repercusiones docentes, institucionales y personales.[1,2]

Dicha problemática adquiere una dimensión crítica en el ámbito de la formación continua para profesionales de la salud. En efecto, la educación virtual en este sector experimenta una notable expansión, impulsada por la necesidad de actualización permanente.[2,3] Sin embargo, en América Latina esta transición digital presenta mayores dificultades estructurales como la alta carga laboral, horarios irregulares y la limitada interacción docente-estudiante en el entorno digital. En conjunto, estos factores configuran un panorama adverso que agrava de manera sistemática el riesgo de abandono en cursos extracurriculares, lo que compromete el impacto formativo. [2,3,4]

Frente a este escenario, la integración de herramientas de Inteligencia Artificial (IA) en los EVA emerge como una alternativa prometedora.[5,6] La IA, mediante el Learning Analytics (LA), posee el potencial de transformar los datos de interacción de los participantes en conocimiento accionable, lo que permite tanto la identificación temprana de riesgos de abandono como la automatización de intervenciones de apoyo oportunas y personalizadas.[7,8] No obstante, en el panorama de la formación médica continua, la evidencia empírica rigurosa sobre el impacto causal de estas herramientas en la retención, entendida como la culminación exitosa del curso,

y en el compromiso académico o engagement, concebido como el nivel de participación activa, esfuerzo e involucramiento conductual del estudiante con el entorno de aprendizaje, resulta escasa en el contexto cubano.[6,9,10]

En el ámbito local, la Universidad "José Martí Pérez" de Sancti Spíritus promueve de forma decidida la implementación de la plataforma Moodle como soporte fundamental para la docencia de posgrado. Como parte de esta estrategia institucional, se desarrolló en esta, el curso extracurricular "Gestión de la Información", dirigido a médicos de familia. Pese a estos esfuerzos, los reportes administrativos internos y la observación sistemática del proceso indican que la deserción en este curso constituye un problema académico relevante, con directa asociación a las particulares condiciones laborales y formativas de este perfil profesional. El objetivo de esta investigación fue evaluar el impacto de un módulo de inteligencia artificial en la plataforma Moodle sobre la retención y engagement de médicos de familia en el curso extracurricular "Gestión de la Información".

Método

Se implementó un estudio con diseño cuasi-experimental, con un grupo de control no equivalente y un análisis de series temporales para el grupo experimental. Este diseño resultó ser robusto para evaluar el impacto de intervenciones en escenarios educativos naturales, donde la asignación aleatoria de participantes era inviable. Cabe destacar que, aunque los grupos no fueron asignados de forma aleatoria, la comparación de las características basales en ambos permitió verificar la equivalencia inicial.

La investigación se desarrolló en la Universidad Virtual de la Universidad "José Martí Pérez" de Sancti Spíritus, Cuba, con el curso extracurricular "Gestión de la Información". El estudio abarcó dos cohortes consecutivas del curso, correspondientes a ciclos académicos distintos. La fase de línea base se realizó con la cohorte del período septiembre 2024 a enero 2025, mientras que la fase de intervención se ejecutó con la cohorte del período febrero - julio 2025.

Población y muestra:

La población accesible del estudio estuvo constituida por los 37 médicos de familia inscritos en las dos ediciones consecutivas del curso extracurricular "Gestión de la Información" (18 en la edición 2024 y 19 en la edición 2025). La muestra final, seleccionada mediante un muestreo no probabilístico por conveniencia a partir de esta población, quedó constituida por 30 participantes (15 en cada grupo), luego de aplicar los criterios detallados a continuación:

Criterios de inclusión:

- Ser médico de familia en ejercicio activo.
- Estar inscrito en el curso "Gestión de la Información" en una de las dos ediciones del estudio.
- Acceso a la plataforma Moodle durante el desarrollo del curso.

Los criterios de exclusión aplicados fueron:

- No pertenecer a la especialidad de Medicina Familiar.
- No completar el proceso de consentimiento informado.
- No presentar ningún registro de actividad en los logs de Moodle durante la primera semana del curso.

La selección de la muestra a través del muestreo no probabilístico por conveniencia se fundamentó en la factibilidad de acceder a la cohorte completa de médicos de familia inscritos en las dos ediciones consecutivas del curso, lo que constituía el universo natural del estudio. Dada la homogeneidad del perfil profesional de los participantes, todos médicos de familia en ejercicio activo, y el propósito evaluativo del estudio en un contexto real, este enfoque se consideró el más viable. Para fortalecer el diseño, se implementaron controles metodológicos rigurosos, como la verificación de la equivalencia basal entre los grupos, con el propósito de asegurar la comparabilidad y mitigar las limitaciones inherentes a esta técnica de muestreo.

Caracterización de la muestra y variables basales

Para caracterizar la muestra y verificar la equivalencia basal entre los grupos, se recogieron las siguientes variables mediante un formulario de caracterización inicial aplicado al momento de la inscripción en el curso:

- Variables sociodemográficas: Edad (en años cumplidos) y sexo (masculino/femenino).
- Variables profesionales y contextuales: Años de experiencia profesional como médico de familia y contexto de práctica profesional (urbano/rural).

La conformación final de los grupos quedó estructurada de la siguiente manera:

- Grupo Experimental (GE): 15 médicos de familia de la edición 2025 del curso donde se integró el módulo de IA.
- Grupo de Control (GC): 15 médicos de familia de la edición 2024 del curso que utilizaron Moodle en su configuración estándar, sin herramientas de IA.

La asignación de la cohorte 2024 al Grupo de Control (GC) y la cohorte 2025 al Grupo Experimental (GE) se consideró la más apropiada desde el punto de vista metodológico, pues imposibilitó la contaminación o efecto de difusión entre participantes, lo cual aseguró que el GC no tuviera conocimiento de la intervención aplicada al GE. Si bien este diseño de cohortes consecutivas introduce el riesgo potencial de factores de confusión temporales, se consideró la opción más robusta para garantizar la validez interna del estudio en un contexto real donde la asignación aleatoria y simultánea no era viable.

Herramientas y materiales utilizados:

1. **Plataforma base:** Se empleó la versión 4.4 de Moodle, alojada en servidores institucionales de la Universidad Virtual.
2. **Intervención (Módulo de IA):** Se implementó el plugin Learning Analytics Dashboard & Predictor, desarrollado *ad hoc* por el grupo de investigación. El módulo fue desarrollado en Python 3.9, con la utilización de librerías scikit-learn (v1.2) para el algoritmo Random Forest

y NLTK (v3.8) para el componente de Procesamiento de Lenguaje Natural del chatbot. Este módulo integró tres componentes principales:

a) **Motor de predictor de riesgo:** Se implementó un algoritmo Random Forest entrenado con un conjunto de datos históricos anonimizados (n=285 registros de participantes de cohortes anteriores) de cursos extracurriculares para profesionales de la salud. El rendimiento del modelo fue evaluado mediante validación cruzada de 5 pliegues, con la obtención de un área bajo la curva ROC (AUC-ROC) de 0,84 (IC 95 %: 0,79-0,89) en la predicción del abandono, lo que indica una capacidad discriminatoria buena. El umbral de riesgo del 70 % para la generación de alertas se estableció mediante un análisis de la curva ROC del modelo, en busca de optimizar el balance entre la sensibilidad (capacidad de detectar verdaderos abandonos) y la especificidad (evitar falsas alarmas).

   Este punto de corte mostró una sensibilidad del 82 % y una especificidad del 75 % en los datos de validación, considerado óptimo para el ambiente educativo donde es preferible priorizar la identificación temprana incluso a costa de un moderado número de falsos positivos. El rendimiento del predictor en el entorno real de implementación fue monitoreado mediante el cálculo de su valor predictivo positivo. El algoritmo analizó en tiempo real 15 variables predictoras, seleccionadas por su relevancia teórica en la literatura de learning analytics y su viabilidad de captura desde los logs de Moodle.
b) **Sistema de alertas automatizadas:** Generaba notificaciones al tutor del curso a través de un *dashboard* visual y correo electrónico si un participante era clasificado con un riesgo de abandono superior al 70 %. El *dashboard* mostraba un semáforo por participante (verde, amarillo, rojo) y un listado de los estudiantes en riesgo con las variables predictoras que más contribuían a dicha clasificación.

c) **Bot de intervención (Chatbot):** Se desarrolló un sistema conversacional basado en Procesamiento de Lenguaje Natural (NLP) con un protocolo de intervención predefinido. El chatbot se activaba de forma automática tras 72 horas de inactividad de un estudiante

clasificado como de riesgo o al detectar un bajo desempeño en una actividad evaluativa. Las intervenciones incluían: a) mensajes de recordatorio sobre actividades pendientes; b) mensajes de apoyo y refuerzo motivacional; c) sugerencias automatizadas de recursos bibliográficos específicos basados en la actividad del usuario; y d) la opción de derivar la conversación a un tutor humano si el participante así lo solicitaba.

Para evaluar el funcionamiento y la eficacia operativa del módulo en el entorno real, se registraron métricas de proceso que incluían: el número total de alertas generadas, el número de participantes únicos con alertas, el valor predictivo positivo de las alertas, el número y tipo de intervenciones automatizadas del chatbot, su tasa de respuesta global y el número de intervenciones humanas del tutor derivadas del sistema.

De manera complementaria, se estableció un protocolo de intervención humana del tutor, disparado por alertas de alto riesgo (≥90 %) o por la persistencia de una alerta de riesgo durante más de una semana. Esta intervención consistía en un contacto personalizado vía mensajería interna de Moodle o correo electrónico, que seguía una plantilla basada en principios de entrevista motivacional. El protocolo incluía: 1) Expresión de preocupación y apoyo; 2) Mención específica de la actividad pendiente o el indicador de riesgo detectado; 3) Ofrecimiento explícito de ayuda flexible y adaptada a las demandas laborales del participante; y 4) Una pregunta abierta para fomentar la respuesta y la autorreflexión del médico.

3. Variables e Instrumentos de medición

- Variable: Retención de médicos de familia:
  - ✓ Definición operacional: Variable dicotómica operacionalizada como "culminación exitosa del curso", definida como la entrega y aprobación del proyecto final del curso (1 = sí, 0 = no).
  - ✓ Instrumento de medición: Obtenida de forma directa de los registros administrativos de Moodle.

- Variable: Engagement (Compromiso académico).[6,10]
  - ✓ Definición operacional: Se operacionalizó mediante un índice compuesto normalizado (puntuación Z) que agregaba cuatro métricas conductuales extraídas de forma automática de los logs de Moodle, adaptadas al perfil del médico de familia: I) Número total de accesos a la plataforma, II) Tasa de finalización de actividades obligatorias, III) Número de intervenciones en foros de discusión clínica, IV) Tiempo promedio de acceso semanal en horarios no laborales (después de las 6:00 pm y fines de semana).
  - ✓ Instrumento de medición: Extracción automatizada y procesamiento de los logs de actividad de Moodle.
  - ✓ Validez y confiabilidad: La validez de constructo de este índice se sustentó en su alineación con marcos teóricos que definen el engagement a través de dimensiones conductuales de esfuerzo, persistencia y participación. Para evaluar su consistencia interna en el ámbito de este estudio, se calculó post-hoc el alfa de Cronbach para la muestra completa (N=30), con el alcance de un valor de 0,72, lo que se considera una fiabilidad aceptable para un instrumento de investigación en ciencias sociales y avala su uso como una medida compuesta coherente.
  - ✓ Consideración metodológica adicional: Los valores basales de engagement para el ANCOVA se calcularon a través de las métricas de actividad correspondientes a la primera semana calendario del curso para ambos grupos, lo que garantizó que la medición inicial se realizara en condiciones equivalentes antes de cualquier intervención diferencial entre GC y GE.

Métodos y procedimientos: La investigación se ejecutó mediante un protocolo secuencial estructurado en cuatro fases, además incluyen una capacitación estandarizada del tutor con criterios de competencia definidos:

1. Fase de línea base: Recolección exhaustiva de datos de la edición 2024 del curso (GC) sin implementación de intervención alguna. Los datos se almacenaron para su posterior análisis comparativo.

2. Fase de implementación: Instalación y configuración del módulo de IA en el espacio del curso para la edición 2025 (GE), acompañada de una capacitación de tres horas al tutor del curso sobre la interpretación de alertas, navegación del dashboard y el protocolo de intervención humana. Esta capacitación se realizó previo al inicio de la edición 2025 del curso. La capacitación incluyó un ejercicio de simulación con datos de prueba, y se consideró que el tutor había alcanzado la competencia necesaria al realizar bien el 100 % de las intervenciones simuladas en el escenario propuesto.
3. Fase de intervención y recolección: Operación continua del módulo de IA durante la edición 2025 del curso, con exportación semanal sistemática de datos de logs y actividad.
4. Fase de análisis de datos: El análisis de los datos del GC se realizó tras la finalización de su cohorte (enero 2025), previo al inicio de la intervención con el GE (febrero 2025). Una vez concluida la fase de intervención con el GE, se procedió al procesamiento estadístico integral y comparativo de la información recolectada de ambas ediciones del curso.

Valoración de expertos: El módulo de IA Learning Analytics Dashboard & Predictor, junto con el protocolo de investigación y los instrumentos de medición, fueron sometidos a la valoración de cinco especialistas con competencias en Informática Educativa, Educación Médica y Metodología de la Investigación. Los expertos emitieron un criterio favorable unánime respecto a la validez de contenido, pertinencia contextual para la educación médica continua y viabilidad operacional del diseño propuesto.

Análisis estadístico:

Procesamiento de datos: Previo al análisis estadístico inferencial, los datos brutos extraídos de los *logs* de Moodle fueron sometidos a un proceso de limpieza y preprocesamiento. Los valores atípicos en las métricas de tiempo de conexión y número de accesos fueron identificados a través del rango intercuartílico (RIQ) y winsorizados al percentil 95 para mitigar su influencia desproporcionada en los análisis. Asimismo, las observaciones correspondientes a participantes

con más del 50 % de métricas faltantes fueron excluidas del cálculo del índice de *engagement,* para garantizar la robustez de la medida.

Análisis estadístico inferencial: El procesamiento estadístico se realizó con el software R (versión 4.3.1). La elección de pruebas no paramétricas se basó en la comprobación de la no normalidad en la distribución del índice de engagement mediante la prueba de Shapiro-Wilk ($W = 0,87$, $p < 0,010$ para el GC; $W = 0,89$, $p < 0,020$ para el GE). Debido al tamaño muestral limitado y a la naturaleza no paramétrica de la mayoría de las métricas de *engagement,* verificada mediante la prueba de Shapiro-Wilk, se implementaron las siguientes estrategias analíticas:

- **Análisis descriptivo:** Cálculo de medias, desviaciones estándar, medianas, rangos intercuartílicos y frecuencias absolutas y relativas.
- **Análisis inferencial:**

✓ **Verificación de equivalencia basal:** Prueba U de Mann-Whitney para variables continuas no paramétricas y prueba exacta de Fisher para variables categóricas.

✓ **Evaluación de la retención:** Modelo de regresión logística binomial.

✓ **Análisis del** *engagement:* Para comparar los grupos con el control de las diferencias basales, se utilizó la **Prueba de Alineación y Rango de Covarianza (ANCOVA no paramétrico de Quade),** con la utilización de la puntuación post-intervención del índice de *engagement* como variable de resultado y la puntuación basal como covariable. Esta prueba mostró diferencias estadísticas relevantes entre los grupos ($F (1, 27) = 5,92$, $p = 0,022$), con un tamaño del efecto grande ($\eta^2 = 0,18$) según los criterios de Cohen. Para evaluar la robustez de los hallazgos principales, se realizó un análisis de sensibilidad post-hoc mediante la exclusión de los participantes identificados como valores atípicos en las métricas de engagement.

✓ **Análisis exploratorio de intervenciones tutoriales: De forma complementaria y con un carácter exploratorio, se evaluó la asociación entre las intervenciones tutoriales humanas (derivadas de las alertas del sistema) y la variable de retención, mediante un modelo de regresión logística binomial que incluía esta variable como predictor.**

- ✓ **Análisis de series temporales:** Para el índice de *engagement* semanal del grupo experimental, se especificó un **modelo ARIMA (1,1,1).** La selección de estos parámetros (p=1, d=1, q=1) se fundamentó en la minimización del Criterio de Información de Akaike (AIC), [11] y en el examen de las funciones de autocorrelación (ACF) y autocorrelación parcial (PACF) de la serie diferenciada, lo que confirmó su estacionariedad antes del modelado. El modelo mostró un coeficiente significativo (coeficiente = 0,38, EE = 0,12, t = 3,17, p = 0,002), lo cual explica una reducción significativa en la varianza residual del modelo.
- El nivel de significancia estadística se estableció en $\alpha = 0,05$ para todas las pruebas.

La investigación se rigió por los principios éticos establecidos en la Declaración de Helsinki.[12] Se obtuvo consentimiento informado por escrito de todos los médicos participantes y del tutor del curso. Se garantizó una estricta la confidencialidad y anonimización de los datos personales y profesionales, con establecimiento de protocolos para su uso exclusivo en los fines de la investigación. El protocolo recibió aprobación formal del Comité de Ética de la Universidad "José Martí Pérez".

Resultados

El análisis de equivalencia basal mostró homogeneidad entre los grupos en todas las variables sociodemográficas y profesionales evaluadas. La prueba U de Mann-Whitney no reveló diferencias significativas en la distribución de edades (p = 0,452) ni en los años de experiencia profesional (p = 0,587). De manera consistente, la prueba exacta de Fisher confirmó la similar distribución por sexo entre ambos grupos (p = 1,000), tal como se detalla en la Tabla I.

Tabla I. Características basales de los médicos de familia participantes en el estudio.

Variable	Grupo Experimental (n=15)	Grupo de Control (n=15)	Valor p
Edad (años), Mediana [RIQ]	34 [31-39]	36 [32-41]	0,452*
Sexo (% mujeres)	60,0 %	53,3 %	1,000**
Años de Experiencia, Mediana	8 [5-12]	9 [6-13]	0,587*

[RIQ]			
Procedencia (% urbana)	73,3 %	66,7 %	0,695**

Fuente: Registros institucionales de la Universidad Virtual.

*Nota: RIQ = Rango Intercuartílico. *Prueba U de Mann-Whitney. *Prueba Exacta de Fisher.

El análisis primario de retención, definida como la culminación exitosa del curso, evidenció un efecto diferenciado entre los grupos. Mientras el GC presentó una tasa de retención del 60,0 % (9 de 15 participantes) en la cohorte 2024, el GE alcanzó una tasa del 86,7 % (13 de 15 participantes) en la cohorte 2025, lo que representó un incremento absoluto de los 26,7 puntos porcentuales en el indicador principal.

En la tabla II se muestran los parámetros del modelo de regresión logística para la retención

Tabla II. Parámetros del modelo de regresión logística para la retención.

Factor	Coeficiente β	Error Estándar	Odds Ratio	IC 95 % (OR)	Valor p
Intercepto	-0,69	0,62	0,50	0,15 – 1,68	0,265
Grupo (GE)	0,18	0,74	1,20	0,27 – 5,33	0,812
Fase (Post)	0,41	0,77	1,50	0,34 – 6,65	0,596
Interacción Grupo*Fase	1,79	0,74	6,00	1,38 – 26,10	0,016

Fuente: Elaboración propia basada en registros administrativos de Moodle.

.El modelo de regresión logística binomial confirmó la significación estadística del efecto de interacción Grupo*Fase ($\chi^2 = 5,82$, $p = 0,016$). Los parámetros estimados del modelo indicaron que los médicos del GE tuvieron 6 veces mayor probabilidad (OR=6,00) de completar con éxito el curso en comparación con sus pares del GC, después de controlar por los efectos principales de grupo y fase.

La tabla III muestra la comparación la comparación del índice de compromiso académico (engagament) entre los grupos de estudiantes después de la intervención.

Tabla III. Comparación del índice de engagement *e*ntre grupos post-intervención

Grupo	n	Mediana	Rango Intercuartílico	Rango Mín-Máx
Experimental	15	0,52	0,41 – 0,61	0,32 – 0,78
Control	15	0,29	0,18 – 0,37	0,12 – 0,55

Fuente: Elaboración propia a partir de logs de actividad de Moodle.

Nota: Resultado de la Prueba de Alineación y Rango de Covarianza (ANCOVA no paramétrico de Quade): F (1,27) =5,92, p=0,022, η^2=0,18.

El índice de engagement, construido a partir de cuatro métricas conductuales normalizadas, mostró una distribución no paramétrica en ambos grupos (Shapiro-Wilk: GC - W = 0,87, p < 0,010; GE - W = 0,89, p < 0,020). El análisis descriptivo reveló que el GE presentó valores superiores en todas las componentes del índice, de manera particular en el tiempo de acceso en horarios no laborales (mediana: 42 vs 18 minutos/semana) y en la tasa de finalización de actividades obligatorias (93 % vs 67 %).

La aplicación de la Prueba de Alineación y Rango de Covarianza (ANCOVA no paramétrico de Quade), con el control de los valores basales de engagement, mostró diferencias estadísticas significativas entre los grupos (F (1, 27) = 5,92, p = 0,022). El tamaño del efecto calculado (η^2 = 0,18) se considera grande según los criterios convencionales para estudios en ciencias sociales.

En la tabla IV se observa la trayectoria diferenciada entre grupos del índice de engagement durante el curso.

Tabla IV. Evolución semanal del índice de engagement normalizado durante las 12 semanas del curso.

Semana	Grupo Experimental (GE)	Grupo Control (GC)	Diferencia (GE - GC)
1	0,35	0,32	+0,03
2	0,38	0,34	+0,04

3	0,45	0,31	+0,14
4	0,52	0,29	+0,23
5	0,58	0,33	+0,25
6	0,61	0,30	+0,31
7	0,59	0,28	+0,31
8	0,63	0,32	+0,31
9	0,65	0,31	+0,34
10	0,68	0,29	+0,39
11	0,66	0,27	+0,39
12	0,70	0,26	+0,44

Fuente: Elaboración propia basada en el análisis longitudinal de logs de Moodle.

El análisis de series temporales del índice de engagement semanal en el GE mediante el modelo ARIMA (1,1,1) identificó un quiebre estructural significativo post-intervención (coeficiente = 0,38, EE = 0,12, t = 3,17, p = 0,002). Se observa que el GE mantuvo una tendencia sostenida de crecimiento a partir de la tercera semana, mientras el GC exhibió un patrón fluctuante sin tendencia definida.

El examen de los residuos del modelo ARIMA mostró ausencia de autocorrelación (Ljung-Box Q = 8,45, p = 0,390) y distribución normal (Shapiro-Wilk: W = 0,96, p = 0,420), lo cual validó los supuestos del modelo.

La tabla V presenta el registro de la actividad del sistema de inteligencia artificial durante el curso.

Tabla V. Métricas de funcionamiento del sistema de IA durante el período de intervención.

Componente del Sistema	Métrica	Valor
Predictor de Riesgo	Alertas generadas (umbral ≥70 %)	42

	Participantes únicos con alertas	9
	Valor predictivo positivo	76,2 %
Chatbot	Intervenciones automatizadas totales	67
	Tasa global de respuesta	78,3 %
	Tipos de intervención (recordatorios/apoyo/recursos/derivaciones)	38/16/9/4
Intervención Tutorial	Intervenciones humanas basadas en alertas	11
	Tiempo promedio respuesta tutor (horas)	4,8

Fuente: Registros del módulo Learning Analytics Dashboard & Predictor.

Durante las 12 semanas de intervención, el módulo de IA procesó 5,340 registros de actividad y generó 42 alertas de riesgo correspondientes a 9 participantes distintos del GE. La distribución temporal de las alertas mostró una concentración en las semanas 3-5 (62 % del total), período que a su vez registró la mayor carga académica del curso.

El sistema de chatbot ejecutó 67 intervenciones automatizadas, distribuidas en: 38 recordatorios de actividades (56,7 %), 16 mensajes de apoyo motivacional (23,9 %), nueve recomendaciones de recursos (13,4 %) y cuatro derivaciones al tutor (6,0 %). La tasa de respuesta global por parte de los participantes fue del 78,3 %, con variación según el tipo de intervención (máxima para recordatorios: 84,2 %; mínima para recomendaciones: 66,7 %).

El tutor del curso realizó 11 intervenciones complementarias basadas en el protocolo establecido para alertas de alto riesgo. El análisis complementario de regresión mostró que, si bien las intervenciones tutoriales presentaron una asociación positiva con la retención (OR = 3,1, IC 95 %: 0,9-10,5), el efecto principal del sistema automatizado se mantuvo con una estadística notable en los modelos que incluían esta variable.

Discusión

Los hallazgos de esta investigación evidencian que la integración de un módulo de inteligencia artificial en Moodle ejerce un impacto significativo en la retención y el engagement de médicos de familia en programas de posgrado. En primer lugar, se observó que los participantes del grupo experimental tuvieron una probabilidad seis veces mayor de culminar con éxito el curso, un efecto que supera lo reportado por Guimarães y Guimarães,[13] en sus estudios sobre implementaciones de IA en Moodle, donde las mejoras en retención fueron moderadas. Esta diferencia marcada podría explicarse por la naturaleza de la población en estudio, dado que, como señalan Cervantes et al.,[2] y Aguilera et al.,[3] los profesionales médicos requieren soluciones personalizadas que se adapten a sus demandas laborales específicas y a las restrictivas condiciones de tiempo.

El análisis del funcionamiento del sistema permite identificar que la efectividad de la intervención se sustenta en la complementariedad entre la predicción temprana de riesgo y las intervenciones automatizadas. En este marco, el chatbot, al proporcionar recordatorios y apoyo adaptativo, funcionó como un sistema de andamiaje continuo, lo que coincide con lo documentado por Bravo et al.,[14] respecto al papel de los asistentes inteligentes en la potenciación de plataformas educativas. Resulta ilustrativo que, como también observó Mukkala,[15] en entornos educativos transformativos, la integración de Tecnologías de la Información y la Comunicación (TIC) con inteligencia artificial produce efectos sinérgicos en el proceso de aprendizaje.

En lo que respecta al engagement, el incremento sustancial y sostenido en el grupo experimental, en especial las métricas contextualizadas como el acceso en horarios no laborales, refleja una adaptación exitosa a las particularidades de los profesionales de la salud, tal como preconizan Mora et al.,[16] en sus trabajos sobre integración de TIC en formación médica. Este hallazgo amplía lo propuesto por Prada y Beltrán,[8] en cuanto al aprendizaje adaptativo, lo cual demuestra la aplicabilidad concreta de este en escenarios de educación continua. La tendencia alcista observada en el análisis temporal, coincide con las observaciones

de Ramirez y Coicue,[17] sobre la educación disruptiva, donde la adopción progresiva de tecnologías supera la mera novedad inicial.

Sin embargo, un hallazgo crucial que emerge del análisis es el papel indispensable del componente humano en el ecosistema de IA. Aunque el sistema operaba de manera automatizada, las intervenciones tutoriales basadas en alertas demostraron ser determinantes en casos de alto riesgo, lo que corrobora las advertencias de Hernández,[18] sobre la necesaria adecuación funcional de la IA en el proceso de aprendizaje. Esta observación respalda con plenitud el modelo híbrido propuesto por Cabrales et al.,[9] para la gestión de posgrados médicos, donde la inteligencia artificial complementa, pero no sustituye la guía humana.

Es necesario contextualizar estos hallazgos con la consideración de las limitaciones del estudio. La muestra reducida, aunque justificable por el enfoque en una población especializada, limita la generalización estadística, una precaución que también señalaron Arellano et al.,[19] en sus estudios sobre implementación de IA en educación superior. La posibilidad de sesgos algorítmicos representa una preocupación ya identificada por Rajpurkar y Lungren,[20] en aplicaciones médicas de IA, de forma particular en modelos entrenados con poblaciones específicas. Además, la validez externa se encuentra restringida a panoramas similares al descrito, una limitación metodológica que Miralles,[21] también reconoce en sus investigaciones sobre innovación educativa con IA.[21,22]

A pesar de estas limitaciones, el estudio aporta evidencia valiosa para el campo de la educación médica continua. La implementación exitosa del modelo híbrido representa una contribución significativa al diseño de intervenciones educativas efectivas, en línea con lo planteado por Calderón et al.,[5] respecto al estado actual y futuro de la IA en entornos médicos. Los resultados obtenidos validan las perspectivas de Guimarães y Guimarães,[13] sobre el papel de la IA como herramienta de apoyo al aprendizaje en Moodle, al tiempo que amplían los marcos conceptuales de Ferrer y Díaz,[4] sobre teorías del aprendizaje para la superación profesional.

Por consiguiente, los autores de la presente investigación sugieren que las instituciones de educación médica consideren la integración progresiva de sistemas de inteligencia artificial bajo un modelo híbrido de acompañamiento, donde la escalabilidad de las intervenciones automatizadas se complemente con la guía oportuna del tutor para sostener el compromiso académico. De esta manera, es posible transitar hacia entornos virtuales más adaptativos y resilientes, capaces de responder de manera personalizada a las demandas específicas de los profesionales de la salud, incluso en contextos de alta carga laboral y recursos limitados. De cara al futuro, resulta esencial explorar el potencial de estas herramientas en el largo plazo, no solo para la retención, sino también para el fortalecimiento de las competencias clínicas y el desarrollo profesional continuo.

Conclusiones

La integración del módulo de inteligencia artificial en Moodle demostró ser una estrategia efectiva para incrementar la retención de médicos de familia en entornos de educación continua, al combinar la escalabilidad de las intervenciones automatizadas con la tutoría humana para generar un compromiso sostenido. Este modelo híbrido, validado de forma empírica en el contexto cubano, se erige como una alternativa viable para reducir el abandono en poblaciones profesionales con alta demanda laboral, lo que destaca el potencial transformador de la IA aplicada a la formación médica de posgrado en entornos de recursos limitados.

Referencias bibliográficas

1. Guale Vera ME, San Lucas Guerra MO, Ramírez Gutiérrez CV, García Hevia S. Implementación de herramientas de Inteligencia Artificial para fortalecer el proceso de enseñanza–aprendizaje en la docencia mediante un aula virtual. MQRInvestigar. 2025 [citado 05/08/2026];9(3):e996. Disponible en: https://www.investigarmqr.com/2025/index.php/mqr/article/view/996

2. Cervantes López MJ, Peña Maldonado AA, Ramos Sánchez A. Uso de las tecnologías de la información y comunicación como herramienta de apoyo en el aprendizaje de los estudiantes de medicina. CienciaUAT. 2020 [citado 18/08/2025];15(1). Disponible en: https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-78582020000200162

3. Aguilera Pupo E, Trujillo Baldoquín Y, Portuondo Hitchman OL. Estrategia curricular Tecnologías de la Información y las Comunicaciones e investigación en la carrera Medicina. Didáctica y Educación. 2022 [citado 05/08/2025];13(5):78-97. Disponible en: https://dialnet.unirioja.es/servlet/articulo?codigo=8881089

4. Ferrer García M, Díaz Tejera KI. Teorías del aprendizaje para una superación profesional en Tecnologías de la Información y la Comunicación. Edumecentro. 2025 [citado 18/05/08/2026];17(1). Disponible en: https://revedumecentro.sld.cu/index.php/edumc/article/view/2920

5. Calderón Palencia M, Loza Vega I, Castellanos Gutiérrez S. El acceso a las TIC y a la IA en las instituciones de educación superior y sus beneficios en la gestión académica y administrativa. RIICONET. 2025 [citado 29/10/2026];18(19). Disponible en: https://riico.net/index.php/riico/article/view/2288

6. Maluenda Albornoz J, Varas Contreras M, Riffo Ferrada M, Diaz Mujica A. Predictores socio-académicos del Study Engagement en estudiantes de primer año de ingeniería. Estud Pedagóg. 2021 [citado 28/09/2025];47(1):235-250. Disponible en: http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-07052021000100235&lng=es&nrm=iso

7. Lopez Gorozabel OA, Castillo Pinargote MG, Nuñez Zambrano JE, Olarte Sancan YJ, Vera Pico LA. Herramientas de inteligencia artificial para entornos virtuales. Un gran salto a la gestión

inteligente. Caso Moodle. Rev ODIGOS. 2025 [citado 06/07/2026];6(2):9-36. Disponible en: https://revista.uisrael.edu.ec/index.php/ro/article/view/1532

8. Prada Segura JA, Beltrán Gómez A. Aprendizaje Adaptativo para Moodle desde la IA. Ciencia Latina Inter. 2024 [citado 24/05/2025];8(5). Disponible en: https://ciencialatina.org/index.php/cienciala/article/view/15241/21728

9. Cabrales Fuentes J, Álvarez Cuesta JA, Velázquez González VA, Torres Guerra A, Martínez Lozada PR, Fornaris Pérez YA, *et al*. Asistente virtual desde la inteligencia artificial para la gestión de una maestría en Radiodiagnóstico. RCIM. 2025 [citado 29/09/2025];17:e851. Disponible en: https://revinformatica.sld.cu/index.php/rcim/article/view/851

10. Lira Munizaga J, Perez-Salas C. Compromiso académico en universitarios del Programa de Acceso a la Educación Superior (PACE). Calidad en la educación. 2022 [citado 29/08/2025];56:78-96. Disponible en: http://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-45652022000100078&lng=es&nrm=iso

11. Akaike H. Information Theory and an Extension of the Maximum Likelihood Principle. In: Parzen E, Tanabe K, Kitagawa G, editors. Selected Papers of Hirotugu Akaike. Springer Series in Statistics: New York: Springer;1998.

12. World Medical Association. World Medical Association Declaration of Helsinki: Ethical Principles for Medical Research Involving Human Participants. JAMA. 2024 [citado 15/08/2025];333(1):71-74. Disponible en: https://jamanetwork.com/journals/jama/fullarticle/2825290

13. Guimarães LB, Guimarães ICC. Inteligência artificial como ferramenta de apoio à aprendizagem no Moodle: uma revisão bibliográfica. Rev Delos. 2025 [citado

28/10/2025];18(69): e6038. Disponible en: https://ojs.revistadelos.com/ojs/index.php/delos/article/view/6038

14. Bravo Bravo V, Fajardo Aguilar GM, Carrión Espinosa WE, Salvatierra Avila LY. Transformando la educación virtual: La revolución de la inteligencia artificial en la potenciación de la plataforma Moodle. JSR. 2022 [citado 29/05/2025];7(3):140-164. Disponible en: https://revistas.utb.edu.ec/index.php/sr/article/view/2936

15. Mukkala PR, Vuyyuru T, Murthy SNVR, Srinivasa Rao A, Al Said N. Integrating ICT with artificial intelligence for transformative education. J Inf Syst Eng. 2025 [citado 03/08/2025];10(10s). Disponible en: https://jisem-journal.com/index.php/journal/article/view/1418/552

16. Mora Mera MM, Ochoa Gonzalez CR, Cango Zhinín MÁ, Gutiérrez Bastidas JO. Innovación educativa en la universidad: uso de tic e inteligencia artificial para mejorar la enseñanza y evaluación. Reincisol. 2024 [citado 02/05/2025];3(6):6409-6427. Disponible en: https://www.reincisol.com/ojs/index.php/reincisol/article/view/503

17. Ramírez CP, Coicue Rodríguez LA. Factorización 4.0: innovando en la enseñanza a través de la educación disruptiva con Moodle y herramientas de Inteligencia Artificial. [Tesis]. [Colombia]: Universidad Nacional Abierta y a Distancia UNAD;2024. Disponible en: https://repository.unad.edu.co/server/api/core/bitstreams/e8e14cb2-3fc2-4f15-92cf-b04530c4afbb/content

18. Hernández Cruz LM. Gestión de una plataforma educativa virtual con inteligencia artificial y su adecuación funcional en el proceso de aprendizaje. Eur Amp Soc Innov Rev. 2024 [citado 29/09/2026];10:1-17. Disponible en: https://epsir.net/index.php/epsir/article/view/694/935

19. Arellano S, Ochoa Gonzalez CR, Ronquillo Morante LK, Ruiz Ramos JE. Transformación educativa en la universidad: implementación de TIC e IA para fortalecer la enseñanza y el proceso evaluativo. ReSoFro. 2024 [citado 29/09/2025];4(5):e45501. Disponible en: https://www.revistasocialfronteriza.com/ojs/index.php/rev/article/view/501

20. Rajpurkar P, Lungren MP. The current and future state of AI interpretation of medical images. N Engl J Med. 2023 [citado 28/05/2025];388(21):1981-1990. Disponible en: https://www.nejm.org/doi/10.1056/NEJMra2301725

21. Miralles Linares F. Inteligencia artificial en medicina. Rev Esp Casos Clin Med Intern. 2024 [citado 06/08/ 2025];9(3):109-110. Disponible en: https://www.reccmi.com/RECCMI/article/view/1098

22. Cervantes López MJ, Cruz Casados J, Cruz Casados LN. Inteligencia artificial en la gestión de la medicina: avances y desafíos. Rev Venez Gerenc. 2024 [citado 06/07/2025];29(108):1817-135. Disponible en: https://produccioncientificaluz.org/index.php/rvg/article/view/42753/49931

Conflicto de intereses

Los autores no declaran conflicto de intereses

Financiamiento

La presente investigación no contó con financiamiento.

Contribución de los autores

Conceptualización: Carlos Lázaro Jiménez-Puerto,

Curación de datos: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido

Análisis formal: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido

Administración del proyecto: Carlos Lázaro Jiménez-Puerto

Investigación: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido

Metodología: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido

Recursos: Carlos Lázaro Jiménez-Puerto

Supervisión: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido, Eliecer González Valdéz, Jim Alex González Consuegra

Validación: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido, Eliecer González Valdéz, Jim Alex González Consuegra

Visualización: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido

Redacción del borrador original: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido, Jim Alex González Consuegra, Eliecer González Valdéz

Redacción, revisión y edición: Carlos Lázaro Jiménez-Puerto, Miguel Angel Amaró Garrido, Jim Alex González Consuegra, Eliecer González Valdéz

Los artículos de la Revista Correo Científico Médico perteneciente a la Universidad de Ciencias Médicas de Holguín se comparten bajo los términos de la Licencia Creative Commons Atribución 4.0 Internacional Email: publicaciones@infomed.sld.cu