apertura
Volumen 18, número 1, pp. 90-101 | Universidad de Guadalajara
http://doi.org/10.32870/Ap.v18n2.2882

Sistema de apoyo docente con inteligencia artificial para personalizar el aprendizaje universitario

Artificial Intelligence-Based Teaching Support System for Personalized Learning in Higher Education

Javier Bárcenas Rosas*
Universidad Iberoamericana, Universidad CENTRO, México
http://orcid.org/0009-0002-6878-5660

María Eugenia Gil Rendón**
Tecnológico de Monterrey, México
https://orcid.org/0009-0003-2852-6725

Recepción del artículo: 29/03/2026 | Aceptación para publicación: 22/09/2026 | Publicación: 30/09/2026

RESUMEN

El objetivo de este estudio fue diseñar y valorar un sistema de apoyo docente impulsado por inteligencia artificial capaz de traducir perfiles multidimensionales de aprendizaje en recomendaciones didácticas y de evaluación para educación superior. La propuesta integró cinco dimensiones diagnósticas: VARK, para preferencias de acceso a la información; FSLSM, para rasgos de procesamiento y representación; ICAP, para niveles de compromiso cognitivo; SRL, para autorregulación del aprendizaje; y EBSI, para hábitos de estudio. Se empleó un enfoque mixto secuencial explicativo. En la fase cuantitativa se aplicó un cuestionario digital a 145 estudiantes de cinco universidades y se procesaron los datos mediante un sistema desarrollado en Python, que generó perfiles diagnósticos y reportes pedagógicos personalizados para el profesorado. En la fase cualitativa, cuatro docentes valoraron la utilidad, coherencia percibida, factibilidad y aceptabilidad ética de los reportes. Los resultados mostraron convergencia sustantiva entre el diagnóstico calculado sin IA y la narrativa generada con IA en dimensiones como VARK e ICAP, así como una aceptación favorable por parte del profesorado. Sin embargo, se identificaron desajustes en la calibración de FSLSM y en la intensidad atribuida a SRL y EBSI. Se concluye que la IA puede mediar decisiones docentes bajo supervisión pedagógica.

Palabras clave
Inteligencia artificial; educación superior; estilos de aprendizaje; personalización del aprendizaje; apoyo docente

ABSTRACT

The aim of this study was to design and evaluate an artificial intelligence-driven teacher support system capable of translating multidimensional learning profiles into instructional and assessment recommendations for higher education. The proposal integrated five diagnostic dimensions: VARK, for preferences in accessing information; FSLSM, for processing and representation traits; ICAP, for levels of cognitive engagement; SRL, for self-regulated learning; and EBSI, for study habits. An explanatory sequential mixed-methods approach was used. In the quantitative phase, a digital questionnaire was administered to 145 students from five universities, and the data were processed through a system developed in Python, which generated diagnostic profiles and personalized pedagogical reports for teachers. In the qualitative phase, four instructors evaluated the usefulness, perceived coherence, feasibility, and ethical acceptability of the reports. The results showed substantial convergence between the diagnosis calculated without AI and the narrative generated with AI in dimensions such as VARK and ICAP, as well as favorable acceptance by the teaching staff. However, mismatches were identified in the calibration of FSLSM and in the intensity attributed to SRL and EBSI. It is concluded that AI can mediate instructional decision-making under pedagogical supervision.

Keywords
Artificial intelligence; Higher education; Learning styles; Personalized learning; Teacher support

SOBRE LOS AUTORES

* Doctorante en Educación Multimodal por la Universidad Autónoma de Querétaro. Profesor de la UNAM, Universidad Iberoamericana, Universidad CENTRO, México. ORCID: http://orcid.org/0009-0002-6878-5660, correoelectrónico: jbarcenasr1@gmail.com

** Doctora en Evaluación Educativa por la Universidad Anáhuac.Profesora de tiempo completo del Tecnológico de Monterrey, México. https://orcid.org/0009-0003-2852-6725, correo electrónico: maru.gil@tec.mx

INTRODUCCIÓN

La educación superior enfrenta el reto de responder a grupos cada vez más heterogéneos, en los que las diferencias no solo se observan en conocimientos previos, sino también en la forma en que el estudiantado percibe, procesa, organiza y aplica la información. En este escenario, la personalización de la enseñanza deja de ser un ideal abstracto y se convierte en una necesidad pedagógica. Sin embargo, aunque muchos docentes reconocen la diversidad de sus grupos, no siempre cuentan con instrumentos que les permitan traducir esa diversidad en decisiones concretas de planeación, mediación didáctica y evaluación. Como advierte Shulman (1987), el saber disciplinar del profesor no basta por sí mismo si no se articula con un conocimiento pedagógico del contenido; por ello, disponer de apoyos que faciliten esa traducción resulta especialmente relevante en contextos universitarios.

El problema que atiende este estudio radica en la limitada disponibilidad de sistemas que integren información diagnóstica del alumnado y la transformen en orientaciones pedagógicas útiles, viables y éticamente responsables para la docencia. Aunque existen aproximaciones adaptativas en educación, gran parte de ellas se ha concentrado en el estudiante como usuario final del sistema, y con menor frecuencia en el docente como actor que interpreta, decide y contextualiza la enseñanza (Brusilovsky, 2001; Brusilovsky & Millán, 2007). Esta ausencia es significativa porque el profesorado universitario suele enfrentar restricciones de tiempo, grupos numerosos y exigencias institucionales que dificultan la personalización sostenida sin apoyo sistemático.

La investigación se justifica porque un sistema de apoyo docente basado en perfiles de aprendizaje puede fortalecer la adecuación de las estrategias didácticas y de evaluación, haciendo más factible una personalización pedagógica realista. En coherencia con ello, el objetivo general consistió en diseñar y valorar un sistema de apoyo docente basado en los modelos VARK, FSLSM, ICAP, SRL y EBSI, con el fin de identificar perfiles de aprendizaje de estudiantes universitarios y generar, mediante inteligencia artificial, recomendaciones personalizadas para la planeación y la evaluación. La hipótesis de trabajo planteó que la implementación del sistema mejoraría la adecuación de las estrategias didácticas y de evaluación,

favoreciendo una enseñanza más personalizada y eficaz. Desde esta perspectiva, la IA no se concibe como sustituto del docente, sino como una herramienta de mediación que apoya decisiones pedagógicas informadas y contextualizadas (Luckin *et al.*, 2016; Unesco, 2021).

Marco teórico o revisión de la literatura

La base conceptual del estudio parte de la premisa de que la diversidad del aprendizaje no puede explicarse desde una sola variable. Uno de los marcos más conocidos es VARK, propuesto por Fleming y Mills (1992), que organiza las preferencias de acceso a la información en modalidades visual, auditiva, lectura-escritura y kinestésica. Aunque este modelo ha sido objeto de debate cuando se utiliza de manera rígida o prescriptiva, su valor pedagógico permanece cuando se emplea como punto de partida para ampliar formatos de representación y reflexión didáctica (Fleming, 2006). En esa lógica, VARK no se asumió como una etiqueta cerrada, sino como un indicador inicial sobre formas preferentes de acceso al contenido.

El modelo de Felder y Silverman (1988) permitió complementar esta mirada al incorporar dimensiones relacionadas con el procesamiento y la organización del aprendizaje, tales como activo-reflexivo, sensorial-intuitivo, visual-verbal y secuencial-global. Este aporte es relevante porque la personalización no solo implica decidir cómo presentar la información, sino también cómo estructurar las experiencias de aprendizaje. En paralelo, el marco ICAP plantea que la profundidad del aprendizaje depende del nivel de compromiso cognitivo alcanzado por el estudiante, pasando de la participación pasiva a la activa, constructiva e interactiva (Chi & Wylie, 2014). Esta teoría aporta una base sólida para traducir perfiles diagnósticos en decisiones sobre tipos de actividad, nivel de elaboración y formas de interacción en el aula.

A la dimensión perceptivo-cognitiva se suman variables asociadas con la autorregulación y los hábitos de estudio. Zimmerman (2000, 2002) ha mostrado que el aprendizaje autorregulado involucra procesos de planeación, monitoreo y reflexión, indispensables para sostener el rendimiento académico. De forma complementaria, los instrumentos derivados de LASSI permiten observar prácticas concretas relacionadas con organización, repaso, gestión del tiempo y control de la postergación (Weinstein *et al.*, 2016). Incorporar SRL y EBSI en el sistema permitió evitar una personalización limitada al formato del contenido y avanzar hacia recomendaciones metacognitivas y conductuales con mayor utilidad pedagógica.

La integración de estas dimensiones permitió que el sistema no se limitara al formato de presentación del contenido, sino que incorporara también niveles de participación cognitiva, hábitos de estudio y autorregulación (ver tabla 1).

En cuanto a la inteligencia artificial en educación, la literatura ha documentado el potencial de los sistemas adaptativos para ajustar contenidos, trayectorias e intervenciones a partir de perfiles del usuario (Brusilovsky & Millán, 2007; Shute & Zapata-Rivera, 2012). No obstante, también se ha insistido en que la IA educativa debe operar bajo principios éticos, transparencia y supervisión humana, especialmente cuando interviene en procesos sensibles de enseñanza y evaluación (Holmes *et al.*, 2019; Khosravi *et al.*, 2022; Unesco, 2021). El presente estudio dialoga con esa línea, pero desplaza el foco del usuario-estudiante al usuario-docente: la IA se plantea aquí como un mecanismo de traducción pedagógica que ayuda al profesorado a interpretar perfiles y convertirlos en decisiones viables para su contexto de aula.

Entre los estudios con propósitos próximos, van Leeuwen (2019) mostró que los reportes de *learning analytics* pueden apoyar el diagnóstico y la intervención docente, aunque la traducción de la información en acciones concretas no siempre resulta directa. Khosravi *et al.*, (2021) desarrollaron *dashboards* inteligentes con un enfoque *human-in-the-loop* para apoyar la exploración de datos por parte del profesor. En una revisión

Tabla 1. Dimensiones diagnósticas integradas en el sistema

Dimensión	Función en el diagnóstico	Aporte al reporte docente	Referencia base
VARK	Acceso perceptivo a la información	Sugiere formatos iniciales de presentación de contenidos	Fleming & Mills (1992); Fleming (2006)
FSLSM	Procesamiento y representación	Aporta balance entre explicación, secuencia, abstracción y práctica	Felder & Silverman (1988)
ICAP	Nivel de compromiso cognitivo	Orienta sobre el tipo de actividad y profundidad de participación	Chi & Wylie (2014)
SRL	Autorregulación del aprendizaje	Genera sugerencias de planeación, monitoreo y autorreflexión	Zimmerman (2002)
EBSI	Hábitos de estudio	Añade orientaciones sobre repaso, práctica activa y organización	Weinstein *et al.* (2016)

Fuente: elaboración propia

de 50 estudios, Kaliisa *et al.* (2023) encontraron que estas herramientas suelen evaluarse mediante percepciones de los usuarios y que todavía es limitada la evidencia sobre efectos en la práctica docente y el aprendizaje. Más recientemente, Kinder *et al.,* (2025) reportaron que la retroalimentación generada por un modelo de lenguaje fue valorada como útil y mejoró algunos componentes del desempeño, pero no produjo diferencias significativas en la precisión de las decisiones. Estos antecedentes permiten contrastar tanto el enfoque del presente estudio como sus criterios de valoración.

METODOLOGÍA

El estudio se desarrolló bajo un enfoque mixto secuencial explicativo, el cual permitió articular una fase cuantitativa de diagnóstico con una fase cualitativa de valoración experta del sistema y de los reportes generados. Este diseño resulta pertinente cuando se busca no solo identificar patrones en los datos, sino también comprender la utilidad práctica de un artefacto educativo desde la perspectiva de quienes podrían implementarlo (Creswell & Plano Clark, 2017).

La población estuvo conformada por estudiantes universitarios y docentes de educación superior. La muestra cuantitativa incluyó 145 estudiantes procedentes de cinco universidades. Para la fase cualitativa participaron cuatro docentes seleccionados mediante muestreo intencional y por conveniencia, privilegiando a profesores con posibilidad de revisar el diagnóstico, contrastarlo con su experiencia de aula y valorar la pertinencia de las recomendaciones generadas (Valenzuela González & Flores Fahara, 2011).

El instrumento se implementó en Google Forms y reunió reactivos organizados en cinco dimensiones: VARK, FSLSM, ICAP, SRL y EBSI. Las respuestas se concentraron en una hoja de cálculo y posteriormente fueron procesadas mediante un sistema desarrollado en Python. Dicho sistema calculó perfiles individuales y generó una consulta a un modelo conversacional para producir reportes pedagógicos personalizados. Estos reportes incluyeron orientaciones para la planeación didáctica, sugerencias de evaluación y recomendaciones sobre mediación pedagógica, organización del estudio y participación cognitiva.

Para generar los reportes narrativos se utilizó GPT-4 de OpenAI mediante su API, integrada al sistema desarrollado en Python. La configuración empleó una temperatura de 0.7 y un *prompt* estructurado que solicitaba diagnóstico del perfil, sugerencias de enseñanza, actividades, una clase muestra de 50 minutos, tareas y recomendaciones

de evaluación. GPT-4 se eligió por su disponibilidad mediante API y su capacidad para seguir instrucciones estructuradas y producir texto contextualizado. El estudio no comparó su desempeño con otros modelos y utilizó el alias gpt-4 disponible en la API, sin registrar un *snapshot* específico.

El procedimiento siguió cuatro etapas. Primero, se aplicó el cuestionario digital a estudiantes universitarios. Segundo, se procesaron los datos para obtener perfiles cuantitativos por dimensión. Tercero, el sistema generó reportes narrativos personalizados con apoyo de IA. Cuarto, dichos reportes fueron valorados por docentes a partir de criterios de utilidad, coherencia percibida, factibilidad y aceptabilidad ética. Conviene señalar que esta fase no buscó medir todavía el efecto de la intervención en el rendimiento académico, sino valorar la aceptabilidad y coherencia del sistema como herramienta de apoyo. Los criterios se interpretaron de la siguiente manera: utilidad, posibilidad de convertir las recomendaciones en decisiones de enseñanza; coherencia percibida, correspondencia entre el reporte y los rasgos observados por el docente; factibilidad, posibilidad de aplicar las sugerencias en las condiciones habituales; y aceptabilidad ética, ausencia percibida de lenguaje discriminatorio o estigmatizante y respeto al juicio profesional del docente.

Para el análisis cuantitativo se tomaron como referencia dos estudios de caso ilustrativos (ver tabla 2), en los cuales se comparó el diagnóstico calculado sin IA con la narrativa producida por IA, dimensión por dimensión. Esta comparación permitió examinar la trazabilidad entre los indicadores cuantitativos y la interpretación pedagógica final, aspecto relevante en modelos generativos cuyas salidas requieren verificación y supervisión humana (Kasneci *et al*., 2023). El veredicto se clasificó como alineado cuando la narrativa conservó el sentido del indicador; parcial cuando mantuvo la dirección general pero modificó su intensidad; no sustentado cuando introdujo una afirmación sin respaldo en el diagnóstico; y omisión cuando dejó fuera información relevante disponible.

RESULTADOS

Los resultados mostraron que el sistema fue capaz de construir perfiles de aprendizaje funcionales a partir de la integración de múltiples dimensiones diagnósticas. En los casos analizados, la convergencia entre el diagnóstico calculado sin IA y la narrativa generada con IA fue más sólida en VARK e ICAP. Esta coincidencia resulta relevante porque ambas dimensiones se traducen de manera relativamente directa en decisiones pedagógicas: la primera orienta sobre formatos de presentación del contenido y la segunda sobre el nivel de exigencia cognitiva promovido por las actividades (Chi & Wylie, 2014; Fleming, 2006).

En contraste, se detectaron áreas de ajuste en FSLSM y en la intensidad narrativa atribuida a SRL y EBSI. En algunos perfiles, la IA tendió a acentuar inclinaciones que en los datos aparecían más equilibradas o a omitir matices importantes cuando la distribución entre polos era cercana (ver tabla 2). Este hallazgo sugiere que la interpretación generativa puede conservar el sentido general del perfil, pero no necesariamente su proporcionalidad interna, lo que representa un riesgo si el reporte se asume como diagnóstico definitivo sin revisión humana.

A pesar de esas tensiones, los reportes mostraron valor pedagógico preliminar. Cuando la narrativa permaneció anclada a los indicadores cuantitativos, las recomendaciones fueron percibidas por los docentes como útiles para seleccionar materiales, ajustar tipos de actividad y definir formas de acompañamiento. En la fase cualitativa, el profesorado participante valoró positivamente la claridad de los reportes, su pertinencia general y su viabilidad para apoyar decisiones inmediatas de enseñanza. Asimismo, consideró que el tratamiento de la información era ético y respetuoso, y que varias sugerencias coincidían con observaciones previas sobre sus grupos (ver tabla 3).

Tabla 2. Comparativa entre diagnóstico sin IA versus con IA

Dimensión	Resultado sin IA	Versión generada con IA	Veredicto
VARK	V=2, A=0, R/W=0, K=1 → Dominante Visual; K secundario.	"Aprendiz visual y kinestésica."	Parcial (dirección correcta, intensidad sobrada en K).
FSLSM – Sensorial	Sensorial +2.	"Prefiere casos reales antes que teoría."	Alineado.
FSLSM – Visual	Visual +2.	"Se beneficia de diagramas, gráficos e imágenes."	Alineado.
FSLSM – Secuencial	Secuencial +2.	"Necesita pasos ordenados y rutas lógicas cortas."	Alineado.
FSLSM – Activo/ Reflexivo	Equilibrado (0).	(No declara polo explícito).	Alineado (no hay afirmación de polo).
ICAP	P=20%, A=10%, C=30%, I=40% → Predomina Interactivo con base Constructiva; Activo es el menor.	"Tendencia activa e interactiva; aprende mejor al discutir y generar ejemplos."	Parcial (interactivo sí; "activa" está sobredicha).
Preferencia por trabajar primero en forma independiente	Sin indicador directo; ICAP Interactivo alto sugiere disposición colaborativa.	"Prefiere trabajar de forma independiente antes de compartir."	No sustentado (y potencialmente inconsistente con I alto).
EBSI / SRL	EBSI 3.33/4; SRL 3.38/4 → hábitos y autorregulación altos.	(No se menciona).	Omisión.

Fuente: elaboración propia

Tabla 3. Juicios docentes por criterio y citas representativas (percepción; sin implementación)

Criterio	Juicio sintetizado	Cita representativa (docente)
Utilidad	Las recomendaciones se perciben como accionables y pertinentes para planear sesiones.	El docente afirma que los reportes sí le brindan herramientas útiles para atender mejor las necesidades específicas de los estudiantes. Destaca que las recomendaciones le permiten identificar formas de mejorar su práctica y ajustar la enseñanza según el estilo o estructura de razonamiento del alumno. Señala explícitamente: "sí me dan herramientas para atender mejor las necesidades específicas de los alumnos"
Coherencia	El diagnóstico y las sugerencias muestran congruencia con rasgos observados del grupo.	La docente comenta que conoce bien a los estudiantes (les dio clase en 2°, 5° y 7° semestre) y que encuentra los reportes congruentes con lo que ha observado de su personalidad y estilo de trabajo. Aunque solo los ve una vez por semana por su modalidad semiescolarizada, señala que percibe una clara vinculación entre el reporte y las características observadas del alumnado
Factibilidad	Se considera viable aplicar al menos una estrategia, pero no se probó en aula.	Altamente factibles, todas son recomendaciones aterrizadas. No ameritan importantes cambios para aplicarlos en clase
Ética	Tratamiento respetuoso y no estigmatizante de la información estudiantil.	El docente señala que revisó con detalle los reportes y que "no vi ninguna parte que pudiera ser malinterpretada o con sesgo", destacando que la información se presenta de forma respetuosa y sin expresiones discriminatorias

Fuente: elaboración propia

En conjunto, los hallazgos respaldan la hipótesis en términos de adecuación potencial y coherencia diagnóstica; el sistema no demostró aún un impacto directo en el aprendizaje de los estudiantes, pero sí mostró capacidad para ofrecer recomendaciones pedagógicas

En conjunto, los hallazgos respaldan la hipótesis en términos de adecuación potencial y coherencia diagnóstica. El sistema no demostró aún un impacto directo en el aprendizaje de los estudiantes, pero sí mostró capacidad para ofrecer recomendaciones pedagógicas razonablemente alineadas con perfiles estructurados y para ser aceptado por el profesorado.

DISCUSIÓN

Los resultados permiten sostener que una aproximación multidimensional aporta más valor pedagógico que aquellas centradas en una sola variable. Mientras VARK ofrece una puerta de entrada sobre el formato de acceso a la información, la incorporación de ICAP, SRL y EBSI amplía la personalización hacia el tipo de actividad, el acompañamiento metacognitivo y los hábitos de estudio que sostienen el aprendizaje (Chi & Wylie, 2014; Weinstein *et al*., 2016; Zimmerman, 2002). Esto implica que la personalización no debe reducirse a adaptar materiales, sino a orientar decisiones integrales sobre cómo enseñar y cómo acompañar el estudio.

Los desajustes detectados en FSLSM y en la intensidad atribuida a SRL y EBSI también confirman lo señalado en la literatura sobre la necesidad de supervisión humana en sistemas de IA educativa. Como advierten Holmes *et al*., (2019) y UNESCO (2021), el valor de la IA no reside en sustituir el juicio pedagógico, sino en ampliar la capacidad de análisis e interpretación de quienes enseñan. En este estudio, la utilidad del sistema fue mayor cuando la narrativa generada operó como apoyo para la reflexión docente y no como prescripción cerrada.

Desde una perspectiva institucional, este hallazgo es particularmente relevante para la educación superior. Muchos docentes universitarios cuentan con sólida formación disciplinar, pero con trayectorias pedagógicas heterogéneas. En ese contexto, disponer de un sistema que traduzca información diagnóstica en recomendaciones aplicables puede fortalecer la planeación instruccional y la evaluación sin exigir al profesor un dominio experto previo de todos los modelos implicados (Laurillard, 2012; Shulman, 1987). Así, la IA funciona menos como automatización de la enseñanza y más como mediación para la toma de decisiones.

Al mismo tiempo, la discusión obliga a matizar el alcance de la personalización. En contextos con grupos numerosos y alta carga docente, la adaptación completamente individualizada puede resultar difícilmente sostenible. Por ello, una proyección razonable de este tipo de sistemas no consiste solo en producir recomendaciones por estudiante, sino también en identificar patrones, subgrupos o *clusters* que faciliten una personalización viable y estratégicamente manejable para el profesorado.

La valoración favorable de los docentes debe interpretarse con cautela. Kaliisa *et al.,* (2023) advierten que la evaluación de herramientas analíticas dirigidas al profesorado se apoya con frecuencia en percepciones y autoinformes, mientras que Kinder *et al.,* (2025) mostraron que una mayor utilidad percibida de la retroalimentación generada por IA no implicó necesariamente una mayor precisión de las decisiones. Por ello, los resultados del presente estudio se interpretan

como evidencia inicial de utilidad, coherencia y factibilidad, no como demostración de efectividad educativa.

CONCLUSIONES

El estudio muestra que es posible diseñar un sistema de apoyo docente impulsado por inteligencia artificial que traduzca perfiles multidimensionales de aprendizaje en recomendaciones pedagógicas personalizadas para educación superior. La integración de VARK, FSLSM, ICAP, SRL y EBSI permitió construir perfiles más ricos que los obtenidos desde una sola dimensión y ofrecer al profesorado insumos concretos para la planeación didáctica y la evaluación.

Los hallazgos respaldan la hipótesis en términos funcionales y de coherencia interpretativa. El sistema mostró capacidad para generar recomendaciones útiles y aceptables para el profesorado, especialmente cuando la narrativa se mantuvo anclada a los indicadores cuantitativos. En ese sentido, la principal aportación del estudio consiste en desplazar el foco de la IA educativa hacia el apoyo a la mediación docente, más que hacia la automatización directa del aprendizaje del estudiante.

Además de ello, los resultados permiten afirmar que el valor del sistema no radica únicamente en su capacidad técnica para procesar datos y generar reportes, sino en su potencial para traducir información compleja en orientaciones pedagógicas comprensibles y utilizables por el docente. En muchos contextos universitarios, el profesorado reconoce la diversidad de sus grupos, pero enfrenta dificultades para convertir esa percepción general en decisiones concretas de enseñanza. Desde esta perspectiva, el sistema propuesto actúa como un mediador entre el diagnóstico y la práctica, al ofrecer una interpretación estructurada de los perfiles estudiantiles y transformarla en sugerencias aplicables a la planeación, la interacción en clase y la evaluación. Esta función de traducción pedagógica constituye una aportación relevante, porque acerca el uso de la inteligencia artificial a necesidades reales del trabajo docente y evita que permanezca como una herramienta abstracta o ajena a la dinámica cotidiana del aula. Esta función de traducción entre información y acción docente coincide con la necesidad de generar conocimiento accionable señalada por van Leeuwen (2019) y con los enfoques de apoyo a la decisión docente descritos por Khosravi *et al.,* (2021).

Asimismo, la investigación pone de manifiesto que la personalización de la enseñanza en educación superior requiere enfoques más amplios que los sustentados en una sola dimensión de análisis. Si bien modelos como VARK ofrecen una puerta de entrada útil para pensar en formatos de presentación de la información, por sí solos resultan insuficientes para orientar una intervención pedagógica más completa. La incorporación de dimensiones como ICAP, SRL y EBSI permitió ampliar la comprensión del aprendizaje hacia niveles de participación cognitiva, hábitos de estudio y procesos de autorregulación, lo que hace posible diseñar recomendaciones más integrales. En otras palabras, el sistema no se limita a sugerir cómo presentar contenidos, sino que

Los resultados permiten afirmar que el valor del sistema no radica únicamente en su capacidad técnica para procesar datos y generar reportes, sino en su potencial para traducir información compleja en orientaciones pedagógicas comprensibles

aporta elementos para decidir cómo promover una participación más activa, cómo acompañar la organización del estudio y cómo fortalecer la autonomía del estudiante. Esta mirada multidimensional representa una ventaja importante frente a propuestas más reduccionistas, ya que reconoce la complejidad del aprendizaje universitario y la necesidad de responder a ella desde varios frentes de acción pedagógica.

De igual manera, el estudio permite subrayar la importancia de conservar al docente como figura central en cualquier proceso de personalización apoyado por inteligencia artificial. Los hallazgos mostraron que la IA puede generar recomendaciones valiosas, pero también evidenciaron que dichas recomendaciones adquieren sentido pedagógico pleno únicamente cuando son interpretadas, ajustadas y contextualizadas por el profesorado. Esto significa que el sistema no debe entenderse como un mecanismo de sustitución del juicio docente, sino como una herramienta que amplía su capacidad de análisis y de toma de decisiones. En este sentido, una de las contribuciones conceptuales más importantes de la investigación consiste en proponer una visión de la IA educativa centrada en el apoyo a la mediación pedagógica. Esta perspectiva resulta especialmente pertinente en un momento en que muchas discusiones sobre inteligencia artificial en educación se concentran en la automatización, mientras que este trabajo pone el acento en el fortalecimiento del rol docente como intérprete, diseñador y acompañante del aprendizaje. Esta centralidad del juicio profesional es consistente con los principios de transparencia, explicabilidad y supervisión humana propuestos para la IA educativa (Khosravi *et al.,* 2022).

Los resultados sugieren que un sistema de esta naturaleza puede constituir un recurso valioso para apoyar la toma de decisiones en la docencia universitaria, especialmente en grupos numerosos, diversidad de perfiles y limitaciones de tiempo para realizar un seguimiento individual profundo

En términos prácticos, los resultados sugieren que un sistema de esta naturaleza puede constituir un recurso valioso para apoyar la toma de decisiones en la docencia universitaria, especialmente en escenarios donde existen grupos numerosos, diversidad de perfiles y limitaciones de tiempo para realizar un seguimiento individual profundo. La posibilidad de disponer de reportes que organicen información diagnóstica y la conviertan en sugerencias concretas puede ayudar al profesorado a planear con mayor intencionalidad, a seleccionar estrategias de mediación más pertinentes y a considerar de manera más explícita las diferencias entre estudiantes. Si bien esto no sustituye la experiencia del docente ni la necesidad de observar el contexto real del grupo, sí puede fortalecer la calidad de sus decisiones y contribuir a una enseñanza más sensible a la diversidad del aula.

Entre las principales limitaciones del estudio se encuentran la ausencia de implementación prolongada en aula, el tamaño reducido de la muestra docente en la fase cualitativa y la necesidad de refinar la calibración de algunas dimensiones, particularmente FSLSM, SRL y EBSI. Estas restricciones no invalidan los hallazgos, pero sí acotan su alcance y exigen cautela al generalizar los resultados. Del mismo modo, debe reconocerse que la valoración positiva del sistema se refiere principalmente a su utilidad percibida, su coherencia diagnóstica y su factibilidad inicial, pero no constituye todavía evidencia suficiente sobre su impacto directo en el aprendizaje, el rendimiento académico o la

permanencia estudiantil. Por ello, los resultados deben leerse como una demostración de viabilidad pedagógica y no como una prueba concluyente de efectividad educativa en sentido amplio.

También es importante señalar que el uso de modelos generativos en educación demanda mecanismos más robustos de trazabilidad, supervisión y validación. Uno de los hallazgos más relevantes del estudio fue que, aunque la IA tendió a conservar el sentido general de los perfiles, en algunas dimensiones produjo sobredimensionamientos, omisiones o interpretaciones que no siempre reflejaron con precisión la proporción de los datos de entrada. Esta observación es crucial porque pone de relieve que la calidad de la personalización no depende solo de la potencia tecnológica del sistema, sino de la claridad de las reglas que orientan su interpretación, de la calidad de los insumos diagnósticos y del papel activo del docente en la revisión de los resultados. En consecuencia, cualquier implementación futura deberá considerar no solo mejoras algorítmicas, sino también marcos pedagógicos y éticos que garanticen un uso responsable de la inteligencia artificial en contextos educativos.

A nivel institucional, la investigación también abre posibilidades que trascienden el uso individual del sistema. Una herramienta de este tipo podría contribuir a generar panoramas grupales o cohortes de aprendizaje que permitan identificar tendencias comunes, necesidades recurrentes y oportunidades de intervención en programas académicos completos. Esto podría tener implicaciones valiosas para la tutoría, la formación docente, el acompañamiento académico y, eventualmente, el rediseño curricular. Aunque estas aplicaciones requieren mayor desarrollo y validación, los resultados sugieren que el sistema puede ser pensado no solo como un recurso puntual para un curso o profesor, sino como una base para estrategias institucionales más amplias de atención a la diversidad del aprendizaje.

Como líneas futuras de investigación, será necesario evaluar la implementación real de las recomendaciones en aula, estimar su efecto sobre el aprendizaje y explorar esquemas de personalización por *clusters* que reduzcan la carga operativa del profesorado. También convendrá fortalecer los mecanismos de trazabilidad entre indicadores cuantitativos y narrativa generada, a fin de mejorar la precisión interpretativa y la transparencia del sistema. De manera complementaria, sería pertinente ampliar la muestra de docentes y contextos institucionales, incorporar evaluaciones longitudinales y analizar en qué medida la utilización sostenida del sistema modifica prácticas de planeación, interacción y evaluación en educación superior. Asimismo, resultará relevante estudiar cómo este tipo de herramientas puede articularse con otras formas de analítica educativa y con modelos de acompañamiento institucional, sin perder de vista la necesidad de proteger los datos del estudiantado y de preservar el juicio profesional del docente como eje central del proceso pedagógico.

La investigación permite concluir que la inteligencia artificial puede aportar valor significativo a la educación superior cuando se orienta al fortalecimiento de la mediación docente y no a la sustitución de la acción pedagógica humana

En conjunto, la investigación permite concluir que la inteligencia artificial puede aportar valor significativo a la educación superior cuando se orienta al fortalecimiento de la mediación docente y no a la sustitución de la acción pedagógica humana. El sistema propuesto constituye

una evidencia inicial de que es posible traducir perfiles multidimensionales de aprendizaje en recomendaciones didácticas útiles, comprensibles y potencialmente aplicables. Su mayor aportación no radica únicamente en la innovación tecnológica, sino en la posibilidad de tender un puente entre diagnóstico, interpretación y acción educativa. Desde esta perspectiva, el estudio no solo muestra la viabilidad de una herramienta específica, sino que propone una forma de concebir la innovación educativa: técnicamente sólida, pedagógicamente pertinente y humanamente responsable.

AGRADECIMIENTOS

El autor agradece a las y los docentes participantes, así como a las instituciones que facilitaron la aplicación del instrumento.

REFERENCIAS

Brusilovsky, P. (2001). Adaptive hypermedia. *User Modeling and User-Adapted Interaction,* 11(1-2), 87-110. https://doi.org/10.1023/A:1011143116306

Brusilovsky, P., & Millán, E. (2007). User models for adaptive hypermedia and adaptive educational systems. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Eds.), *The adaptive web* (pp. 3-53). Springer. https://doi.org/10.1007/978-3-540-72079-9_1

Chi, M. T. H., & Wylie, R. (2014). The ICAP framework: Linking cognitive engagement to active learning outcomes. *Educational Psychologist*, 49(4), 219-243. https://doi.org/10.1080/00461520.2014.965823

Creswell, J. W., & Plano Clark, V. L. (2017). *Designing and conducting mixed methods research* (3rd ed.). SAGE.

Felder, R. M., & Silverman, L. K. (1988). Learning and teaching styles in engineering education. *Engineering Education,* 78(7), 674-681.

Fleming, N. D. (2006). *Teaching and learning styles: VARK strategies* (2nd ed.). N. D. Fleming.

Fleming, N. D., & Mills, C. (1992). Not another inventory, rather a catalyst for reflection. *To Improve the Academy*, 11(1), 137-155. https://doi.org/10.1002/j.2334-4822.1992.tb00213.x

Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning. Center for Curriculum Redesign.*

Kaliisa, R., Jivet, I., & Prinsloo, P. (2023). A checklist to guide the planning, designing, implementation, and evaluation of learning analytics dashboards. *International Journal of Educational Technology in Higher Education*, 20, Article 28. https://doi.org/10.1186/s41239-023-00394-6

Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günnemann, 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

Khosravi, H., Shabaninejad, S., Bakharia, A., Sadiq, S., Indulska, M., & Gašević, D. (2021). Intelligent learning analytics dashboards: Automated drill-down recommendations to support teacher data exploration. *Journal of Learning Analytics,* 8(3), 133-154. https://doi.org/10.18608/jla.2021.7279

Khosravi, H., Shum, S. B., Chen, G., Conati, C., Tsai, Y.-S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Gašević, D. (2022). Explainable artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 3, 100074. https://doi.org/10.1016/j.caeai.2022.100074

Kinder, A., Briese, F. J., Jacobs, M., Dern, N., Glodny, N., Jacobs, S., & Leßmann, S. (2025). Effects of adaptive feedback generated by a large language model: A case study in teacher education. *Computers and Education: Artificial Intelligence*, 8, 100349. https://doi.org/10.1016/j.caeai.2024.100349

Laurillard, D. (2012). *Teaching as a design science: Building pedagogical patterns for learning and technology*. Routledge.

Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson.

Shulman, L. S. (1987). Knowledge and teaching: Foundations of the new reform. *Harvard Educational Review*, 57(1), 1-23. https://doi.org/10.17763/haer.57.1.j463w79r56455411

Shute, V. J., & Zapata-Rivera, D. (2012). Adaptive educational systems. In P. J. Durlach & A. M. Lesgold (Eds.), *Adaptive technologies for training and education* (pp. 7-27). Cambridge University Press. https://doi.org/10.1017/CBO9781139049580.004

Unesco. (2021). *Reimagining our futures together: A new social contract for education.* https://doi.org/10.54675/ASRB4722

Valenzuela González, J. R., & Flores Fahara, M. (2011). *Fundamentos de investigación educativa (Vol. 2: El proceso de investigación educativa).* Editorial Digital del Tecnológico de Monterrey.

van Leeuwen, A. (2019). Teachers' perceptions of the usability of learning analytics reports in a flipped university course: When and how does information become actionable knowledge? *Educational Technology Research and Development*, 67(5), 1043-1064. https://doi.org/10.1007/s11423-018-09639-y

Weinstein, C. E., Palmer, D. R., & Acee, T. W. (2016). *Learning and Study Strategies Inventory (LASSI): User's manual* (3rd ed.). H&H Publishing.

Zimmerman, B. J. (2000). Attaining self-regulation: A social cognitive perspective. In M. Boekaerts, P. R. Pintrich, & M. Zeidner (Eds.), *Handbook of self-regulation* (pp. 13-39). Academic Press. https://doi.org/10.1016/B978-012109890-2/50031-7

Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, 41(2), 64-70. https://doi.org/10.1207/S15430421TIP4102_2

Este artículo es de acceso abierto. Los usuarios pueden leer, descargar, distribuir, imprimir y enlazar al texto completo, siempre y cuando sea sin fines de lucro y se cite la fuente.

CÓMO CITAR ESTE ARTÍCULO:

Bárcenas Rosas, J., y Gil Rendón, M. E. (2026). Sistema de apoyo docente con inteligencia artificial para personalizar el aprendizaje universitario. *Apertura*, *18*(2), 90-101. http://doi.org/10.32870/Ap.v18n2.2882