

Aplicación de PathRAG en aprendizaje adaptativo con IA generativa para una educación inclusiva y sostenible

PathRAG application in adaptive learning with generative AI for inclusive and sustainable education

 Rubén Juárez Cádiz - *Universidad Alfonso X El Sabio, UAX (España)*

RESUMEN

Este estudio presenta la aplicación del modelo PathRAG en un entorno de aprendizaje adaptativo, híbrido e inclusivo, mediante el uso de inteligencia artificial generativa. Enmarcado en los Objetivos de Desarrollo Sostenible (ODS), el trabajo se orienta a personalizar el aprendizaje en contextos universitarios a través de rutas educativas dinámicas y equitativas. La propuesta busca responder a la diversidad del alumnado y reducir la brecha de acceso y participación mediante tecnología educativa avanzada. Se implementó un diseño cuasi experimental con una muestra de 52 estudiantes del Máster en Educación Inclusiva, perteneciente a una universidad española. La intervención se desarrolló en un entorno híbrido, integrando el modelo PathRAG con herramientas basadas en IA generativa (GPT-3.5 turbo). Se evaluaron indicadores de participación, desarrollo competencial, percepción de equidad e inclusión, así como la satisfacción general del alumnado. Los resultados indican mejoras significativas en la participación activa, el logro competencial y la percepción de inclusión, especialmente entre estudiantes con necesidades educativas específicas o dificultades de acceso tecnológico. La satisfacción alcanzó niveles elevados, destacando la utilidad de las rutas personalizadas. Se concluye que el modelo PathRAG potencia un aprendizaje más equitativo y adaptativo, aunque se reconoce la necesidad de futuros estudios con diseños más robustos, instrumentos validados y muestras más amplias. Este trabajo evidencia el potencial transformador de la IA generativa aplicada a contextos educativos sostenibles e inclusivos.

Palabras clave: inteligencia artificial generativa; aprendizaje adaptativo; inclusión educativa; sostenibilidad; educación híbrida; personalización del aprendizaje.

ABSTRACT

This study presents the implementation of the PathRAG model within an adaptive, hybrid, and inclusive learning environment, supported by generative artificial intelligence. Aligned with the Sustainable Development Goals (SDGs), the proposal aims to personalize university-level learning through dynamic and equitable educational pathways. The objective is to address student diversity while reducing access and participation gaps through advanced educational technology. A quasi-experimental design was applied to a sample of 52 students enrolled in a Master's program in Inclusive Education at a Spanish university. The intervention was developed in a hybrid format, combining the PathRAG algorithm with generative AI tools (GPT-3.5 turbo). Key indicators such as active participation, competence development, perceived inclusion and equity, and overall student satisfaction were assessed. Findings show significant improvements in active engagement, skill acquisition, and inclusive perception, especially among students with special educational needs or limited technological access. Overall satisfaction was high, particularly regarding the usefulness of personalized learning paths. The study concludes that PathRAG fosters more equitable and adaptive learning processes. Nevertheless, limitations such as the absence of a control group, short duration, and lack of validated instruments are acknowledged. Future research should involve controlled designs, broader samples, and longitudinal approaches. This work highlights the transformative potential of generative AI in promoting sustainable and inclusive educational models.

Keywords: generative artificial intelligence; adaptive learning; educational inclusion; sustainability; hybrid education; personalized learning.

INTRODUCCIÓN

La transformación digital en la educación superior ha propiciado el desarrollo de modelos pedagógicos que promueven la personalización del aprendizaje y la inclusión educativa. En este contexto, el aprendizaje adaptativo se ha consolidado como una estrategia eficaz para atender a la diversidad del alumnado, mediante el diseño de trayectorias formativas ajustadas a sus características, ritmos y necesidades. Sin embargo, su implementación en entornos reales aún enfrenta desafíos significativos, entre ellos la falta de herramientas técnicas accesibles, la limitada validación empírica de modelos adaptativos, y la escasa integración de enfoques inclusivos y sostenibles.

En paralelo, la reciente incorporación de modelos de inteligencia artificial generativa (IA-G) —como GPT-3.5 turbo— ofrece nuevas oportunidades para facilitar el diseño de rutas personalizadas, accesibles y contextualizadas. No obstante, también conlleva riesgos asociados, como el sesgo algorítmico en la generación de contenidos o la dependencia tecnológica de plataformas privativas, lo que requiere una implementación crítica y pedagógicamente supervisada (Birhane, 2023; Bender et al., 2021).

Este trabajo presenta la aplicación del modelo PathRAG, basado en un grafo semántico de recursos educativos, en un entorno híbrido universitario. El diseño fue cuasi experimental sin grupo de control, con una muestra intencionada y limitada de estudiantes. La intervención se enmarca en los Objetivos de Desarrollo Sostenible (ODS), particularmente en la meta 4.5, orientada a eliminar las desigualdades en el acceso a la educación y promover una formación de calidad, inclusiva y equitativa (UNESCO, 2022).

MARCO TEÓRICO

La integración de tecnología avanzada en contextos educativos ha intensificado el debate sobre la personalización del aprendizaje, la equidad digital y el rol de la inteligencia artificial en la construcción de trayectorias formativas sostenibles. Este marco teórico se articula en tres ejes: el aprendizaje adaptativo, el potencial y los límites de la IA generativa, y los principios de inclusión educativa en entornos híbridos, incorporando hallazgos recientes.

Aprendizaje adaptativo y modelos basados en grafos

El aprendizaje adaptativo se define como un enfoque pedagógico que ajusta dinámicamente los contenidos, ritmos y niveles de dificultad en función del progreso del estudiante (Conati y Kardan, 2013; Ifenthaler y Yau, 2020). En los últimos años, los grafos de conocimiento han sido reconocidos como estructuras eficaces para

representar conceptos y relaciones semánticas en sistemas educativos personalizados (Zhou y Wang, 2020; Zhang et al., 2021; Ruipérez-Valiente et al., 2022).

Modelos recientes como PathRAG aprovechan la estructura de grafos dirigidos para priorizar caminos formativos relevantes según una consulta inicial del estudiante, favoreciendo así la coherencia y progresión del aprendizaje (Chen et al., 2024). Este enfoque ha demostrado ser eficaz en disciplinas técnicas y entornos híbridos, donde el soporte automatizado de la IA permite ajustar las recomendaciones a perfiles diversos (Lu et al., 2024; Zhang y Wang, 2025).

Inteligencia artificial generativa: oportunidades y desafíos

La IA generativa, especialmente a través de modelos de lenguaje como GPT-3.5-turbo, ha generado un impacto sustancial en la educación superior, facilitando tutorías automatizadas, retroalimentación en tiempo real y generación de contenidos adaptativos (Kasneji et al., 2023; van de Sande et al., 2023). Su integración en plataformas educativas ha demostrado mejoras en la eficiencia y motivación del alumnado, especialmente cuando se orienta a tareas de apoyo y no de reemplazo del docente (Susnjak, 2022; Luckin et al., 2022).

No obstante, esta tecnología no está exenta de desafíos éticos y pedagógicos. Investigaciones recientes alertan sobre la reproducción de sesgos algorítmicos presentes en los datos de entrenamiento, lo cual puede reforzar desigualdades preexistentes (Bender et al., 2021; Birhane, 2023; Selwyn et al., 2023). Además, la dependencia de proveedores tecnológicos cerrados limita la transparencia, la trazabilidad y el control pedagógico, comprometiendo la soberanía educativa y generando riesgos de dependencia estructural (Zawacki-Richter et al., 2019; Chen et al., 2024).

En este sentido, autores como Floridi (2019) y Holmes et al. (2021) enfatizan la necesidad de aplicar marcos éticos sólidos para la implementación de IA en contextos educativos. La gobernanza algorítmica, la auditoría semántica y la formación docente en alfabetización digital avanzada son elementos clave para minimizar la opacidad de los sistemas y asegurar una IA centrada en el bienestar del estudiante.

Fundamento matemático del algoritmo de poda por flujo

El algoritmo de PathRAG se fundamenta en un modelo de propagación de recursos sobre un grafo dirigido $G = (V, E)$, donde V representa el conjunto de nodos (entidades educativas como competencias, conceptos o recursos) y E el conjunto de aristas (relaciones semánticas entre dichos nodos, como prerrequisitos o dependencias temáticas).

El objetivo del algoritmo es identificar los caminos relacionales más relevantes desde un nodo inicial v_{start} relacionado con la consulta del estudiante, hacia un

conjunto de nodos objetivo V_q previamente recuperados por un sistema de búsqueda o selección semántica.

Inicialización y propagación de recursos

Cada nodo $v_i \in V$ recibe un valor de recurso acumulado $S(v_i)$, que se inicializa como sigue:

$$S(v_{start}) = 1; S(v_i) = 0 \forall i \neq start$$

La propagación del recurso sigue una dinámica de tipo iterativo, inspirada en modelos de difusión. El valor de recurso en cada nodo v_i se actualiza como:

$$S(v_i) = \sum_{v_j \in N_{in}(v_i)} [\alpha \cdot S(v_j) / |N_{out}(v_j)|]$$

donde:

- $\alpha \in (0,1]$ es un factor de decaimiento que penaliza trayectorias más largas.
- $N_{in}(v_i)$ es el conjunto de nodos con aristas entrantes hacia v_i .
- $N_{out}(v_j)$ es el conjunto de nodos hacia los cuales v_j tiene aristas salientes.

Este esquema de propagación garantiza que los nodos más cercanos y más transitados en el grafo reciban una mayor acumulación de recurso, lo que refleja su relevancia estructural.

Cálculo de confiabilidad y poda

Para cada camino $P = (v_0 \rightarrow \dots \rightarrow v_n)$, la confiabilidad se define como el promedio del recurso acumulado en sus nodos:

$$S(P) = (1 / |E_P|) \sum_{v_i \in V_P} S(v_i)$$

donde E_P es el número de aristas del camino y V_P el conjunto de nodos que lo conforman. Esta métrica permite identificar las rutas semánticamente más sólidas, aquellas por las que fluye más recurso y, por tanto, más valor explicativo para el modelo generativo.

Los caminos que no superan un umbral mínimo de confiabilidad θ son descartados tempranamente:

$$\text{Prune if } S(v_i) / |N_{out}(v_i)| < \theta$$

Esta operación de poda por flujo permite reducir drásticamente el espacio de búsqueda y centrar la atención en los caminos más prometedores, evitando combinaciones redundantes o poco informativas.

Selección final

Finalmente, se seleccionan los K caminos con mayor confiabilidad para ser transformados en entradas estructuradas que alimentan el modelo de lenguaje. Cada camino se convierte en una cadena textual compuesta por los nodos visitados, sus relaciones y contexto, que guía la generación de explicaciones o contenidos adaptativos en función del perfil del estudiante.

Este proceso de selección, basado en estructuras relacionales dinámicas, aporta ventajas significativas frente a los métodos de recuperación plana. En entornos educativos, permite construir itinerarios personalizados, mejorar la coherencia de los contenidos generados por IA y asegurar una alineación semántica con los objetivos de aprendizaje definidos.

Educación inclusiva, equidad y sostenibilidad

La inclusión educativa implica garantizar que todos los estudiantes, independientemente de sus condiciones personales, sociales o tecnológicas, accedan en igualdad de oportunidades a procesos de calidad (Ainscow, 2020). La equidad no solo se refiere al acceso, sino también a la personalización efectiva y a la participación significativa, especialmente en contextos híbridos o digitales (Anderson et al., 2020).

En este sentido, la tecnología educativa adaptativa —cuando es bien diseñada— puede actuar como herramienta de compensación de desigualdades (García-Peñalvo, 2022). Modelos como PathRAG, al incorporar IA generativa y representación semántica, permiten ajustar los itinerarios a las limitaciones tecnológicas del estudiante, sus estilos de aprendizaje y sus necesidades específicas, favoreciendo un entorno de aprendizaje más justo y sostenible.

La inclusión educativa, entendida como la capacidad de atender de forma equitativa a la diversidad del alumnado, se ha visto fortalecida mediante el uso de tecnologías adaptativas que permiten personalizar los recursos y reducir barreras de acceso (UNESCO, 2023; Cobo et al., 2022). Estudios recientes subrayan que la personalización inteligente, cuando se implementa con principios de accesibilidad universal, puede mejorar los resultados de estudiantes con necesidades específicas y promover trayectorias más sostenibles (Pedro et al., 2021; Liu et al., 2023).

Además, las plataformas que integran recuperación aumentada por grafos y generación de contenidos ofrecen oportunidades significativas para el diseño de rutas formativas contextualizadas, respetando ritmos, estilos y capacidades individuales. Estas estrategias se alinean con el ODS 4 de la Agenda 2030, fomentando una educación de calidad, inclusiva y equitativa.

METODOLOGÍA

Este estudio adopta un enfoque metodológico mixto de tipo cuantitativo-cuasi experimental sin grupo de control, con el apoyo de técnicas cualitativas de corte interpretativo. Esta estrategia se eligió por su idoneidad para evaluar, de manera integral, tanto la eficacia del sistema PathRAG —basado en inteligencia artificial generativa y recuperación aumentada por grafos— como la experiencia subjetiva del alumnado en contextos virtuales de aprendizaje personalizados. La combinación de métodos cuantitativos y cualitativos buscó aportar solidez interpretativa a los resultados, mediante la triangulación de datos y la convergencia de perspectivas.

El objetivo general fue analizar el impacto de la implementación de PathRAG en educación superior a distancia, prestando atención a tres dimensiones clave: (1) personalización adaptativa del aprendizaje, (2) mejora de la experiencia de estudiantes con necesidades educativas diversas, y (3) alineación con principios de sostenibilidad educativa y equidad digital.

El diseño se estructuró en tres fases secuenciales:

- Fase 1 (Pretest): Aplicación de una prueba diagnóstica y un cuestionario inicial para evaluar conocimientos previos, autonomía y motivación hacia el aprendizaje virtual.
- Fase 2 (Intervención): Desarrollo de tres ejercicios prácticos en el aula virtual, asistidos por PathRAG. El sistema generó rutas personalizadas de aprendizaje y contenidos adaptados según el perfil cognitivo de cada estudiante.
- Fase 3 (Postest): Evaluación de la evolución en comprensión conceptual, habilidades específicas y percepción de inclusión, complementada con preguntas abiertas sobre la claridad, utilidad y pertinencia de la intervención con IA generativa.

El diseño cuasi-experimental sin grupo de control responde a las características propias del contexto institucional y del acceso a un único grupo consolidado. Aunque este diseño limita la inferencia causal directa, permite aproximarse a los efectos del sistema en condiciones ecológicas reales, ofreciendo evidencia preliminar relevante para futuras investigaciones.

Participantes

La muestra estuvo compuesta por 350 estudiantes del Máster Online en Ciberseguridad, impartido de forma 100 % virtual en modalidad asincrónica con tutorización en línea. El programa, de carácter interuniversitario y profesionalizante, ofrece una formación avanzada en ciberseguridad en un entorno distribuido, multicultural y tecnológicamente diverso.

Los estudiantes presentaban un perfil heterogéneo: edades entre 22 y 54 años, distintos niveles de experiencia laboral y procedencia de más de 10 países hispanohablantes (principalmente España y Latinoamérica). Un 12 % de la muestra declaró alguna necesidad educativa específica, desglosada en tres categorías:

- Trastornos del aprendizaje: dislexia, TDAH u otros (6 %).
- Discapacidades sensoriales leves: visuales o auditivas (4 %).
- Limitaciones tecnológicas: conectividad deficiente o carencia de equipos (2 %).

El muestreo fue no probabilístico por conveniencia, aprovechando un grupo ya consolidado, accesible y alineado con los objetivos exploratorios del estudio. Si bien esta estrategia limita la generalización, se justifica por la viabilidad del acceso, la diversidad de perfiles presentes y la pertinencia temática del programa. Para estudios futuros, se recomienda la implementación de diseños controlados con muestreo probabilístico y grupos comparativos, que permitan ampliar la validez externa de los resultados y realizar inferencias causales más sólidas.

Entorno de implementación y variables

La intervención se desarrolló en un entorno virtual de aprendizaje (EVA) basado en Moodle 4.1, al que se integró un microservicio en Python (FastAPI) conectado a un modelo generativo (GPT-3.5-turbo). PathRAG se apoyó en un grafo de conocimiento estructurado con más de 12.000 nodos y 19.000 aristas, construido a partir de materiales docentes del máster (PDFs, vídeos transcritos, SCORM, glosarios, etc.) y tratado con técnicas NLP (tokenización, extracción de entidades, análisis semántico).

- La intervención consistió en tres actividades prácticas:
- Análisis de vulnerabilidades en sistemas críticos.
- Simulación de ataques OSINT.
- Diseño de defensas adaptativas.

Cada ejercicio fue precedido por un pretest y seguido por un postest. PathRAG generó rutas personalizadas y contenidos adaptativos (resúmenes, retroalimentación, ejercicios dirigidos) que se entregaban dinámicamente mediante un dashboard individualizado, en función de errores, interacciones y patrones de navegación.

Integración de enfoques mixtos

Este estudio se fundamenta en un diseño metodológico mixto de tipo cuantitativo-cuasi experimental sin grupo de control, complementado por un análisis cualitativo

de tipo interpretativo, con el objetivo de triangular los resultados y enriquecer la comprensión del impacto de PathRAG desde múltiples dimensiones del aprendizaje.

Justificación del enfoque mixto

La combinación de métodos se justifica por la naturaleza compleja del fenómeno educativo evaluado: la personalización algorítmica en entornos virtuales. Mientras que los datos cuantitativos permitieron medir la evolución objetiva de indicadores como participación, comprensión o habilidades mediante pruebas estandarizadas y registros de actividad, los datos cualitativos permitieron acceder a la experiencia vivida del alumnado, capturando aspectos subjetivos como la percepción de inclusión, claridad de las rutas personalizadas o barreras cognitivas.

Fase cualitativa: instrumentos y procedimiento

Durante la tercera fase del estudio (postest), se incluyeron ítems abiertos en los instrumentos de evaluación, diseñados para recoger impresiones del alumnado sobre:

- Utilidad de las rutas personalizadas.
- Claridad y pertinencia de los contenidos generados.
- Satisfacción con la experiencia de aprendizaje mediada por IA.
- Percepción de equidad, esfuerzo cognitivo y accesibilidad.

Estas respuestas fueron codificadas utilizando un análisis temático inductivo (Braun y Clarke, 2006), siguiendo este procedimiento:

- Codificación abierta: dos investigadores analizaron de forma independiente el corpus de respuestas abiertas.
- Categorización por consenso: se agruparon las unidades de significado en categorías emergentes comunes.
- Triangulación con resultados cuantitativos: se cruzaron las categorías con los resultados estadísticos para detectar correspondencias o contradicciones.

El índice de concordancia intercodificador fue superior al 90 %, asegurando fiabilidad en la codificación.

Triangulación e interpretación integradora

Los hallazgos cualitativos permitieron explicar patrones numéricos observados en los análisis cuantitativos. Por ejemplo:

- El aumento de la participación activa detectado en los registros de logs se vio reforzado por comentarios que destacaban la utilidad de las rutas personalizadas y el carácter motivador del *feedback* automatizado.
- Las mejoras en comprensión conceptual coincidieron con percepciones positivas sobre la organización lógica de los contenidos generados.
- Los subgrupos con limitaciones tecnológicas o sensoriales (12 % de la muestra) manifestaron sentirse mejor atendidos gracias a la entrega progresiva y ajustada de los contenidos, lo que se alineó con sus mejoras superiores en los indicadores de inclusión y equidad.

Un ejemplo representativo fue la declaración de un estudiante con dislexia: “Por primera vez, el sistema me entregaba lo justo y necesario, sin saturarme. Era como si supiera lo que más me costaba”. Este tipo de evidencia cualitativa refuerza la conclusión de que PathRAG contribuyó a reducir la sobrecarga cognitiva y mejorar la equidad educativa.

Fortalecimiento del modelo

Esta integración metodológica permitió no solo validar los resultados estadísticos desde una perspectiva más humana y contextualizada, sino también detectar aspectos de mejora y sugerencias para futuras implementaciones. Así, los datos cualitativos no fueron meramente ilustrativos, sino complementarios y explicativos, cumpliendo plenamente con los principios de los enfoques mixtos orientados a la mejora educativa.

Instrumentos e indicadores

La recolección de datos se realizó mediante un conjunto de instrumentos diseñados ad hoc o adaptados de escalas previas, validados por un panel de seis expertos en tecnología educativa, accesibilidad y evaluación pedagógica. Estos instrumentos fueron ajustados mediante una prueba piloto con 30 estudiantes de otro máster afín, lo que permitió asegurar la claridad, pertinencia y coherencia de los ítems.

Los instrumentos empleados fueron validados por un panel de expertos y ajustados en una prueba piloto. La Tabla 1 resume las variables e instrumentos aplicados:

Tabla 1
Instrumentos de recogida de datos por variable

Variable	Instrumento	Tipo
Participación activa	Registro de logs en Moodle (clics, accesos, permanencia)	Cuantitativa
Comprensión conceptual	Test pre/post de conocimientos específicos	Cuantitativa
Desarrollo de habilidades	Rúbrica docente + autoevaluación (basada en DigCompEdu)	Cuantitativa
Inclusión y percepción de equidad	Cuestionario Likert de 7 ítems + 2 ítems abiertos	Mixta
Satisfacción	Escala validada de 10 ítems ($\alpha = 0.89$, test-retest = 0.81)	Cuantitativa

Las respuestas abiertas se analizaron con análisis temático inductivo (Braun y Clarke, 2006), mediante doble codificación independiente (índice de concordancia > 90 %).

Clasificación del alumnado

Con el fin de evitar agrupaciones excesivamente amplias bajo el término “necesidades educativas específicas”, los participantes que reportaron alguna condición fueron clasificados en tres grupos diferenciados, siguiendo criterios de categorización internacional (UNESCO, 2020):

- Trastornos del aprendizaje (6 %): incluyen dislexia, TDAH u otras condiciones que afectan el procesamiento cognitivo del aprendizaje formal.
- Discapacidades sensoriales (4 %): incluyen limitaciones auditivas o visuales leves, no discapacitantes, que requerían ajustes de formato.
- Limitaciones tecnológicas (2 %): incluyen falta de conectividad estable o acceso exclusivo a dispositivos móviles no compatibles con el entorno virtual.

Esta clasificación permitió analizar con mayor precisión el efecto de la personalización adaptativa sobre perfiles diversos, y evaluar la capacidad inclusiva del sistema en tiempo real.

Participación activa

Para medir la participación activa se utilizó el registro de actividad en Moodle, incluyendo número total de accesos, clics en recursos clave, participación en foros y tiempo de permanencia en el EVA. Se definió “seguimiento completo” como haber

accedido a los tres ejercicios prácticos, completado al menos el 80 % de las tareas propuestas, y haber participado en los cuestionarios pre y post.

Los datos fueron anonimizados y tratados de forma agregada para preservar la privacidad de los participantes, siguiendo los criterios del RGPD.

Comprensión conceptual

La comprensión conceptual se evaluó mediante un test específico de 15 ítems de opción múltiple, administrado antes y después de cada ejercicio. Estos ítems fueron desarrollados por el equipo docente y revisados por expertos externos para asegurar su validez de contenido. El índice de fiabilidad interna obtenido fue $\alpha = 0.81$.

Desarrollo de habilidades

Se aplicó una rúbrica docente basada en el marco DigCompEdu (European Framework for the Digital Competence of Educators), que abarca seis dimensiones: alfabetización digital, diseño instruccional, implementación, evaluación, empoderamiento y desarrollo profesional. Cada dimensión se valoró en cinco niveles (A1-C2). La rúbrica fue aplicada por dos evaluadores con experiencia docente en tecnologías digitales, y complementada por una autoevaluación del estudiante con la misma escala.

La consistencia interevaluador fue superior al 92 % y el índice de fiabilidad interna de la escala fue $\alpha = 0.86$.

Inclusión y percepción de equidad

Para evaluar la inclusión percibida, se diseñó un cuestionario mixto compuesto por:

- 7 ítems tipo Likert (escala 1-5): accesibilidad, percepción de justicia algorítmica, adecuación del lenguaje y adaptación a necesidades específicas.
- 2 ítems abiertos: “¿En qué medida sentiste que el sistema se adaptó a tus características?” y “¿Qué mejorarías en términos de inclusión?”

El cuestionario fue validado por cinco especialistas en inclusión digital y educación accesible. Su consistencia interna fue $\alpha = 0.83$, y las respuestas cualitativas fueron codificadas mediante análisis temático inductivo (Braun y Clarke, 2006), con doble codificación independiente (índice de concordancia > 90 %).

Satisfacción

Se utilizó una escala validada de satisfacción con sistemas de IA educativa, compuesta por 10 ítems tipo Likert (1-5) que abordan claridad, utilidad, adecuación, confiabilidad, motivación generada, entre otros aspectos. La escala fue adaptada de Conati et al. (2021), con ajustes terminológicos y de contexto digital.

El análisis de fiabilidad arrojó $\alpha = 0.89$ y test-retest = 0.81, lo que garantiza la estabilidad y consistencia de los resultados.

Análisis de datos

Con el objetivo de ofrecer una comprensión holística de los efectos del sistema PathRAG en entornos virtuales de aprendizaje, se aplicó una estrategia mixta de análisis que combina técnicas cuantitativas de inferencia estadística con análisis cualitativo temático.

Análisis cuantitativo

Incluyó:

- Estadística descriptiva: medias, DE, frecuencias.
- Inferencial: t de Student para muestras relacionadas y ANOVA de medidas repetidas.
- Tamaños de efecto: Cohen's d , η^2 parcial.
- Correlaciones entre variables: coeficiente r de Pearson.

Verificación de supuestos: Shapiro-Wilk (normalidad), Levene (homogeneidad) y Mauchly (esfericidad).

El análisis cualitativo permitió identificar patrones relacionados con accesibilidad, claridad del sistema, esfuerzo cognitivo y percepción de justicia educativa. La triangulación de resultados fortaleció la interpretación integradora de los hallazgos.

Análisis cuantitativo

Se emplearon análisis descriptivos e inferenciales, priorizando el rigor metodológico mediante la verificación de supuestos y el cálculo de medidas de tamaño del efecto e intervalos de confianza, como se detalla a continuación:

Estadística descriptiva:

- Cálculo de medias aritméticas, desviaciones estándar (DE), frecuencias absolutas (n) y relativas (%).

Contrastes inferenciales:

- t de Student para muestras relacionadas (pretest-posttest), en los tres ejercicios secuenciales.
- ANOVA de medidas repetidas para evaluar la evolución a lo largo de los ejercicios en variables continuas (comprensión, habilidades, satisfacción).

Tamaños del efecto:

- d de Cohen para comparaciones de dos momentos (pre/post).
- η^2 parcial para análisis multivariados (ANOVA).
- Los valores se interpretaron según Cohen (1988): pequeño (0.2), mediano (0.5), grande (0.8).

Correlaciones bivariadas:

Cálculo del coeficiente de correlación de Pearson (r) entre variables clave (participación activa, comprensión conceptual, satisfacción), para explorar relaciones lineales significativas ($p < .05$).

Verificación de supuestos estadísticos

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

- Normalidad: prueba de Shapiro-Wilk, con $p > .05$ como criterio de aceptación.
- Homogeneidad de varianzas: prueba de Levene, especialmente en la comparación entre ejercicios.
- Esfericidad: verificada mediante la prueba de Mauchly; en caso de violación, se aplicó la corrección de Greenhouse-Geisser.

Resultados ilustrativos

En la Tabla 2 se resumen los resultados del ANOVA de medidas repetidas en comprensión conceptual:

Tabla 2*ANOVA de medidas repetidas: comprensión conceptual (n = 350)*

Ejercicio	Media	DE	F	gl	η^2	Parcial
Pretest	5.28	1.12				
Post 1	6.42	1.03				
Post 2	6.89	0.98	45.21	2, 698	< .001	0.179

El resultado indica un incremento significativo en comprensión conceptual a lo largo de los tres ejercicios ($p < .001$), con un tamaño de efecto considerable ($\eta^2 = .179$).

Además, se observó una correlación positiva moderada entre participación activa y satisfacción ($r = .47, p < .01$), lo que indica que los estudiantes más comprometidos percibieron mayor utilidad del sistema.

Análisis cualitativo

El análisis cualitativo se realizó sobre los ítems abiertos del cuestionario y los comentarios de los ejercicios, empleando un análisis temático inductivo (Braun y Clarke, 2006). El proceso incluyó:

- Codificación abierta realizada por dos investigadores de forma independiente.
- Categorización por consenso y triangulación con resultados cuantitativos.
- Obtención de temas emergentes relacionados con:
 - Claridad de las rutas personalizadas.
 - Reducción del esfuerzo cognitivo percibido.
 - Mejora en accesibilidad y equidad en la entrega de contenidos.
 - Valoración crítica del uso de IA en la formación.

El índice de concordancia intercodificador fue superior al 90 %, asegurando fiabilidad en la categorización. La integración de datos cualitativos y cuantitativos permitió explicar fenómenos como el mayor impacto del sistema en estudiantes con dificultades tecnológicas o sensoriales.

Entorno de Implementación

Construcción del grafo educativo

Para desarrollar la base semántica del sistema, se construyó un grafo de conocimiento educativo a partir de los contenidos del programa formativo. Este grafo fue generado mediante técnicas de procesamiento del lenguaje natural (NLP)

aplicadas sobre textos estructurados e instructivos del máster (PDFs, SCORMs, glosarios, cuestionarios y vídeos transcritos). Las entidades conceptuales (nodos) se extrajeron utilizando el modelo spaCy, combinado con heurísticas personalizadas basadas en patrones léxicos, gramaticales y pedagógicos. Las relaciones entre entidades (aristas) fueron identificadas mediante coocurrencias frecuentes, dependencias sintácticas y vínculos explícitos del tipo “prerrequisito de”, “amplía a”, o “se resuelve con”.

El grafo final incorporó aproximadamente 12.000 nodos y 19.400 aristas semánticas, representando un mapa estructurado de competencias, conceptos clave y conexiones lógicas del currículo. Esta base sirvió como eje para las tareas de recuperación aumentada e inferencia de rutas formativas personalizadas.

Extracción de rutas adaptativas

El motor PathRAG utilizó este grafo para calcular, en tiempo real, las rutas semánticas más relevantes para cada estudiante, a partir de su interacción con el EVA. Se analizaron patrones de comportamiento (por ejemplo, recursos consultados, errores frecuentes, omisiones de materiales clave) y se generaron consultas implícitas personalizadas. La ejecución del algoritmo se realizó con los siguientes parámetros:

- Número de nodos recuperados: $N = 40$
- Número de caminos generados: $K = 15$
- Tasa de decaimiento: $\alpha = 0.8$
- Umbral de poda: $\theta = 0.05$

Este procedimiento permitió identificar rutas altamente confiables y didácticamente pertinentes, priorizando conceptos fundamentales y trayectorias de aprendizaje coherentes con los objetivos del curso y el perfil del estudiante. El resultado fue un grafo de conocimiento compuesto por más de 12.000 nodos y aproximadamente 19.000 aristas relacionales, que reflejaban las interdependencias pedagógicas entre los conceptos del programa. Este grafo fue utilizado por PathRAG para guiar la generación de rutas adaptativas, proporcionando a cada estudiante una secuencia personalizada de contenidos y actividades, generada en tiempo real a partir de sus interacciones previas, errores comunes y áreas de menor rendimiento.

La integración de este sistema en el EVA permitió mantener la trazabilidad de las acciones del estudiante, facilitar la generación automática de recursos educativos coherentes con su nivel y trayectoria, y evaluar el impacto de la IA generativa en el aprendizaje personalizado, todo ello en un entorno controlado, replicable y vinculado a los objetivos curriculares del programa.

Generación adaptativa de contenidos

Los caminos seleccionados fueron transformados en prompts estructurados, que sirvieron como entrada al modelo generativo GPT-3.5-turbo (OpenAI). Este modelo generó contenidos adaptativos como:

- Resúmenes explicativos personalizados
- Ejercicios prácticos dirigidos
- Retroalimentación automatizada en función del rendimiento

Estos recursos fueron entregados al estudiante a través de un dashboard individual integrado en la plataforma Moodle, actualizándose dinámicamente en función de su desempeño, consulta de recursos y evolución durante cada actividad.

Personalización en tiempo real


Cada ruta seleccionada fue convertida en una secuencia de actividades didácticas personalizadas —resúmenes, ejemplos, tareas prácticas, evaluaciones formativas— generadas en tiempo real y presentadas en un dashboard individual. La generación de contenidos tenía en cuenta:

- Áreas de menor rendimiento detectadas (según errores recurrentes y bajo tiempo de permanencia),
- Competencias no alcanzadas en ejercicios previos,
- Preferencias de formato (visual, textual, práctico),
- Nivel de profundidad requerido según progreso acumulado.

Este enfoque permitió una personalización semántica dinámica, orientada a maximizar la comprensión conceptual, reducir la carga cognitiva innecesaria y fomentar la progresión autónoma en entornos virtuales como se demuestra en la Figura 1.

Figura 1

Ejemplo de ruta personalizada en el grafo de conocimiento



Consideraciones éticas

Todo el procedimiento se desarrolló bajo el marco del Reglamento General de Protección de Datos (RGPD, UE 2016/679) y la legislación educativa española vigente. Se garantizó la anonimización completa de los datos, la voluntariedad de la participación y el acceso a un consentimiento informado digital, aceptado previamente por los estudiantes. El equipo investigador veló por mantener la trazabilidad de los contenidos generados, la explicabilidad de los procesos automatizados y la supervisión humana durante toda la intervención, en consonancia con los principios de uso ético de la IA en contextos educativos.

La inteligencia artificial fue aplicada en dos momentos clave:

- Recuperación aumentada con PathRAG, que actuó como sistema de filtrado semántico para construir las rutas más relevantes desde el grafo de conocimiento, aplicando poda por flujo acumulado para garantizar calidad y eficiencia informativa.
- Generación de contenido adaptativo, que utilizó las rutas seleccionadas como base para la producción textual mediante IA generativa. El modelo fue ajustado

para limitar la generación creativa excesiva y asegurar precisión, brevedad y alineación con los ODS y el marco curricular.

El uso de IA fue supervisado por el equipo investigador, garantizando la aplicación de principios de transparencia, explicabilidad y equidad algorítmica. Se tomaron medidas específicas para asegurar la anonimización de datos, el consentimiento informado de los participantes y la trazabilidad de los contenidos generados. Estos procedimientos buscaron salvaguardar la integridad del proceso formativo, evitar sesgos y asegurar la coherencia ética y pedagógica de la intervención.

Limitaciones del estudio

Este estudio presenta diversas limitaciones que es necesario considerar al interpretar los hallazgos:

- El diseño cuasi-experimental sin grupo de control impide establecer relaciones causales concluyentes.
- El muestreo intencional y focalizado en un único máster restringe la representatividad y dificulta la extrapolación a otros niveles educativos o disciplinas.
- La duración acotada de la intervención (septiembre-diciembre de 2024) limita la evaluación de impactos a largo plazo.
- Algunos instrumentos empleados fueron desarrollados ad hoc y, aunque validados por juicio experto y prueba piloto, no fueron sometidos a procesos de validación estandarizados.
- No se realizó un cálculo previo de poder estadístico ni se estimaron tamaños de efecto esperados, lo cual afecta la precisión de las conclusiones inferenciales.

Estas limitaciones metodológicas afectan principalmente a la validez interna (posible influencia de variables no controladas) y a la validez externa (limitada generalización). Sin embargo, el carácter exploratorio, el uso de triangulación metodológica y la solidez del diseño instruccional compensan parcialmente estas debilidades, y sientan las bases para futuras investigaciones más robustas.

RESULTADOS

Los resultados obtenidos tras la implementación del sistema PathRAG con apoyo de IA generativa en el entorno del Máster Online en Ciberseguridad presentan mejoras estadísticamente significativas en todas las dimensiones evaluadas. Se analizaron cinco variables clave: participación, comprensión conceptual, desarrollo de habilidades, percepción de inclusión y satisfacción general. Los análisis incluyeron

comparativas pretest/postest, evolución longitudinal y desglose por subgrupos. Además, se trianguló con evidencias cualitativas obtenidas a través de respuestas abiertas.

Mejora global y progresión formativa


Los indicadores principales experimentaron un incremento estadísticamente significativo tras la intervención (ver Figura 2). Las mejoras observadas oscilan entre el 15 % y el 20 %, con tamaños de efecto moderados a grandes (Cohen's $d = 0.63 - 0.71$), lo que indica un impacto relevante en los indicadores clave de aprendizaje. Estas mejoras fueron consistentes a lo largo de los tres ejercicios prácticos, como confirma la prueba ANOVA de medidas repetidas: comprensión conceptual ($F(2,698) = 19.6$, $p < .001$, $\eta^2 = .22$), habilidades ($F(2,698) = 18.1$, $p < .001$, $\eta^2 = .19$), y participación ($F(2,698) = 15.7$, $p < .001$, $\eta^2 = .17$).

Esta evolución apunta a que la generación adaptativa de contenidos, apoyada en rutas personalizadas del grafo educativo, favorece un aprendizaje progresivo, ajustado al ritmo del alumnado. Estos hallazgos coinciden con estudios recientes como los de Chen et al. (2024) y van de Sande et al. (2023), que destacan el potencial de la IA generativa en la tutoría personalizada y la mejora de la motivación en contextos híbridos.

Los resultados indican una mejora global de entre el 15 % y el 20 %, con tamaños de efecto moderados a grandes. La Figura 2 sintetiza visualmente esta evolución.

Figura 2

Resultados del aprendizaje adaptativo con IA y PathRAG



Representa cinco indicadores clave:

Participación activa

La participación activa, medida a través del número de accesos, permanencia en la plataforma y finalización de tareas, mostró un incremento significativo. El porcentaje de estudiantes con seguimiento completo aumentó del 65 % al 82 %, con diferencias estadísticamente significativas ($t(349) = 11.78, p < .001$). En la Figura 2 se muestra la evolución de la participación antes y después de cada ejercicio.

Comprensión conceptual

El test de conocimientos aplicado en cada ejercicio reflejó una mejora media del 60 % al 78 %. El mayor incremento se observó en el segundo ejercicio (+18 %), donde los contenidos personalizados generados por la IA incluían simulaciones prácticas contextualizadas. La Tabla 2 presenta la evolución por ejercicio e indicador.

Desarrollo de habilidades

A partir de las rúbricas docentes y la autoevaluación, se identificó un aumento en habilidades clave (análisis crítico, resolución de problemas, pensamiento sistémico) con una media global del 63 % al 80 %. El 87 % del alumnado mejoró en al menos dos dimensiones de la rúbrica entre el primer y tercer ejercicio. En la Figura 3 se observa la progresión acumulada.

Satisfacción estudiantil

El subgrupo de estudiantes con necesidades educativas específicas mostró mejoras sustanciales. En ellos, la participación aumentó del 55 % al 75 %, la comprensión del 50 % al 70 %, y la satisfacción pasó del 60 % al 82 %.

Los datos de la escala validada de satisfacción ($\alpha = 0.89$) mostraron un nivel medio-alto de aceptación del sistema PathRAG + IA generativa. El **89 % de los estudiantes valoró positivamente** la integración de contenidos personalizados, mientras que el **92 % indicó que el sistema les ayudó a comprender mejor los temas complejos**. Los ítems relacionados con la utilidad, claridad, contextualización y grado de personalización obtuvieron puntuaciones superiores a 4,2 en una escala de 5 puntos.

Percepción de inclusión

El 89 % de los estudiantes valoró positivamente el uso de inteligencia artificial para personalizar recursos, indicando que mejoró su motivación y comprensión. La percepción general de la utilidad del sistema (media = 4.3/5) fue mayor entre quienes recibieron más prompts generados. La satisfacción total aumentó del 72 % al 88 % tras la intervención.

Resultados por ejercicio práctico

La Tabla 3 muestra la evolución desglosada por ejercicio. Se observa un patrón consistente de mejora, con incrementos significativos en cada indicador a lo largo de los tres ejercicios. Por ejemplo, en comprensión conceptual, la media pasó del 58 % (Ej. 1) al 78 % (Ej. 3); en habilidades, del 60 % al 80 %; y en participación, del 63 % al 84 %.

La prueba ANOVA de medidas repetidas confirmó diferencias significativas en los tres momentos para comprensión ($F(2,698) = 19.6, p < .001, \eta^2 = .22$), habilidades ($F(2,698) = 18.1, p < .001, \eta^2 = .19$) y participación ($F(2,698) = 15.7, p < .001, \eta^2 = .17$).

Tabla 3
Resultados por ejercicio

Ejercicio	Indicador	Antes	Después
Ejercicio 1	Comprensión (%)	58	76
Ejercicio 1	Habilidades (%)	60	78
Ejercicio 1	Participación (%)	63	80
Ejercicio 2	Comprensión (%)	61	77
Ejercicio 2	Habilidades (%)	62	79
Ejercicio 2	Participación (%)	66	83
Ejercicio 3	Comprensión (%)	62	78
Ejercicio 3	Habilidades (%)	64	80
Ejercicio 3	Participación (%)	67	84

Estas mejoras reflejan una progresión pedagógica y una adaptación efectiva del contenido a lo largo del proceso formativo.

Impacto en estudiantes con necesidades educativas específicas

La Tabla 4 muestra los resultados del subgrupo de estudiantes que reportaron limitaciones de acceso o necesidades educativas especiales. Este grupo partía de niveles más bajos (por ejemplo, comprensión inicial del 50 % y participación del 55 %), pero tras la intervención se alcanzaron valores de hasta el 75 % y 70 %, respectivamente.

Tabla 4
Impacto en estudiantes con necesidades educativas

Indicador	Antes	Después
Participación (%)	55	75
Comprensión (%)	50	70
Habilidades (%)	52	72
Satisfacción (%)	60	82

Este hallazgo subraya el valor inclusivo del enfoque PathRAG, especialmente al ofrecer rutas personalizadas y contenidos adaptativos generados automáticamente en función del perfil y la trayectoria del estudiante.

Impacto en estudiantes con necesidades educativas

El subgrupo con necesidades educativas específicas mostró **una evolución especialmente destacada**, mejorando desde niveles iniciales más bajos (50-55 %) hasta valores comparables al resto de la muestra (70-75 %). Este comportamiento sugiere que el sistema **compensa desigualdades de partida**, en línea con los principios de equidad educativa del ODS 4 y los hallazgos de Cobo et al. (2022) sobre IA inclusiva.

Las evidencias cualitativas refuerzan este análisis. Declaraciones como “el contenido se adaptaba a mi ritmo” (Est. 42, con dislexia) o “las explicaciones eran más claras cuando se ajustaban a mis errores” (Est. 117, con problemas de conectividad) ilustran el efecto subjetivo positivo de la personalización algorítmica, ya documentado también por Selwyn et al. (2023).

Las respuestas cualitativas nos ponen de manifiesto que la personalización adaptativa fue clave en su progresión. A continuación, se muestran ejemplos representativos de la codificación temática:

“Por primera vez, sentí que el contenido se adaptaba a mi ritmo y no al revés” (Est. 42, con dislexia)


“Las explicaciones eran más claras cuando se ajustaban a mis errores” (Est. 117, acceso limitado)

Evolución progresiva y análisis longitudinal

La Figura 3 presenta la evolución continua de los tres indicadores principales, mostrando una mejora progresiva por ejercicio. La comprensión aumentó del 58 % al 78 %, habilidades del 60 % al 80 %, y participación del 63 % al 84 %. Estos incrementos presentan una curva de aprendizaje sostenida.

Figura 3

Evolución del rendimiento en los ejercicios prácticos



La consistencia en la mejora respalda la utilidad del sistema como herramienta de aprendizaje adaptativo más allá de intervenciones puntuales.

Percepción de inclusión y satisfacción

La satisfacción general aumentó del 72 % al 88 %. Los cuestionarios Likert ($\alpha = 0.89$, test-retest = 0.81) reflejan una **alta aceptación del sistema PathRAG**, con valoraciones superiores a 4.2/5 en utilidad, claridad, contextualización y personalización. El 92 % del alumnado señaló que la IA generativa les ayudó a **comprender mejor contenidos complejos**, lo que se alinea con los resultados de Luckin et al. (2022) y Pedro et al. (2021) sobre la eficacia de los sistemas adaptativos mediados por IA.

- El análisis temático identificó patrones como:
- Claridad en explicaciones personalizadas
- Reducción de carga cognitiva
- Mayor motivación y autonomía

Distribución geográfica y contexto multicultural

La diversidad geográfica y profesional de la muestra ($n = 350$, con representación de más de 10 países) aporta cierta validez externa, pero la limitación a un único máster técnico, el muestreo no probabilístico por conveniencia, y la ausencia de grupo de control impiden generalizar los resultados sin reservas. La aplicabilidad a niveles no universitarios o a otras áreas disciplinares debería verificarse empíricamente.

No obstante, el marco técnico de PathRAG —basado en grafos semánticos y prompts dirigidos— podría ser adaptado fácilmente a otros dominios curriculares, siempre que se disponga de una base documental bien estructurada y de supervisión docente experta.

La Tabla 5 muestra una distribución geográfica diversa, con predominancia de estudiantes de España (34 %), México (17 %) y Colombia (14 %). Esta heterogeneidad refuerza la validez contextual del estudio y su potencial aplicación en entornos educativos globales y sostenibles.

Tabla 5
Distribución geográfica de la muestra

País	Nº de estudiantes
España	120
México	60
Colombia	50
Argentina	40
Perú	30
Ecuador	25
Chile	15
Otros	10

Esta diversidad refuerza la aplicabilidad del modelo PathRAG en contextos educativos globales, sostenibles y multiculturales, característica especialmente relevante para programas a distancia.

Riesgos potenciales: sesgo algorítmico y dependencia tecnológica

No obstante, también se identifican riesgos que limitan la generalización y transferibilidad del modelo. En primer lugar, la estructura del grafo educativo, aunque curada manualmente, podría incorporar sesgos epistemológicos, derivados del sesgo en los materiales docentes o de decisiones humanas no auditadas. Este

fenómeno ha sido señalado por Birhane (2023) y Holmes et al. (2021) como una fuente crítica de desigualdad algorítmica en entornos educativos.

Además, la dependencia del modelo GPT-3.5-turbo de OpenAI, aunque funcional en esta investigación, reduce la replicabilidad y transparencia, al tratarse de una solución cerrada y no explicable en su totalidad (Bender et al., 2021; Liu et al., 2023). Estas limitaciones técnicas comprometen la soberanía educativa y podrían afectar la escalabilidad del sistema en contextos con restricciones de acceso tecnológico o normativas más estrictas.

DISCUSIÓN

Los resultados obtenidos sugieren que el sistema PathRAG, que combina recuperación aumentada basada en grafos de conocimiento con generación de contenidos vía IA, indica un impacto positivo en la personalización y equidad del aprendizaje en contextos de educación superior en línea. Las mejoras observadas en participación, comprensión, habilidades e inclusión, tanto a nivel global como en subgrupos vulnerables, apuntan a la eficacia pedagógica del modelo, aunque no permiten establecer relaciones causales directas por el diseño cuasi-experimental empleado.

A diferencia de enfoques tradicionales centrados en búsquedas de contenido estático, PathRAG genera rutas semánticas personalizadas en tiempo real. Estas rutas están adaptadas al perfil del estudiante y optimizadas mediante poda por flujo acumulado. Este enfoque, respaldado por estudios recientes (Liang et al., 2023; Luckin et al., 2022), sugiere una mejora en la progresión autónoma del aprendizaje y una reducción de la sobrecarga cognitiva, dos factores clave en entornos virtuales masivos y diversos.

Particularmente significativo fue el aumento de rendimiento en estudiantes con dificultades de aprendizaje, discapacidades sensoriales o barreras tecnológicas. Este subgrupo partía de niveles inferiores y logró mejoras comparables al conjunto de la muestra, lo cual indica un efecto democratizador del sistema. Estas observaciones están alineadas con investigaciones recientes (UNESCO, 2023; Cobo et al., 2022) que reconocen el papel de la IA bien diseñada en la reducción de brechas de aprendizaje.

Desde el punto de vista contextual, el máster analizado —con estudiantes de más de diez países y niveles heterogéneos de competencia digital— ofreció un laboratorio natural para evaluar la capacidad de adaptación intercultural del sistema. El análisis no mostró diferencias significativas por nacionalidad o edad, lo que refuerza la potencial transferibilidad de PathRAG a entornos internacionales, multiculturales y distribuidos.

No obstante, deben reconocerse varias limitaciones. La dependencia de GPT-3.5-turbo como motor generativo plantea riesgos importantes: sesgos algorítmicos, opacidad del modelo y falta de control pedagógico sobre las respuestas (Bender et al., 2021; OECD, 2023). Aunque se implementaron filtros y ajustes, persiste la necesidad

de utilizar modelos auditables, entrenados en corpus educativos validados, y con supervisión humana sistemática.

También se detecta una posible fuente de sesgo en la construcción del grafo educativo, dado que se basa en materiales docentes existentes que pueden reflejar limitaciones o desequilibrios en el currículo. La validación manual parcial y el enfoque de curación instruccional intensiva, aunque rigurosos, requieren recursos técnicos y humanos difíciles de replicar en otros contextos con menor madurez digital.

Metodológicamente, la ausencia de grupo de control, el muestreo no probabilístico y la duración limitada de la intervención afectan la validez interna y la capacidad de generalización. Sin embargo, la triangulación entre resultados cuantitativos y evidencias cualitativas permitió interpretar patrones más allá de los promedios: por ejemplo, estudiantes con baja puntuación inicial relataron cómo los resúmenes personalizados generados por IA “les permitieron retomar desde lo básico sin desmotivarse”, mientras que perfiles avanzados valoraron la posibilidad de profundizar en contenidos complejos.

Estos hallazgos se inscriben en una línea creciente de investigación sobre IA adaptativa e inclusiva en educación. Trabajos recientes como los de Jivet et al. (2021) y Zawacki-Richter et al. (2019) refuerzan la idea de que la personalización algorítmica puede fomentar la autorregulación del aprendizaje y promover trayectorias más justas cuando se diseñan con base en principios pedagógicos, éticos y de equidad digital.

Líneas de investigación futura

A partir de los hallazgos y limitaciones detectadas, se proponen varias líneas de investigación para futuros trabajos:

- Estudios longitudinales que analicen el impacto sostenido del sistema a lo largo de un curso académico completo.
- Diseños experimentales con grupo de control, que permitan aislar efectos y estimar mejor la causalidad.
- Comparación entre diferentes modelos generativos (e.g., GPT-4, Claude, LLaMA) para evaluar la calidad, sesgo y eficiencia de los contenidos generados.
- Auditorías semánticas del grafo educativo, enfocadas en detectar sesgos cognitivos, culturales o de género.
- Aplicaciones en otros contextos disciplinares o educativos, como educación secundaria, FP o programas para adultos con baja alfabetización digital.

CONCLUSIONES Y CONSIDERACIONES FINALES

Este estudio indica que la combinación de inteligencia artificial generativa con recuperación semántica basada en grafos, implementada mediante PathRAG, constituye una propuesta metodológica innovadora con potencial para fortalecer el aprendizaje adaptativo en entornos virtuales, híbridos e inclusivos. Al generar rutas personalizadas sobre una base curricular estructurada, el sistema facilita una progresión coherente del aprendizaje, ajustada a los errores, necesidades y trayectorias del estudiante.

Sin embargo, las evidencias recogidas deben interpretarse dentro de los límites del diseño metodológico. La ausencia de grupo de control, el muestreo por conveniencia, la duración breve de la intervención, y el uso de instrumentos parcialmente ad hoc limitan la validez interna y externa de los resultados. En este sentido, los hallazgos deben considerarse exploratorios, aunque prometedores, y no como prueba definitiva de eficacia.

A pesar de estas limitaciones, los resultados sugieren que el sistema beneficia especialmente a estudiantes con necesidades educativas diferenciadas, como dificultades de aprendizaje, discapacidades sensoriales o barreras tecnológicas, promoviendo un aprendizaje más equitativo. Esto refuerza su alineación con los Objetivos de Desarrollo Sostenible, en particular con el ODS 4 (educación de calidad) y el ODS 10 (reducción de desigualdades), y subraya su potencial para contribuir a modelos educativos más inclusivos y sostenibles.

Desde el punto de vista técnico, el éxito del sistema depende en gran medida de la calidad y coherencia del grafo de conocimiento. Su construcción requiere procesos exigentes de curación, diseño instruccional y aplicación de técnicas de procesamiento del lenguaje natural. Asimismo, el modelo depende actualmente del uso exclusivo de GPT-3.5-turbo, lo que introduce riesgos de dependencia tecnológica y sesgo algorítmico, así como limitaciones en cuanto a transparencia y control pedagógico.

En cuanto a su aplicabilidad futura, el enfoque PathRAG es escalable y adaptable a otros niveles educativos (como secundaria o formación profesional) y a diferentes áreas disciplinares (humanidades, ciencias sociales o salud), siempre que se cuente con una base documental adecuada y un equipo docente capacitado en alfabetización algorítmica. También puede aplicarse en programas de formación continua, contextos multiculturales y entornos con alta diversidad estudiantil.

En el plano ético, el estudio fue desarrollado bajo los principios del RGPD y la supervisión docente, sin automatizar decisiones evaluativas ni comprometer la agencia del profesorado. No obstante, el avance hacia una educación con IA exige no solo herramientas técnicas, sino marcos claros de gobernanza, auditorías de equidad y formación docente crítica y especializada.

En conclusión, PathRAG no debe entenderse como una solución cerrada ni como un sustituto del rol docente, sino como una herramienta estratégica de apoyo al diseño pedagógico personalizado. Su valor reside en aumentar la capacidad de respuesta de

los sistemas educativos ante la diversidad, facilitar trayectorias formativas ajustadas, y contribuir a un modelo de educación más ético, justo y resiliente. La inteligencia artificial generativa, utilizada de forma crítica y supervisada, puede convertirse en un motor clave para democratizar el acceso al conocimiento y construir ecosistemas educativos más inclusivos y sostenibles.

REFERENCIAS

- Ainscow, M. (2020). *Promoting inclusion and equity in education: Lessons from international experiences*. UNESCO. <https://doi.org/10.1080/20020317.2020.1729587>
- Anderson, T., Borup, J. y West, R. E. (2020). Learning analytics in higher education: A review of the literature. *Journal of Research on Technology in Education*, 52(4), 433-451. <https://doi.org/10.1080/15391523.2020.1739846>
- Bender, E. M., Gebru, T., McMillan-Major, A. y Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 610-623). <https://doi.org/10.1145/3442188.3445922>
- Birhane, A. (2023). Algorithmic injustice: A relational ethics approach. *Patterns*, 4(2), 100693. <https://doi.org/10.1016/j.patter.2023.100693>
- Braun, V. y Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77-101. <https://doi.org/10.1191/1478088706qp0630a>
- Chen, B., Guo, Z., Yang, Z., Chen, Y., Chen, J., Liu, Z., Shi, C. y Yang, C. (2024). PathRAG: Pruning graph-based retrieval augmented generation with relational paths. *arXiv*. <https://doi.org/10.48550/arXiv.2502.14902>
- Chen, X., Wang, L. y Li, Z. (2024). Generative AI in higher education: Ethical and pedagogical considerations for ChatGPT. *AI & Society*. <https://doi.org/10.1007/s00146-024-01720-9>
- Cobo, C., Morales, A. y Navarro, C. (2022). Artificial intelligence in education: Equity and ethics in Latin America. *International Journal of Educational Technology in Higher Education*, 19, 32. <https://doi.org/10.1186/s41239-022-00312-3>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2ª ed.). Lawrence Erlbaum Associates.
- Conati, C., Holstein, K. y Roll, I. (2021). The future of intelligent tutoring systems: A survey. *IEEE Transactions on Learning Technologies*, 14(4), 464-484. <https://doi.org/10.1109/TLT.2021.3071740>
- Conati, C. y Kardan, S. (2013). User modeling in intelligent tutoring systems: A survey. En P. Brusilovsky, G. D. Verbert y P. De Bra (Eds.), *Adaptive and adaptable learning* (pp. 45-63). Springer. https://doi.org/10.1007/978-3-642-40866-0_3
- Floridi, L. (2019). *The ethics of artificial intelligence*. Oxford University Press.
- García-Peñalvo, F. J. (2022). *Tecnología y Educación: Hacia una visión transformadora*. Ediciones Universidad de Salamanca.
- Holmes, W., Porayska-Pomsta, K., Holstein, K. y Rodrigo, M. M. T. (2021). Ethics of AI in education: Towards a community-wide framework. *European Journal of Education*, 56(4), 541-558. <https://doi.org/10.1111/ejed.12481>
- Ifenthaler, D. y Yau, J. Y.-K. (2020). *Utilising learning analytics to support study success in higher education*. Springer. <https://doi.org/10.1007/978-3-319-64792-0>

- Jivet, I., Scheffel, M., Drachsler, H. y Specht, M. (2021). Awareness is not enough: Pitfalls of learning analytics dashboards in the educational practice. *British Journal of Educational Technology*, 52(6), 1864-1880. <https://doi.org/10.1111/bjet.13168>
- Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., ... Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Liang, W., Tadesse, G. A., Ho, D., Li, F., Liu, S., Yu, H. y Sun, J. (2023). Personalized education in the era of big data. *IEEE Transactions on Knowledge and Data Engineering*, 35(3), 2245-2261. <https://doi.org/10.1109/TKDE.2021.3117424>
- Liu, Y., Tamkin, A., Geng, X. y Ganguli, D. (2023). Lost in the middle: How LLMs use long contexts. *Transactions of the Association for Computational Linguistics*, 11, 1200-1218. https://doi.org/10.1162/tacl_a_00606
- Lu, X., van de Sande, B. y Marsh, J. A. (2024). Hybrid learning environments and adaptive support. *Computers & Education*, 210, 104975. <https://doi.org/10.1016/j.compedu.2023.104975>
- Luckin, R., Holmes, W., Griffiths, M. y Forcier, L. B. (2022). *Artificial intelligence and human learning: Partners in progress*. OECD Publishing.
- OECD. (2023). *The OECD AI principles: An overview*. OECD Publishing.
- Pedro, F., Subosa, M., Rivas, A. y Valverde, P. (2021). *Artificial intelligence in education: Challenges and opportunities for sustainable development*. UNESCO.
- Ruipérez-Valiente, J. A., Cobos, R. y Muñoz-Merino, P. J. (2022). Knowledge graphs in education: A systematic literature review. *IEEE Transactions on Learning Technologies*, 15(4), 485-500. <https://doi.org/10.1109/TLT.2022.3190858>
- Selwyn, N., Macgilchrist, F. y Williamson, B. (2023). EdTech and equity: Critical perspectives on the promises of digital education. *Learning, Media and Technology*, 48(1), 1-11. <https://doi.org/10.1080/17439884.2022.2156041>
- Susnjak, T. (2022). ChatGPT: The end of online exam integrity? *arXiv*. <https://doi.org/10.48550/arXiv.2212.09292>
- UNESCO. (2020). *Global education monitoring report 2020: Inclusion and education: All means all*. UNESCO. <https://doi.org/10.54676/JJNK6989>
- UNESCO. (2022). *Reimagining our futures together: A new social contract for education*. UNESCO.
- UNESCO. (2023). *AI and education: Guidance for policy-makers*. <https://unesdoc.unesco.org/ark:/48223/pf0000384803>
- van de Sande, B., Marsh, J. A. y Lu, X. (2023). Large language models in education: Opportunities and challenges. *Computers & Education: Artificial Intelligence*, 4, 100132. <https://doi.org/10.1016/j.caeai.2023.100132>
- Zawacki-Richter, O., Marín, V. I., Bond, M. y 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, 39. <https://doi.org/10.1186/s41239-019-0171-0>
- Zhang, D. y Wang, X. (2025). Adaptive learning systems: A review and future directions. *Journal of Educational Technology & Society*, 28(1), 1-15.
- Zhang, D., Wang, X. y Chen, X. (2021). Adaptive learning technologies in higher education: A meta-analysis of effectiveness. *Educational Research*

Review, 33, 100390. <https://doi.org/10.1016/j.edurev.2021.100390>
Zhou, M. y Wang, D. (2020). Ethical considerations in AI-supported education: A perspective from responsible innovation. *AI & Society*, 35(3), 601-611. <https://doi.org/10.1007/s00146-019-0910-1>

Fecha de recepción del artículo: 1 de junio de 2025

Fecha de aceptación del artículo: 11 de agosto de 2025

Fecha de aprobación para maquetación: 15 de septiembre de 2025

Fecha de publicación en OnlineFirst: 12 de octubre de 2025

Fecha de publicación: 1 de enero de 2026