

Desarrollo y validación de la escala de Aprendizaje Autorregulado con IA (AI-SRL)

Development and validation of the AI-Enhanced Self-Regulated Learning (AI-SRL) scale



- ✉ Mehmet Ali Ayaz - *Giresun University, GRÜ (Turquía)*
✉ Fatih Karataş - *Neuşehir Hacı Bektaş Veli University, NEVÜ (Turquía)*
✉ Erkan Yüce - *Aksaray University, ASÜ (Turquía)*

RESUMEN

La integración de la Inteligencia Artificial (IA) en entornos educativos brinda nuevas oportunidades para mejorar el aprendizaje autorregulado (SRL) en los estudiantes. Sin embargo, las herramientas actuales carecen de precisión para evaluar cómo la IA influye en las capacidades autorregulatorias de los estudiantes. Este estudio presenta la Escala de Aprendizaje Autorregulado Mejorado por IA (AI-SRL), diseñada para evaluar el aprendizaje autorregulado en entornos educativos asistidos por IA. A través de un riguroso proceso de desarrollo de escala, que incluyó revisión de literatura, consulta con expertos y validación sistemática, se construyó un instrumento de medición integral. En el desarrollo se empleó un enfoque de validación en dos fases con muestras separadas para análisis factoriales exploratorios y confirmatorios. La escala final validada consta de 22 ítems organizados en cinco dimensiones: Competencia en IA, Conciencia de Aprendizaje, Estrategias de Aprendizaje, Implicación y Eficiencia, y Colaboración Ética. Estos factores capturan la naturaleza multifacética de cómo los estudiantes regulan su aprendizaje al usar herramientas de IA, desde competencia técnica hasta consideraciones éticas. La escala demostró sólidas propiedades psicométricas, con excelente consistencia interna y robusta validez de constructo. Este instrumento validado tiene aplicaciones prácticas para docentes que buscan optimizar la integración de IA en sus aulas, investigadores que investigan la intersección de IA y aprendizaje autorregulado, e instituciones desarrollando currículos mejorados con IA. La Escala AI-SRL proporciona un marco confiable para evaluar en qué medida los estudiantes aprovechan las herramientas de IA mientras mantienen sus capacidades autorregulatorias, contribuyendo así a una implementación de IA más efectiva y responsable.

Palabras clave: IA; AIED; aprendizaje autorregulado; AI-SRL; escala AI-SRL.

ABSTRACT

The integration of Artificial Intelligence (AI) into educational settings offers new opportunities for enhancing self-regulated learning (SRL) among students. However, current tools lack precision in measuring how AI influences learners' self-regulatory capabilities. This study introduces the AI-Enhanced Self-Regulated Learning (AI-SRL) Scale, designed to assess SRL in AI-supported educational environments. Through a rigorous scale development process involving a literature review, expert consultation, and systematic validation, we developed a comprehensive measurement instrument. The development employed a two-phase validation approach with separate samples for exploratory and confirmatory factor analyses. The final validated scale comprises 22 items organized into five dimensions: AI Competence, Learning Awareness, Learning Strategies, Engagement and Efficiency, and Ethical Collaboration. These factors capture the multifaceted nature of how students regulate their learning when using AI tools, from technical proficiency to ethical considerations. The scale demonstrated strong psychometric properties, with excellent internal consistency and robust construct validity. This validated instrument has practical applications for educators aiming to optimize AI integration in their classrooms, researchers investigating the intersection of AI and SRL, and institutions developing AI-enhanced curricula. The AI-SRL Scale provides a reliable framework for assessing how effectively students leverage AI tools while maintaining their self-regulatory capabilities, thereby contributing to more effective and responsible AI implementation.

Keywords: AI; AIED; self-regulated learning; AI-SRL; AI-SRL scale.

INTRODUCCIÓN

El aprendizaje autorregulado (AAR), componente crítico para el éxito en el aprendizaje digital y permanente, implica establecer metas, supervisar el progreso y ajustar conductas para alcanzar el éxito académico (Hilpert et al., 2023; Lai, 2024). En la era digital, el AAR es cada vez más crucial para la formación continua, pues permite a las personas adaptarse a necesidades educativas cambiantes y promueve la resolución de problemas (Adams et al., 2024; Hilpert et al., 2023; Kong y Yang, 2024). La evolución de las prácticas educativas y la integración de tecnologías avanzadas como la IA ofrecen oportunidades para potenciar el AAR y afrontar sus desafíos.

Las bases teóricas del AAR se fundamentan en dos marcos integrales que han moldeado la psicología educativa durante más de tres décadas. El modelo de fases cíclicas de Zimmerman, basado en la teoría social cognitiva, concibe el AAR como un proceso estructurado en tres fases recurrentes: planificación, ejecución y autorreflexión (Panadero, 2017; Schunk y Zimmerman, 2012; Zimmerman, 1989). La fase de planificación abarca el análisis de la tarea —incluyendo fijar metas y la planificación estratégica— junto con creencias motivacionales como la autoeficacia, las expectativas de resultado y el interés intrínseco. La fase de ejecución implica estrategias de autocontrol como la atención focalizada y la autoinstrucción, combinadas con la autoobservación mediante la monitorización metacognitiva del progreso. La fase de autorreflexión incluye el autojuicio, donde se evalúa el desempeño contra estándares, y procesos de autorreacción con respuestas de satisfacción y reacciones adaptativas que influyen en futuros aprendizajes (Panadero, 2017; Tinajero et al., 2024).

Como complemento, el marco de Pintrich (2000) presenta una taxonomía de cuatro fases —planificación/activación, monitorización, control y reacción/reflexión— aplicadas a cuatro áreas de regulación: cognición, motivación/afecto, conducta y contexto (Tinajero et al., 2024; Yot-Domínguez y Marcelo, 2017). Este marco es valioso por su tratamiento explícito de la regulación motivacional y los factores contextuales, y proporciona una matriz de 16 celdas de procesos regulatorios que abarca de forma exhaustiva los componentes del AAR. El modelo de Pintrich enfatiza que el AAR es un proceso activo y constructivo donde los aprendices establecen metas, y luego intentan monitorizar, regular y controlar su cognición, motivación y conducta, guiados por sus objetivos y el entorno (Panadero, 2017). Estos modelos fundamentales, aunque desarrollados para formatos convencionales, constituyen la arquitectura teórica esencial para investigar cómo la IA transforma los procesos establecidos del AAR.

La integración de la IA en entornos educativos transforma la estructura del aprendizaje, creando oportunidades y desafíos para fomentar el AAR (Chang et al., 2023; Grüneke et al., 2024). Las tecnologías de IA ofrecen formas innovadoras para potenciar las estrategias de AAR, al proveer retroalimentación personalizada, apoyo

flexible y observación en tiempo real que ayudan al aprendiz a gestionar eficazmente su aprendizaje (Huang et al., 2023; Molenaar et al., 2023; Ng et al., 2024). La investigación demuestra que la IA apoya la regulación metacognitiva, cognitiva y conductual en las cuatro fases de Pintrich; por ejemplo, los paneles de analíticas de aprendizaje mejoran la conciencia metacognitiva a través del seguimiento del progreso y la visualización del rendimiento (Gkintoni et al., 2025; Seo et al., 2021; Wang y Lin, 2023). Además, las herramientas de IA apoyan estrategias metacognitivas con soporte en la fijación de metas y planificación, alineándose con la fase de planificación de Zimmerman (Anggoro y Pratiwi, 2023; Liu et al., 2024). Estos sistemas rastrean conductas y ofrecen información sobre los procesos de AAR, y ofrecen soluciones para su desarrollo (Chang et al., 2023; Jin et al., 2023; Molenaar et al., 2023).

Aunque las herramientas de IA pueden apoyar habilidades metacognitivas y la monitorización en tiempo real (Dahri et al., 2024; Jin et al., 2023), los investigadores temen que la dependencia excesiva de la IA obstaculice el desarrollo de habilidades esenciales (Boguslawski et al., 2025). La literatura destaca una tensión entre la capacidad de la IA para dar apoyo personalizado y el riesgo de mermar la autonomía del aprendiz por la descarga cognitiva, donde el uso frecuente de la IA se asocia negativamente con el pensamiento crítico (Chiu, 2024; Gerlich, 2025; Kong y Yang, 2024). Los estudios revelan que, si bien los aprendices perciben la IA como útil para la regulación metacognitiva, cognitiva y conductual, prefieren el apoyo humano para sus necesidades motivacionales. Esto sugiere que la IA tiene dificultades para apoyar la regulación de la motivación, un componente crítico del marco de Pintrich (Lan y Zhou, 2025; Seo et al., 2021). Los estudios también enfatizan la importancia de equilibrar el apoyo de la IA y la guía humana en entornos educativos (Kong y Yang, 2024; Lai, 2024). Si bien la IA ofrece supervisión y retroalimentación detalladas, los educadores son cruciales para diseñar actividades y dar apoyo emocional (Chiu et al., 2023). La investigación sugiere que una implementación eficaz de la IA en el AAR requiere considerar cómo estas herramientas pueden complementar, y no reemplazar, la interacción humana, sobre todo en el desarrollo metacognitivo y la motivación del estudiante (Wang y Lin, 2023; Xia et al., 2023).

No obstante, el potencial de la IA para mejorar plenamente el AAR aún no se ha materializado debido a varias barreras. Mientras algunos estudios destacan que la IA puede aliviar la ansiedad ante el aprendizaje y mejorar la motivación (Biju et al., 2024), otros señalan la necesidad de una integración equilibrada para mantener la participación activa del estudiante (Grüneke et al., 2024). Además, han surgido preocupaciones éticas de gran relevancia, entre ellas la privacidad de los datos y la vigilancia, el sesgo algorítmico que puede perpetuar desigualdades educativas, y desafíos a la integridad académica, dado que el contenido generado por IA complica la evaluación del aprendizaje auténtico (Gkintoni et al., 2025; Walter, 2024). Para afrontar estos retos, los investigadores enfatizan la necesidad crucial de desarrollar

instrumentos de medición fiables para evaluar el impacto de la IA en los procesos de AAR (Baker, 2023; Grüneke et al., 2024; Jin et al., 2023; Molenaar et al., 2023).

Basado en fundamentos teóricos, este estudio conceptualiza el AAR potenciado por IA en cinco dimensiones que amplían y operacionalizan los marcos de Zimmerman y Pintrich para el contexto tecnológico actual. El factor de Competencia en IA se alinea con la fase de planificación, que incluye la autoeficacia en el uso de herramientas de IA y su planificación estratégica. La Conciencia del Aprendizaje corresponde a la monitorización metacognitiva de ambos modelos y capta la percepción del estudiante sobre su comprensión y progreso con la IA. Los factores de Estrategias de Aprendizaje, Implicación y Eficiencia se corresponden con las fases de desempeño y control de ambos marcos, y refleja la selección de estrategias cognitivas y la adaptación, así como la regulación conductual y motivacional necesaria para perseverar en las tareas de aprendizaje. De manera crítica, el factor de Colaboración Ética representa una extensión necesaria a los modelos clásicos, operacionaliza la regulación del contexto moderno (la cuarta área regulatoria de Pintrich) que aborda el sesgo algorítmico, la privacidad de los datos y las preocupaciones sobre la integridad académica: demandas regulatorias únicas de la era de la IA no anticipadas en los marcos tradicionales de AAR (Gkintoni et al., 2025; Walter, 2024).

El desarrollo de la Escala AI-SRL es clave para evaluar diversos entornos de tecnología educativa. En plataformas con evaluación formativa en tiempo real como Socrative, sus dimensiones de Conciencia del Aprendizaje y Estrategias de Aprendizaje miden si el *feedback* instantáneo promueve la monitorización metacognitiva y el ajuste estratégico (Bauer et al., 2025). En Sistemas de Gestión del Aprendizaje (SGA) como Moodle con asistentes de IA, las subescalas de Competencia en IA e Implicación y Eficiencia evalúan si los tutores IA 24/7 mejoran la autorregulación del estudiante sin supervisión directa. Con respecto a los Sistemas de Tutoría Inteligente que proporcionan andamiaje adaptativo y rutas de aprendizaje personalizadas, la escala completa ofrece una evaluación integral de todo el ciclo regulatorio, desde la planificación y el uso de estrategias hasta las consideraciones éticas, y proporciona retroalimentación valiosa para el diseño de sistemas que sean tanto inteligentes como pedagógicamente sólidos (Wu y Chiu, 2025). Con el uso creciente de IA generativa en tareas académicas, la escala ofrece métodos estructurados para investigar la regulación de la indagación, la evaluación crítica y el uso ético, cerrando brechas en la comprensión de los ecosistemas digitales de aprendizaje (Li et al., 2025; Mohamed et al., 2025). Por ello, este estudio aborda las siguientes preguntas:

PI1: ¿Cómo puede medirse de manera integral el aprendizaje autorregulado potenciado por IA con una escala que operacionalice y extienda los marcos teóricos establecidos por Zimmerman y Pintrich para contextos tecnológicos contemporáneos?

PI2: ¿Cuál es la estructura factorial y cuáles son las propiedades psicométricas de la Escala AI-SRL cuando se valida mediante procedimientos de análisis factorial exploratorio y confirmatorio?

PI3: ¿En qué medida la Escala AI-SRL funciona como un instrumento fiable y válido para capturar las dimensiones específicas del AAR en entornos educativos apoyados por IA?

Revisión de la literatura

Los avances recientes en IA han transformado el panorama del aprendizaje autorregulado (AAR) en entornos educativos, creando tanto oportunidades sin precedentes como desafíos complejos que exigen un examen teórico y empírico. La literatura revela un panorama matizado donde las tecnologías de IA muestran un gran potencial para apoyar las dimensiones cognitivas y metacognitivas del AAR (Seo et al., 2021; Wang y Lin, 2023), pero también presentan desafíos para la regulación motivacional y plantean preocupaciones éticas sobre la agencia del aprendiz y su bienestar digital (Lan y Zhou, 2025).

Las bases teóricas del AAR, en particular el modelo cíclico de Zimmerman y el marco integral de Pintrich, han demostrado ser notablemente robustas en contextos de aprendizaje potenciados por IA. La estructura cíclica de tres fases de Zimmerman —planificación, ejecución y autorreflexión— se corresponde eficazmente con las aplicaciones de IA (Chiu, 2024), las cuales ofrecen un apoyo específico en cada fase. La investigación de Lan y Zhou (2025) encontró que, aunque el 50 % de las aplicaciones de IA apoyan principalmente la fase de ejecución, el apoyo integral en las tres fases sigue siendo escaso (solo el 21 % de las aplicaciones), siendo la fase de autorreflexión la que menos apoyo recibe. Esto sugiere una necesidad continua de guía humana en los procesos reflexivos. Del mismo modo, el marco de Pintrich y sus cuatro áreas de regulación (cognitiva, motivacional/afectiva, conductual y contextual) encuentra claros paralelismos en los entornos de aprendizaje mediados por IA (Yot-Domínguez y Marcelo, 2017), aunque la regulación motivacional sigue siendo particularmente problemática (Jin et al., 2023; Seo et al., 2021).

Las tecnologías de IA han demostrado un apoyo significativo a los componentes centrales del AAR en diversas disciplinas, sobre todo, en los dominios cognitivo y metacognitivo. Estudios empíricos recientes revelan relaciones significativas entre la autoeficacia en el uso de IA y el rendimiento académico, siendo la aplicación práctica de estas herramientas el predictor más fuerte de la autoeficacia (Bećirović et al., 2025). La investigación de Liang et al. (2023) halló que la interacción estudiante-IA mejoró significativamente el rendimiento a través de una mayor implicación cognitiva ($\beta = 0.046$), mientras que los sistemas de retroalimentación basados en IA mejoran la conciencia metacognitiva del estudiante a través del seguimiento del progreso y la visualización del rendimiento en tiempo real (Gkintoni et al., 2025; Molenaar et al., 2023). La implementación de la IA en el AAR revela complejas dinámicas de apoyo y obstaculización. Aunque herramientas como ChatGPT han mejorado las habilidades de investigación y han apoyado el aprendizaje autodirigido a través de

la autonomía (Li et al., 2025), otros estudios revelan preocupantes correlaciones negativas ($r = -0.39$) entre la dependencia excesiva de la IA y el pensamiento crítico, especialmente en aprendices de 17-25 años (Gerlich, 2025). Este efecto de “descarga cognitiva” sugiere que el uso frecuente de la IA puede impedir el desarrollo de habilidades metacognitivas independientes, lo que hace que los aprendices dependan de los sistemas en lugar de desarrollar capacidades de autorregulación autónomas (Gerlich, 2025). La investigación de Glick et al. (2024) demostró que, si bien los módulos de formación con IA aumentaron el uso de herramientas de planificación y la fijación de metas, el equilibrio entre el apoyo de la IA y la agencia del aprendiz sigue siendo una preocupación crítica.

Quizá el hallazgo más significativo en la literatura es que las aplicaciones de IA tienen dificultades para apoyar la regulación motivacional, un componente crítico del AAR (Seo et al., 2021). Múltiples revisiones sistemáticas confirman que, si bien los aprendices perciben la IA como útil para la regulación metacognitiva, cognitiva y conductual, prefieren recibir apoyo humano para satisfacer sus necesidades motivacionales (Jin et al., 2023; Lan y Zhou, 2025). Desde la Teoría de la Autodeterminación, aunque la IA puede apoyar la competencia con retroalimentación personalizada y la autonomía mediante el control de las rutas de aprendizaje (Chiu, 2024; Li et al., 2025), la vinculación sigue siendo su aspecto más débil.

La evidencia empírica reciente (2020-2025) apunta cada vez más hacia los sistemas híbridos de regulación humano-IA como el enfoque óptimo para apoyar el AAR. La investigación distingue entre la autorregulación centrada en el humano, donde la IA es un facilitador que provee herramientas y datos para el control del aprendiz, y la autorregulación centrada en la IA, donde esta genera ciclos de AAR a partir de datos (Lan y Zhou, 2025). Las implementaciones más efectivas parecen implicar una interacción en la que la IA se integra en los ciclos de AAR centrados en el humano a través de las dimensiones conductual, emocional y cognitiva, manteniendo la agencia humana (Wu y Chiu, 2025).

En general, aunque la IA tiene un potencial transformador para el AAR, la evidencia sugiere que una implementación eficaz requiere un enfoque equilibrado que aproveche sus capacidades tecnológicas preservando los elementos humanos fundamentales del AAR. El desarrollo de nuevas herramientas de medición como la Escala AI-SRL es crucial para obtener una comprensión más profunda de la eficacia e impacto de las herramientas de IA, abordar la compleja interacción entre la mejora cognitiva y los posibles déficits motivacionales, así como guiar futuras integraciones que mantengan la agencia del aprendiz mientras se aprovechan las fortalezas de la IA en personalización y la gestión de la carga cognitiva.

MÉTODO

En este estudio, el objetivo fue desarrollar una escala para medir los niveles de AAR de los participantes en el contexto del uso de la IA. A pesar de las directrices

establecidas, los investigadores a menudo enfrentan limitaciones en el desarrollo de escalas, que incluyen las características de la muestra, cuestiones metodológicas y desafíos psicométricos. Para optimizar futuras prácticas, es crucial considerar estas posibles limitaciones y tomar decisiones metodológicas informadas durante todo el proceso (Morgado et al., 2017). Por tanto, y reconociendo estas limitaciones, este estudio emplea una metodología robusta para el desarrollo de una escala fiable y válida.

Participantes

Se utilizaron dos muestras distintas para el análisis factorial exploratorio (AFE) y el análisis factorial confirmatorio (AFC). La muestra del AFE consistió en 504 participantes, mientras que la del AFC incluyó 424. Los participantes fueron reclutados en línea mediante un muestreo por conveniencia e intencional (Creswell, 2014).

El muestreo por conveniencia se usó para facilitar el acceso a los participantes, procedentes de universidades con las que teníamos algún tipo de conexión. Nuestro muestreo fue intencional para seleccionar participantes capaces de comprender fácilmente los ítems de la escala. La mayoría era de departamentos de enseñanza de lenguas extranjeras o de literatura. En el caso de participantes de otros departamentos, se verificó que pudieran entender los ítems sin dificultad. Se priorizó la recolección de datos principalmente de estos departamentos para garantizar la claridad en la comprensión de los ítems, los cuales estaban en inglés. Esto podría haber afectado en cierta medida la generalizabilidad de las respuestas y la interpretación de los factores en algunos constructos. Futuros estudios para validar la escala podrían recolectar datos de poblaciones académicas más diversas para mejorar la generalizabilidad y los estadísticos. Los datos demográficos de nuestros participantes se resumen en la siguiente tabla.

Tabla 1
Datos demográficos

Género	n	Edad	n	Año/Curso	n	Departamento/ Carrera	n
Hombre	334	18 o menos	195	Curso preparatorio de inglés	212	Enseñanza de la Lengua Inglesa	288
Mujer	594	19	202	1. ^{er} año	184	Lengua y Literatura Inglesa	262
Total	928	20	228	2. ^o año	260	Grado en Farmacia	149

Género	n	Edad	n	Año/Curso	n	Departamento/ Carrera	n
		21	193	3. ^{er} año	180	Relaciones Internacionales	31
		22	195	4. ^o año o superior	92	Psicología	28
		23 +	202	Total	928	Derecho	25
		Total	928			Turismo y Orientación	23
						Ingeniería	24
						Otros	98
						Total	928

Como indica la Tabla 1, se contó con un total de 928 participantes para los dos primeros pasos (AFE y AFC) del estudio. De ellos, 594 (64.0 %) eran mujeres y 334 (36.0 %) hombres. Según el departamento académico, 288 participantes (31.0 %) eran de Enseñanza de la Lengua Inglesa, 262 (28.2 %) de Lengua y Literatura Inglesa, y 149 (16.1 %) de Grado en Farmacia. La distribución por curso incluyó a 212 participantes (22.8 %) de cursos preparatorios de inglés, 184 (19.8 %) de primer año, 260 (28.0 %) de segundo, 180 (19.4 %) de tercero y 92 (9.9 %) de cuarto o superior. También se recolectó información adicional sobre el uso de la tecnología y la IA en el aprendizaje por parte de los participantes. La Tabla 2 resume esta información.

Tabla 2

Uso de tecnología e IA en el aprendizaje por parte de los participantes

Nivel de uso de tecnología en el aprendizaje	n	Experiencia con IA	n	Frecuencia de uso de la IA para aprender	n
Muy bajo	8	1 año	543	Cada día	104
Bajo	46	2 años	239	Varias veces por semana	212
Medio	395	3 años	81	Una vez por semana	141
Alto	338	4 años	29	Varias veces al mes	180
Muy alto	141	5 años	13	Una vez al mes	189
Total	928	6+ años	23	Rara vez / si es necesario	102
		Total	928	Total	928

Como se observa en la Tabla 2, los participantes indicaron su nivel de uso de la tecnología en el aprendizaje; la gran mayoría reportó niveles medios (395, 42.5 %), altos (338, 36.4 %) y muy altos (141, 14 %). Aquellos con un nivel bajo o muy bajo representaron el 5.8 % de los participantes. También proporcionaron información sobre su experiencia con la IA: 543 de ellos (58.5 %) tenían un año de experiencia, 239 tenían 2 años (25.7 %), 81 tenían 3 años (8.7 %), y el resto tenía 4, 5, 6 o más años de experiencia. Finalmente, recabamos datos sobre la frecuencia de uso de la IA para aprender. El número de participantes que la usaba cada día fue de 104 (11.2 %), 212 (aproximadamente el 22.8 %) la usaba varias veces por semana, 141 (15.2 %) una vez por semana, 180 (19.3 %) varias veces al mes, y 189 (20.3 %) una vez al mes. Además, 102 participantes (aproximadamente el 11 %) reportaron usar la IA para aprender cuando lo necesitaban.

Generación de ítems

El desarrollo de escalas constituye un proceso fundamental en la investigación social y conductual, el cual suele comprender tres fases principales: la generación de ítems, la construcción de la escala y la evaluación de la misma (Boateng et al., 2018). La fase de generación de ítems se inicia con la definición precisa del constructo que se desea medir y la elaboración de un banco preliminar de ítems (Boateng et al., 2018).

En este estudio, el banco inicial de ítems se elaboró a través de una revisión exhaustiva de la literatura sobre AAR e IA. La validez de contenido suele evaluarse mediante una revisión realizada por expertos (Teeluckdharry et al., 2021). Los ítems de nuestra escala se diseñaron para capturar las dimensiones clave del AAR en el contexto de la IA, asegurando su coherencia con los marcos teóricos existentes. El banco inicial de ítems se sometió a un riguroso proceso de validación de contenido por un panel de siete expertos. La selección de los expertos se realizó con base en criterios específicos: (1) poseer un doctorado en Tecnología Educativa, Psicología Educativa o un campo afín; (2) un mínimo de cinco años de experiencia en investigación; y (3) al menos dos publicaciones revisadas por pares sobre AAR o la aplicación de la IA en la educación. Esta estrategia de muestreo intencional aseguró un alto nivel de experiencia tanto teórica como práctica. El panel proporcionó retroalimentación sobre la claridad, la relevancia y la representatividad de los ítems. La validez de contenido se evaluó con el Índice de Validez de Contenido (IVC). Se conservaron aquellos ítems que alcanzaron un $IVC \geq .80$ por parte de al menos 6 de los 7 expertos. El promedio del IVC a nivel de escala ($IVC-E/Prom$) fue de .92, superando el umbral recomendado de .90.

Los ítems fueron revisados o eliminados basándose en esta retroalimentación, lo que resultó en una escala preliminar para la prueba piloto. La literatura señala varios tamaños de muestra para estudios piloto. Johanson y Brooks (2009) destacan que Isaac y Michael (1995) y Hill (1998) sugirieron entre 10 y 30 participantes, mientras

que Mooney y Duval (1993) propusieron entre 30 y 50, y Hertzog (2008) entre 25 y 40 para el desarrollo de escalas. En nuestro caso, la prueba piloto se llevó a cabo con una muestra de 33 participantes que representaban características similares a las de los grupos objetivo del estudio. El objetivo de la prueba piloto fue identificar problemas relacionados con la redacción de los ítems, las opciones de respuesta o la extensión global de la escala. A partir de los resultados, se realizaron revisiones menores para mejorar la claridad y la fiabilidad de los ítems.

Análisis Factorial Exploratorio (AFE)

La fase de construcción de la escala incluye la prueba preliminar, la administración del cuestionario, la reducción de ítems y la extracción de factores (Boateng et al., 2018). Tras la aplicación de la escala al primer grupo de participantes, se procedió al siguiente paso. La fase de evaluación de la escala implica la prueba de la dimensionalidad, la fiabilidad y la validez (Teeluckdharry et al., 2021). Se evaluó la adecuación de los datos de la primera muestra ($n = 504$) para el análisis factorial. La medida de adecuación muestral de Kaiser-Meyer-Olkin (KMO) fue de .96, lo que indica una adecuación excelente (Kaiser y Rice, 1974). Además, la Prueba de Esfericidad de Bartlett fue significativa, $\chi^2 = 9846.80, p < .001$, lo que confirmó que la matriz de correlaciones no era una matriz de identidad y que, por tanto, resultaba apropiada para el análisis. Tras esto, se llevó a cabo un Análisis Factorial Exploratorio (AFE) con SPSS 22 para examinar y confirmar la estructura factorial de la Escala AI-SRL. El AFE se utilizó para revelar la estructura factorial subyacente e identificar grupos de ítems relacionados, estableciendo así la validez de constructo de la escala al reducir los datos a un número menor de factores significativos (Field, 2018).

Se empleó el Análisis de Componentes Principales (ACP) como método de extracción y la rotación promax —un método de rotación oblicua— que permite correlaciones entre factores (Kline, 2014; Muthén y Muthén, 2017). Aunque se probaron la Factorización de Ejes Principales (FEP) y la Máxima Verosimilitud (MV), no generaron soluciones factoriales estables o interpretables. Dado nuestro objetivo de explorar las dimensiones subyacentes y reducir los ítems a componentes coherentes, se seleccionó el ACP por su robustez e interpretabilidad en este contexto, en concordancia con recomendaciones previas para el desarrollo inicial de escalas (Fabrigar y Wegener, 2012; Jolliffe, 2014). Para garantizar aún más la validez, se utilizó una muestra distinta para realizar un Análisis Factorial Confirmatorio (AFC) mediante AMOS, que confirmó la estructura derivada del ACP con índices de ajuste del modelo satisfactorios.

El AFE sugirió en la mayoría de los casos una solución de cuatro factores, y en algunos casos cinco, basándose en autovalores superiores a uno. Tras evaluar un gran número de modelos con AFE y AFC, se adoptó la solución de cinco factores por ser la que ofreció el mejor ajuste del modelo. En la etapa de AFE, se mantuvieron los ítems con cargas factoriales de 0.4 o superiores, umbral considerado significativo

(Floyd y Widaman, 1995; Hair et al., 2010). Durante el AFE, se eliminaron tres ítems debido a cargas cruzadas que no superaban el umbral de diferencia de 0.10 (Büyüköztürk, 2018): “No comparto mi información personal al usar herramientas de IA”, “Verifico la originalidad del trabajo generado por IA antes de usarlo” y “Me aseguro de que mis compañeros también usen la IA de forma ética”. En la etapa de AFC, se eliminaron nueve ítems adicionales debido a cargas estandarizadas bajas o marginales, redundancia con ítems de mayor carga o índices de modificación problemáticos entre factores. Estos incluían ítems correspondientes a Competencia en IA (ej., “Puedo aprender rápidamente a usar nuevas herramientas de IA”), de Conciencia del Aprendizaje reflexiva (ej., “Evalúo si las herramientas de IA me dan información precisa”), y de Colaboración Ética (ej., “Discuto cuestiones éticas sobre IA con compañeros”). Las decisiones de eliminación se basaron en criterios estadísticos y conceptuales para asegurar el rigor psicométrico y la coherencia teórica de la escala final. Los ítems eliminados y su justificación se detallan en el Apéndice B. El AFE reveló una estructura de cinco factores que explicó el 62.42 % de la varianza total. Los ítems mostraron cargas elevadas en sus respectivos factores, con valores entre 0.44 y 0.96.

Tabla 3
Autovalores del análisis paralelo

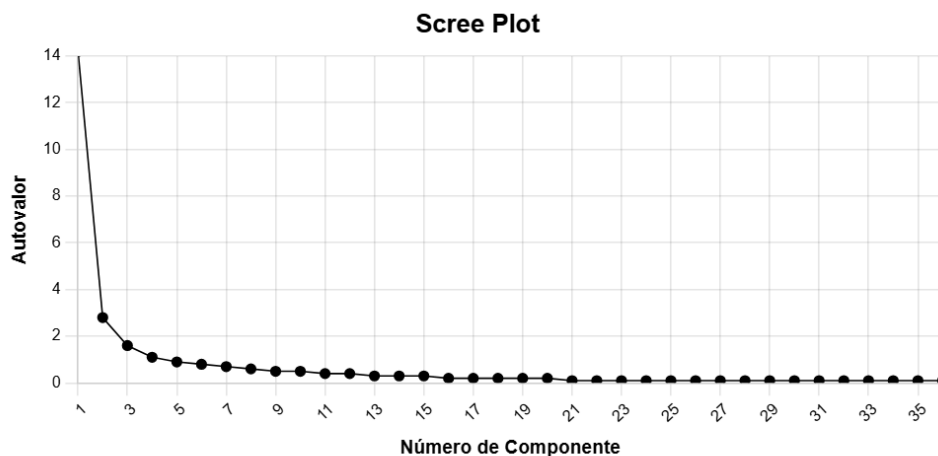
Factor	Autovalores iniciales	% de varianza	% acumulados
Factor 1	14.183	43.99	43.99
Factor 2	2.220	6.95	50.95
Factor 3	1.652	5.25	56.20
Factor 4	1.006	3.13	59.34
Factor 5	.996	3.080	62.42

Como muestra la Tabla 3, los autovalores de los primeros cuatro factores son superiores a uno, y el del quinto es 0.99, justo por debajo de 1.00. Decidimos mantenerlo como factor en la escala final porque estaba respaldado por la literatura previa y los análisis posteriores. Se realizó un análisis paralelo empleando 1000 matrices de datos generadas aleatoriamente con el mismo número de variables (31) y participantes (504). Los primeros tres factores superaron claramente el percentil 95 de los autovalores aleatorios, lo que justificó firmemente su retención. Los factores 4 y 5 tuvieron autovalores ligeramente por debajo del umbral del percentil 95, pero se mantuvieron basándose en: (a) su alineación teórica con los marcos de AAR, (b) cargas factoriales adecuadas (todas > .40), y (c) una mejora en el ajuste del modelo en el AFC posterior. Esta decisión se encuentra en consonancia con las recomendaciones de considerar múltiples criterios más allá de los autovalores para

la retención de factores (Fabrigar y Wegener, 2012). Asimismo, la solución de cinco factores fue respaldada por un gráfico de sedimentación, que ilustra los factores potenciales dentro de la escala (Eisinga et al., 2013).

Figura 1

Gráfico de sedimentación del análisis factorial exploratorio inicial



El gráfico de sedimentación también respaldó una solución de cinco factores, ya que la pendiente del gráfico se aplanó considerablemente después del quinto factor. El Apéndice C presenta las cargas factoriales de cada ítem del modelo inicial, lo que describe la naturaleza subdimensional de la escala. Tras este análisis, se eliminaron los ítems 21, 24 y 29. Los 31 ítems restantes formaron una estructura de cinco factores, que luego fue sometida a un AFC utilizando los datos del segundo grupo de estudio. Este análisis posterior dio como resultado la escala final de 22 ítems.

Análisis Factorial Confirmatorio (AFC)

Una vez confirmado el modelo inicial del AFE, recolectamos nuevos datos basados en este último modelo, los cuales se usaron para el AFC. Sun (2005) indica tres propósitos principales para realizar un AFC: evaluación de la validez de constructo, comparación de patrones de respuesta y comparación de modelos competidores. En nuestro caso, lo usamos para evaluar la validez de constructo y comparar modelos.

El AFC, realizado con una muestra independiente ($n = 424$), se utilizó para probar la estructura de cinco factores identificada en el AFE. El modelo inicial se refinó basándose en las cargas estandarizadas y los índices de modificación. Los ítems con

cargas bajas o aquellos que creaban una covarianza significativa entre factores se eliminaron iterativamente para mejorar el ajuste del modelo, manteniendo al mismo tiempo la coherencia teórica. Este proceso dio como resultado el modelo final de 22 ítems. La Tabla 4 resume los principales índices de ajuste de los análisis de AFC.

Tabla 4
Resultados del AFC

Índices clave	Criterios de Hu y Bentler (1999)	Nuestros resultados
CFI	> .95 excelente, > .90 bueno, > .80 a veces aceptable	0.96
RMSEA	< .05 bueno, < .10 moderado, > .10 no bueno	0.04
CMIN/DF	< 3 bueno, < 5 aceptable	2.82
GFI	> .95 excelente, > .90 bueno	0.94
AGFI	> .80	0.92
SRMR	< .09	0.04
TLI	> .95 excelente, > .90 aceptable	.95

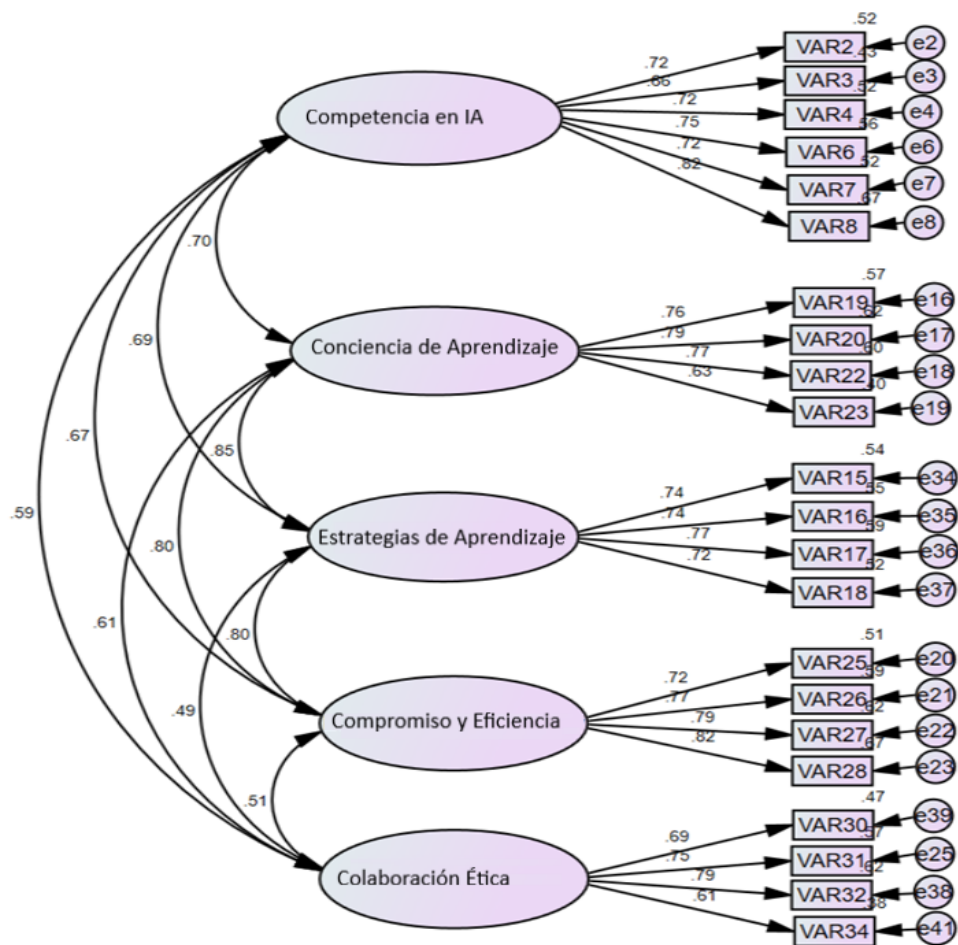
Como indica la Tabla 4, el modelo final demostró un buen ajuste a los datos, evaluado según los criterios de ajuste convencionales (Hu y Bentler, 1999). Los índices de ajuste fueron: χ^2/gl (CMIN/DF) = 2.82, Índice de Ajuste Comparativo (CFI) = .97, Índice de Tucker-Lewis (TLI) = .95, Error Cuadrático Medio de Aproximación (RMSEA) = .04 (IC 90 % [.035, .045]), y Raíz del Residuo Cuadrático Medio Estandarizado (SRMR) = .04. Dado que el CFI y el TLI fueron superiores a .95 y el RMSEA y el SRMR inferiores a .05, el modelo de cinco factores se confirmó como una representación válida de los datos.

Modelo de Análisis Factorial Confirmatorio (AFC)

La siguiente figura ilustra el modelo de AFC y los coeficientes entre variables e ítems.

Figura 2

Análisis factorial confirmatorio de la escala AI-SRL con coeficientes de trayectoria estandarizados



La figura confirma el modelo final, que consta de 5 factores y 22 ítems. Los cinco factores confirmados mediante el AFC representan dimensiones distintas del aprendizaje autorregulado potenciado por IA con claras implicaciones pedagógicas.

La Competencia en IA (Factor 1, 6 ítems) refleja la autoeficacia y la competencia técnica del aprendiz al utilizar herramientas de IA con fines educativos, reflejando su confianza para adaptarse a diversas interfaces, comprender instrucciones generadas por IA e interpretar eficazmente la información que esta produce para su

aprendizaje. La Conciencia del Aprendizaje (Factor 2, 4 ítems) abarca procesos de monitorización metacognitiva donde los aprendices supervisan de forma consciente su comprensión, progreso y eficacia al interactuar con sistemas de IA, lo que incluye la reflexión crítica acerca de su dependencia de estas herramientas. Las Estrategias de Aprendizaje (Factor 3, 4 ítems) implica la selección, adaptación e implementación de estrategias cognitivas apoyadas por IA, incluyendo cómo los aprendices usan la IA para encontrar métodos de estudio efectivos, mejorar la resolución de problemas y fortalecer el pensamiento crítico. La Implicación y Eficiencia (Factor 4, 4 ítems) evalúa la regulación conductual y motivacional del aprendiz para mantener la participación, lograr resultados de aprendizaje permanentes y sostener el interés al usar herramientas de IA adaptadas a su estilo. La Colaboración Ética (Factor 5, 4 ítems) representa una dimensión novedosa que aborda la conciencia del aprendiz sobre el uso responsable de la IA, incluyendo consideraciones sobre responsabilidad personal, privacidad, sesgos potenciales y seguridad de la información en contextos de aprendizaje asistidos por IA.

Estos factores, en conjunto, operacionalizan cómo los aprendices contemporáneos afrontan el complejo panorama de la educación potenciada por IA manteniendo sus capacidades de autorregulación. La versión validada completa de la Escala AI-SRL, compuesta por 22 ítems organizados en torno a estos cinco factores, se presenta en el Apéndice A. En las secciones siguientes se detalla la fiabilidad y validez de la escala.

Análisis de fiabilidad

Realizamos varias pruebas con el propósito de garantizar la fiabilidad de la escala AI-SRL. Estas pruebas se explican a continuación.

Consistencia interna

Se calculó el Alfa de Cronbach para evaluar la consistencia interna de la escala general y de cada factor, utilizado como indicador del grado de homogeneidad de los ítems. Valores de Alfa de Cronbach superiores a .90 se consideran de consistencia excelente; entre .80 y .90 reflejan una buena consistencia; entre .70 y .80 indican una consistencia aceptable; entre .60 y .70 son cuestionables; de .50 a .60 son pobres; y valores por debajo de .50 son inaceptables (George y Mallery, 2003). La escala general mostró una consistencia interna excelente ($\alpha = .94$, IC 95 % [.93, .95]). Los subfactores individuales también mostraron una fiabilidad de buena a excelente: Competencia en IA ($\alpha = .91$), Conciencia del Aprendizaje ($\alpha = .88$), Estrategias de Aprendizaje ($\alpha = .84$), Implicación y Eficiencia ($\alpha = .86$), y Colaboración Ética ($\alpha = .87$). Los estadísticos detallados, incluidas las correlaciones ítem-factor, se presentan en el Apéndice D.

Fiabilidad de dos mitades (split-half)

Se realizó un análisis de fiabilidad de dos mitades en la escala AI-SRL para evaluar adicionalmente la consistencia de los ítems. La Tabla 5 muestra los resultados de este análisis.

Tabla 5
Resultados del análisis de fiabilidad de dos mitades (split-half)

	Número de ítems	Medias Máx – Mín	Medias	Alfa de Cronbach	Correlación entre formas	Coefficiente de dos mitades de Guttman	Coefficiente de Spearman-Brown
Parte 1	11 ^a	3.56 ± 3.16	3.39	0.90	0.80	0.89	0.89
Parte 2	11 ^b	3.59 ± 3.19	3.41	0.89			
Total	22	3.59 ± 3.16	3.40	0.94			

Notas: ^a Los ítems son: 1, 3, 5, 7, 9, 11, 13, 15, 17, 19, 21.
^b Los ítems son: 2, 4, 6, 8, 10, 12, 14, 16, 18, 20, 22.

Como indica la Tabla 5, el coeficiente de Spearman-Brown fue de .89 (IC 95 % [.87, .91]) y el coeficiente de Dos Mitades de Guttman fue de .89 (IC 95 % [.87, .91]), lo que muestra una excelente fiabilidad de dos mitades. La correlación entre formas fue de .80 (IC 95 % [.77, .83]).

Validez

Según Cheung et al. (2024), la validez convergente requiere una Fiabilidad Compuesta (FC) ≥ 0.70, cargas estandarizadas ≥ 0.50 y una Varianza Media Extraída (VME) ≥ 0.50, criterios que nuestro modelo cumple. La Tabla 6 muestra las puntuaciones de las escalas AI-SRL.

Tabla 6
FC, VME, MVC y correlaciones entre factores

	FC	VME	MVC	Colaboración ética	Competencia en IA	Conc. del aprend.	Implic. y efíc.	Estrateg. de aprend.
Colaboración ética	0.80	0.51	0.37	0.71				
Competencia en IA	0.87	0.54	0.49	0.59	0.73			

Conciencia del aprendizaje	0.83	0.55	0.73	0.61	0.70	0.74		
Implicación y eficiencia	0.85	0.59	0.65	0.51	0.67	0.80	0.77	
Estrategias de aprendizaje	0.83	0.55	0.73	0.49	0.68	0.85	0.80	0.74

Nota: Los intervalos de confianza del 95% para las correlaciones están disponibles en los materiales suplementarios. Todas las correlaciones son significativas a $p < .001$. FC = Fiabilidad Compuesta; VME = Varianza Media Extraída; MVC = Varianza Máxima Compartida.

La validez discriminante se probó a través de múltiples criterios: (a) ningún ítem presentó cargas cruzadas entre constructos, (b) la VME de cada constructo superó las correlaciones inter-constructo al cuadrado, y (c) las correlaciones entre factores estuvieron por debajo de los valores recomendados —ninguna superó 0.85— (Cheung et al., 2024; Hair et al., 2010). Aunque se encontraron algunas correlaciones altas entre Conciencia del Aprendizaje, Implicación y Eficiencia y Estrategias de Aprendizaje, estos constructos mantuvieron su distinción teórica dentro del marco AI-SRL. Por tanto, su retención se consideró psicométricamente justificable y conceptualmente significativa.

Los análisis estadísticos se realizaron con IBM SPSS Statistics 22 y AMOS 22. Todos los intervalos de confianza se calcularon al nivel del 95 % usando el método bootstrap acelerado y con corrección de sesgo (BCa) con 5000 remuestreos. El análisis paralelo se empleó con la sintaxis de SPSS de O'Connor (2000), generando 1000 matrices de correlación aleatorias para la comparación de autovalores. Se fijó un nivel de significancia de $\alpha = .05$ para todas las pruebas, aplicando correcciones de Bonferroni para comparaciones múltiples cuando fue apropiado. La escala validada ofrece una medida fiable y válida del AAR en el contexto de la IA, con potenciales aplicaciones tanto en la investigación como en la práctica educativa. Futuras investigaciones podrían ampliar el uso de la escala en diversas poblaciones y entornos.

DISCUSIÓN

Este estudio desarrolló y validó con éxito la Escala AI-SRL, proporcionando un instrumento psicométricamente robusto diseñado específicamente para evaluar las capacidades de AAR en entornos educativos apoyados por IA. Para los análisis preliminares, se elaboró una herramienta de 34 ítems basada en la literatura y la opinión de expertos. El análisis factorial mediante KMO reveló una adecuación excelente (.96), y la Prueba de Esfericidad de Bartlett confirmó la distribución normal multivariante de los datos. Tras el AFE y el ACP para establecer factores

significativos y revelar sus correlaciones, se eliminaron 12 ítems para preservar la coherencia teórica y la integridad psicométrica de la escala. Con las respuestas de 928 participantes, se realizaron los análisis de AFE y AFC. Los resultados de validez de contenido, validez de constructo, consistencia interna y fiabilidad de dos mitades confirmaron que la Escala AI-SRL es psicométricamente sólida para evaluar el AAR con IA en entornos educativos. La versión final de la escala consta de 22 ítems bajo 5 factores: Competencia en IA, Conciencia del Aprendizaje, Estrategias de Aprendizaje, Implicación y Eficiencia, y Colaboración Ética.

Esta estructura de cinco factores muestra que el uso de la IA en entornos educativos profundiza y contribuye al constructo tradicional de la autorregulación al detallar la competencia, la conciencia del aprendizaje, las estrategias, la implicación y eficiencia, y la colaboración ética. Esta nueva estructura se alinea con la literatura reciente al destacar cómo la integración de la IA en entornos educativos avanza las teorías convencionales del AAR propuestas por Zimmerman (1989) y Pintrich (1999). Además, el factor Competencia en IA de este estudio contribuye a la literatura. Por ejemplo, Bećirović et al. (2025) hallaron una correlación significativa entre el rendimiento académico y la autoeficacia en IA. Este factor también puede vincularse con las estrategias de regulación cognitiva de Pintrich (1999), ya que el estudio actual destacó que las herramientas de IA pueden apoyar las estrategias de elaboración. Por otra parte, el factor Conciencia del Aprendizaje evoca el proceso de autoobservación de la fase de ejecución de Zimmerman (Panadero, 2017; Zimmerman, 1989), señalando el potencial de la IA para mejorar la monitorización metacognitiva. Gkintoni et al. (2025) revelaron que la retroalimentación de las herramientas de IA, al permitir evaluar el rendimiento simultáneamente, promueve la conciencia metacognitiva de los aprendices, ayudándoles a seguir sus procesos de aprendizaje de forma más consciente. Adicionalmente, el factor Colaboración Ética contribuye a la literatura previa. Cuestiones como la privacidad de datos, la vigilancia, el sesgo algorítmico y la integridad académica fueron señaladas como preocupaciones éticas que pueden afectar directamente al AAR en contextos educativos con IA (Gkintoni et al., 2025; Walter, 2024). Así, este factor subraya las responsabilidades éticas de los estudiantes al usar herramientas de IA.

El factor Colaboración Ética representa una extensión paradigmática más allá de los marcos clásicos del AAR, introduciendo dimensiones que ni Zimmerman ni Pintrich anticiparon. Este factor operacionaliza lo que Pintrich (1999) denominó “regulación del contexto”, pero lo amplía para abarcar la transparencia algorítmica, la soberanía de los datos y la ética colaborativa en las interacciones humano-IA. La aparición de este factor, estadística y conceptualmente distinta, sugiere que las consideraciones éticas en el aprendizaje mediado por IA no son un mero añadido, sino un dominio regulatorio fundamental que requiere atención teórica. Este hallazgo coincide con las llamadas recientes a la “alfabetización algorítmica” como una competencia central en la educación digital (Walter, 2024). En cuanto al factor de Implicación y Eficiencia, las tecnologías de IA pueden presentar un

potencial inestimable para apoyar las dimensiones cognitivas y metacognitivas del AAR, aunque podrían resultar limitadas en la regulación motivacional (Lan y Zhou, 2025; Seo et al., 2021; Wang y Lin, 2023). Considerando las teorías de Zimmerman (1989) y Pintrich (1999), la regulación motivacional está estrechamente asociada con la confianza, la afinidad y el apoyo afectivo individualizado que proporcionan las herramientas educativas basadas en IA. Así, este factor emerge como un área crítica para nuevas investigaciones. Por último, el factor Estrategias de Aprendizaje se vincula tanto con la fase de control cognitivo de Pintrich (1999) como con la fase de ejecución de Zimmerman (1989), y muestra cómo los aprendices seleccionan, adaptan e implementan estrategias cognitivas apoyadas por IA. Este factor refleja los hallazgos de la literatura de que las herramientas de IA apoyan eficazmente la adaptación y selección de estrategias, siendo utilizadas para encontrar métodos de estudio efectivos y mejorar la resolución de problemas (Liu et al., 2024; Seo et al., 2021). Su incorporación reconoce que los aprendices contemporáneos integran activamente las recomendaciones de la IA en su repertorio estratégico.

CONCLUSIÓN Y FUTURAS DIRECCIONES

Los rápidos avances en las herramientas de IA han generado la necesidad de que los entornos educativos las adapten adecuadamente a sus procesos. Junto con otros constructos psicológicos, se ha hecho evidente la necesidad de contar con un instrumento de medición del AAR en el uso de la IA en contextos educativos. Con este propósito, el presente estudio tuvo como objetivo realizar el estudio de validez y fiabilidad de la escala AI-SRL para responder a esta necesidad en la literatura. El estudio propuso la escala AI-SRL, la cual puede usarse como una herramienta psicométricamente sólida para evaluar las habilidades de AAR de los estudiantes en el uso de la IA en entornos educativos. Esta escala puede hacer una contribución original a la literatura y tiene potencial como un instrumento eficaz para su implementación en contextos educativos mediados por IA.

La Escala AI-SRL representa una contribución pionera a la medición educativa al ser uno de los primeros instrumentos validados diseñados específicamente para ver la naturaleza multidimensional del AAR en entornos potenciados por IA. A diferencia de las medidas genéricas de AAR o las escalas de aceptación de la tecnología, este instrumento une de forma única los fundamentos teóricos de la psicología educativa con las realidades contemporáneas de la integración de la IA, y proporciona una herramienta psicométricamente robusta para comprender cómo los aprendices manejan las complejidades de la educación mediada por IA. El potencial de la escala va más allá de la evaluación individual, pues también puede orientar políticas institucionales e innovación pedagógica. Las instituciones educativas que implementan sistemas de aprendizaje con IA pueden utilizar la escala para evaluar la preparación de los estudiantes, identificar necesidades de apoyo y valorar la eficacia de sus iniciativas. La estructura de cinco factores proporciona ideas prácticas para los

diseñadores curriculares, indicando que los programas de alfabetización en IA deben abordar no solo la competencia técnica, sino también la conciencia metacognitiva, la adaptación estratégica, la implicación motivacional y el razonamiento ético.

Para futuras investigaciones, se pueden realizar estudios de validación transcultural de este instrumento con el fin de analizar su aplicabilidad en diferentes entornos culturales. Además, dado que los datos del estudio actual se recolectaron en contextos de educación superior, se podrían recolectar datos futuros en contextos de educación secundaria o profesionales para observar si se obtienen resultados diferentes. Los estudios futuros de validación deberían priorizar investigaciones transculturales, particularmente en contextos educativos no occidentales, donde las orientaciones de aprendizaje colectivistas podrían interactuar de manera distinta con las herramientas de IA. También la aplicabilidad de la escala en entornos de educación primaria y secundaria (K-12) merece ser investigada, ya que los aprendices más jóvenes pueden presentar patrones distintos de autorregulación. Los contextos de formación profesional, incluidos los entornos de aprendizaje corporativo, representan otra frontera donde la escala podría iluminar cómo los profesionales integran la IA en sus prácticas de aprendizaje permanente. Por último, los estudios longitudinales que sigan los perfiles de AI-SRL a lo largo del tiempo proporcionarían información valiosa sobre las trayectorias de desarrollo y el impacto de las intervenciones educativas.

IMPLICACIONES PRÁCTICAS Y LIMITACIONES

La escala AI-SRL puede implementarse como una herramienta eficaz y fiable en entornos educativos, desde la planificación hasta la evaluación. Puede aplicarse para medir los niveles de AAR con IA de los estudiantes; se pueden diseñar u observar analíticas del aprendizaje basadas en sus informes; y puede proporcionar información para la elaboración de diseños instruccionales. Además, la escala puede usarse en la educación presencial, en línea e híbrida.

La escala AI-SRL ofrece aplicaciones concretas para mejorar las prácticas docentes. En la evaluación diagnóstica, los docentes pueden administrarla al inicio del curso para identificar a estudiantes que podrían tener dificultades con los componentes de aprendizaje potenciados por IA, permitiendo intervenciones de apoyo específicas. Para las analíticas del aprendizaje, las puntuaciones pueden integrarse con datos de rastro digital para crear perfiles de aprendizaje completos, revelando patrones entre las capacidades de AAR con IA autoinformadas y los comportamientos de uso reales. Esta integración es valiosa en cursos en línea masivos y abiertos (MOOCs), donde el apoyo personalizado a gran escala es un desafío. En el diseño instruccional, su estructura de cinco factores orienta el desarrollo de estrategias de andamiaje adaptadas: por ejemplo, los estudiantes con baja Competencia en IA podrían beneficiarse de módulos de orientación técnica, mientras que aquellos con una Colaboración Ética débil podrían trabajar con estudios de caso sobre el uso

responsable de la IA. En entornos de aprendizaje híbridos, la escala puede informar sobre cuándo desplegar el apoyo de la IA frente a la instrucción humana. Asimismo, los programas de educación a distancia pueden usarla para evaluar si los estudiantes poseen las habilidades de AAR con IA necesarias para el éxito en entornos de aprendizaje autónomos.

Sin embargo, el presente estudio presenta varias limitaciones. En primer lugar, la mayoría de los participantes fueron seleccionados de departamentos de enseñanza de lenguas extranjeras y de literatura inglesa en universidades de Türkiye, lo que puede limitar la generalizabilidad de los hallazgos a otros contextos de educación superior. En segundo lugar, se utilizaron métodos de muestreo por conveniencia e intencional, lo que, al ser un muestreo no aleatorio, puede dificultar la generalizabilidad a otras poblaciones. En tercer lugar, los ítems de la escala pueden ser interpretados de manera diferente por individuos de distintos contextos lingüísticos. Por último, los sesgos disciplinarios pueden influir negativamente en la implementación del instrumento. Otras limitaciones a considerar: el desarrollo de la escala en el contexto de la educación superior turca, con participantes predominantemente de disciplinas lingüísticas, puede haber limitado la generalizabilidad transcultural y transdisciplinaria. Los ítems en inglés podrían haber introducido sesgos de respuesta entre los hablantes no nativos, afectando potencialmente la invarianza de la medición entre grupos lingüísticos. Además, la rápida evolución de las tecnologías de IA significa que la escala requerirá actualizaciones periódicas para mantener su relevancia.

Aprobación ética

Esta investigación recibió aprobación ética de la Universidad de Ciencias Sociales de Ankara, según el número de decisión 98038.

Uso ético de herramientas de IA

De acuerdo con los principios de transparencia, declaramos el uso de herramientas de IA en la preparación de este manuscrito. Utilizamos Claude Opus principalmente para el refinamiento lingüístico, específicamente para mejorar estructuras gramaticales, la fluidez de las oraciones y asegurar la consistencia en la terminología académica. Esta herramienta se empleó exclusivamente como asistente editorial para el pulido del lenguaje, no para generar contenido de investigación, análisis de datos o contribuciones teóricas. Todo el contenido sustantivo, incluyendo el diseño de la investigación, la recolección de datos, los análisis estadísticos y la interpretación de los resultados, representa el trabajo original de los autores. Mantuvimos el control editorial total, revisando y modificando críticamente todas las sugerencias de la IA. Los autores asumen la plena responsabilidad por la exactitud, originalidad e integridad académica del manuscrito final.

Disponibilidad de los datos

Los datos y materiales utilizados en este estudio están disponibles previa solicitud al autor de correspondencia.

Financiación

Los autores declaran no haber recibido financiación.

REFERENCIAS

- Adams, D., Chuah, K.-M., Devadason, E. y Azzis, M. S. A. (2024). From novice to navigator: Students' academic help-seeking behaviour, readiness, and perceived usefulness of ChatGPT in learning. *Education and Information Technologies*, 29(11), 13617-13634. <https://doi.org/10.1007/s10639-023-12427-8>
- Anggoro, K. J. y Pratiwi, D. I. (2023). Fostering self-assessment in English learning with a generative AI platform: A case of Quizizz AI. *Studies in Self-Access Learning Journal*, 14(4), 489-501. <https://doi.org/10.37237/140406>
- Baker, R. S. (2023). AI and self-regulated learning theory: What could be on the horizon? *Computers in Human Behavior*, 147, 107849. <https://doi.org/10.1016/j.chb.2023.107849>
- Bauer, E., Greiff, S., Graesser, A. C., Scheiter, K. y Sailer, M. (2025). Looking beyond the hype: Understanding the effects of AI on learning. *Educational Psychology Review*, 37(2). <https://doi.org/10.1007/s10648-025-10020-8>
- Bećirović, S., Polz, E. y Tinkel, I. (2025). Exploring students' AI literacy and its effects on their AI output quality, self-efficacy, and academic performance. *Smart Learning Environments*, 12, 29. <https://doi.org/10.1186/s40561-025-00384-3>
- Biju, N., Abdelrasheed, N. S. G., Bakiyeva, K., Prasad, K. D. V. y Jember, B. (2024). Which one? AI-assisted language assessment or paper format: An exploration of the impacts on foreign language anxiety, learning attitudes, motivation, and writing performance. *Language Testing in Asia*, 14, 45. <https://doi.org/10.1186/s40468-024-00322-z>
- Boateng, G. O., Neilands, T. B., Frongillo, E. A., Melgar-Quinonez, H. R. y Young, S. L. (2018). Best practices for developing and validating scales for health, social, and behavioral research: A primer. *Frontiers in Public Health*, 6. <https://doi.org/10.3389/fpubh.2018.00149>
- Boguslawski, S., Deer, R. y Dawson, M. G. (2025). Programming education and learner motivation in the age of generative AI: Student and educator perspectives. *Information and Learning Sciences*, 126(1/2), 91-109. <https://doi.org/10.1108/ILS-10-2023-0163>
- Büyüköztürk, Ş. (2018). *Sosyal bilimler için veri analizi el kitabı*. Pegem Akademi Yayıncılık. <https://doi.org/10.14527/9789756802748>
- Chang, D. H., Lin, M. P.-C., Hajian, S. y Wang, Q. Q. (2023). Educational design principles of using AI chatbot that supports self-regulated learning in education: Goal setting, feedback, and personalization. *Sustainability*, 15(17), 12921. <https://doi.org/10.3390/su151712921>

- Cheung, G. W., Cooper-Thomas, H. D., Lau, R. S. y Wang, L. C. (2024). Reporting reliability, convergent and discriminant validity with structural equation modeling: A review and best-practice recommendations. *Asia Pacific Journal of Management*, 41(2), 745-783. <https://doi.org/10.1007/s10490-023-09871-y>
- Chiu, T. K. F. (2024). A classification tool to foster self-regulated learning with generative artificial intelligence by applying self-determination theory: A case of ChatGPT. *Educational Technology Research and Development*, 72(4), 2401-2416. <https://doi.org/10.1007/s11423-024-10366-w>
- Chiu, T. K. F., Moorhouse, B. L., Chai, C. S. y Ismailov, M. (2023). Teacher support and student motivation to learn with artificial intelligence (AI) based chatbot. *Interactive Learning Environments*, 1-17. <https://doi.org/10.1080/10494820.2023.2172044>
- Creswell, J. W. (2014). *Research design: Qualitative, quantitative and mixed methods approaches* (4ª ed.). SAGE.
- Dahri, N. A., Yahaya, N., Al-Rahmi, W. M., Aldraiweesh, A., Alturki, U., Almutairy, S., Shutaleva, A. y Soomro, R. B. (2024). Extended TAM based acceptance of AI-powered ChatGPT for supporting metacognitive self-regulated learning in education: A mixed-methods study. *Heliyon*, 10(8), e29317. <https://doi.org/10.1016/j.heliyon.2024.e29317>
- DeVellis, R. F. (1991). *Scale development: Theory and applications*. SAGE.
- Eisinga, R., te Grotenhuis, M. y Pelzer, B. (2013). The reliability of a two-item scale: Pearson, Cronbach, or Spearman-Brown? *International Journal of Public Health*, 58(4), 637-642. <https://doi.org/10.1007/s00038-012-0416-3>
- Fabrigar, L. R. y Wegener, D. T. (2012). *Exploratory factor analysis*. Oxford University Press. <https://doi.org/10.1093/acprof:osobl/9780199734177.001.0001>
- Field, A. P. (2018). *Discovering statistics using IBM SPSS statistics* (5ª ed.). SAGE.
- Floyd, F. J. y Widaman, K. F. (1995). Factor analysis in the development and refinement of clinical assessment instruments. *Psychological Assessment*, 7(3), 286-299. <https://doi.org/10.1037/1040-3590.7.3.286>
- George, D. y Mallery, P. (2003). *SPSS for Windows step by step: A simple guide and reference, 11.0 update* (4ª ed.). Allyn & Bacon.
- Gerlich, M. (2025). AI tools in society: Impacts on cognitive offloading and the future of critical thinking. *Societies*, 15(1), 6. <https://doi.org/10.3390/soc15010006>
- Gkintoni, E., Antonopoulou, H., Sortwell, A. y Halkiopoulos, C. (2025). Challenging cognitive load theory: The role of educational neuroscience and artificial intelligence in redefining learning efficacy. *Brain Sciences*, 15(2), 203. <https://doi.org/10.3390/brainsci15020203>
- Glick, D., Miedijensky, S. y Zhang, H. (2024). Examining the effect of AI-powered virtual-human training on STEM majors' self-regulated learning behavior. *Frontiers in Education*, 9, 1465207. <https://doi.org/10.3389/feduc.2024.1465207>
- Grüneke, T., Guggenberger, T., Hofmeister, S. y Stoetzer, J. C. (2024). AI-enabled self-regulated learning: A multi-layer taxonomy development. In *Proceedings of the 32nd European Conference on Information Systems (ECIS 2024)*, Paphos, Cyprus. (ISBN 978-1-958200-10-0). https://aisel.aisnet.org/ecis2024/track13_learning_teach/track13_learning_teach/4
- Hair, J. F., Black, W. C., Babin, B. J. y Anderson, R. E. (2010). *Multivariate data analysis* (7ª ed.). Pearson.
- Hertzog, M. A. (2008). Considerations in determining sample size for pilot studies. *Research in Nursing & Health*, 31, 180-191. <https://doi.org/10.1002/nur.20247>

- Hill, R. (1998). What sample size is 'enough' in Internet survey research? *Interpersonal Computing and Technology: An Electronic Journal for the 21st Century*, 6, 1–10.
- Hilpert, J. C., Greene, J. A. y Bernacki, M. (2023). Leveraging complexity frameworks to refine theories of engagement: Advancing self-regulated learning in the age of artificial intelligence. *British Journal of Educational Technology*, 54(5), 1204–1221. <https://doi.org/10.1111/bjet.13340>
- Hu, L. T. y Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling: A Multidisciplinary Journal*, 6(1), 1–55. <https://doi.org/10.1080/10705519909540118>
- Huang, A. Y. Q., Lu, O. H. T. y Yang, S. J. H. (2023). Effects of artificial intelligence-enabled personalized recommendations on learners' learning engagement, motivation, and outcomes in a flipped classroom. *Computers & Education*, 194, 104684. <https://doi.org/10.1016/j.compedu.2022.104684>
- Isaac, S. y Michael, W. B. (1995). *Handbook in research and evaluation: A collection of principles, methods, and strategies useful in the planning, design, and evaluation of studies in education and the behavioral sciences* (3ª ed.). EdITS Publishers.
- Jin, S.-H., Im, K., Yoo, M., Roll, I. y Seo, K. (2023). Supporting students' self-regulated learning in online learning using artificial intelligence applications. *International Journal of Educational Technology in Higher Education*, 20, 37. <https://doi.org/10.1186/s41239-023-00406-5>
- Johanson, G. A. y Brooks, G. P. (2009). Initial scale development: Sample size for pilot studies. *Educational and Psychological Measurement*, 70(3), 394–400. <https://doi.org/10.1177/0013164409355692>
- Jolliffe, I. (2014). Principal component analysis. En N. Balakrishnan, T. Colton, B. Everitt y W. W. Piegorsch (Eds.), *Wiley StatsRef: Statistics Reference Online*. John Wiley & Sons. <https://doi.org/10.1002/9781118445112.stat06472>
- Kaiser, H. F. y Rice, J. (1974). Little jiffy, mark IV. *Educational and Psychological Measurement*, 34(1), 111–117. <https://doi.org/10.1177/001316447403400115>
- Kline, P. (2014). *An easy guide to factor analysis*. Routledge. <https://doi.org/10.4324/9781315788135>
- Kong, S. C. y Yang, Y. (2024). A human-centered learning and teaching framework using generative artificial intelligence for self-regulated learning development through domain knowledge learning in K-12 settings. *IEEE Transactions on Learning Technologies*, 17, 1562–1573. <https://doi.org/10.1109/TLT.2024.3392830>
- Lai, J. W. (2024). Adapting self-regulated learning in an age of generative artificial intelligence chatbots. *Future Internet*, 16(6), 218. <https://doi.org/10.3390/fi16060218>
- Lan, M. y Zhou, X. (2025). A qualitative systematic review on AI empowered self-regulated learning in higher education. *npj Science of Learning*, 10(1). <https://doi.org/10.1038/s41539-025-00319-0>
- Li, Y., Sadiq, G., Qambar, G. y Zheng, P. (2025). The impact of students' use of ChatGPT on their research skills: The mediating effects of autonomous motivation, engagement, and self-directed learning. *Education and Information Technologies*, 30(4), 4185–4216. <https://doi.org/10.1007/s10639-024-12981-9>
- Liang, J., Wang, L., Luo, J., Yan, Y. y Fan, C. (2023). The relationship between student interaction with generative artificial intelligence and learning achievement: Serial mediating roles of self-efficacy and cognitive engagement. *Frontiers in*

- Psychology*, 14, 1285392. <https://doi.org/10.3389/fpsyg.2023.1285392>
- Liu, Z. M., Hwang, G. J., Chen, C. Q., Chen, X. D. y Ye, X. D. (2024). Integrating large language models into EFL writing instruction: Effects on performance, self-regulated learning strategies, and motivation. *Computer Assisted Language Learning*, 1-25. <https://doi.org/10.1080/09588221.2024.2389923>
- Mohamed, A. M., Shaaban, T. S., Bakry, S. H., Guillén-Gámez, F. D. y Strzelecki, A. (2025). Empowering the faculty of education students: Applying AI's potential for motivating and enhancing learning. *Innovative Higher Education*, 50(2), 587-609. <https://doi.org/10.1007/s10755-024-09747-z>
- Molenaar, I., Mooij, S. de, Azevedo, R., Bannert, M., Järvelä, S. y Gašević, D. (2023). Measuring self-regulated learning and the role of AI: Five years of research using multimodal multichannel data. *Computers in Human Behavior*, 139, 107540. <https://doi.org/10.1016/j.chb.2022.107540>
- Mooney, C. Z. y Duval, R. D. (1993). *Bootstrapping: A nonparametric approach to statistical inference*. SAGE. <https://doi.org/10.4135/9781412983532>
- Morgado, F. F. R., Meireles, J. F. F., Neves, C. M., Amaral, A. C. S. y Ferreira, M. E. C. (2017). Scale development: Ten main limitations and recommendations to improve future research practices. *Psicologia: Reflexão e Crítica*, 30(1). <https://doi.org/10.1186/s41155-016-0057-1>
- Muthén, L. K. y Muthén, B. O. (2017). *Mplus: Statistical analysis with latent variables: User's guide* (Version 8). Muthén & Muthén.
- Ng, D. T. K., Tan, C. W. y Leung, J. K. L. (2024). Empowering student self-regulated learning and science education through ChatGPT: A pioneering pilot study. *British Journal of Educational Technology*, 55(4), 1328-1353. <https://doi.org/10.1111/bjet.13454>
- O'Connor, B. P. (2000). SPSS and SAS programs for determining the number of components using parallel analysis and Velicer's MAP test. *Behavior Research Methods, Instruments, & Computers*, 32(3), 396-402. <https://doi.org/10.3758/BF03200807>
- Panadero, E. (2017). A review of self-regulated learning: Six models and four directions for research. *Frontiers in Psychology*, 8, 422. <https://doi.org/10.3389/fpsyg.2017.00422>
- Pintrich, P. R. (1999). The role of motivation in promoting and sustaining self-regulated learning. *International Journal of Educational Research*, 31(6), 459-470. [https://doi.org/10.1016/S0883-0355\(99\)00015-4](https://doi.org/10.1016/S0883-0355(99)00015-4)
- Pintrich, P. R. (2000). The role of goal orientation in self-regulated learning. En M. Boekaerts, P. R. Pintrich y M. Zeidner (Eds.), *Handbook of self-regulation* (pp. 451-502). Academic Press. <https://doi.org/10.1016/B978-012109890-2/50043-3>
- Schunk, D. H. y Zimmerman, B. J. (2012). Self-regulation and learning. En I. B. Weiner, G. E. Miller y W. M. Reynolds (Eds.), *Handbook of psychology: Vol. 7. Educational psychology* (2ª ed., pp. 59-78). John Wiley & Sons. <https://doi.org/10.1002/9781118133880.hop207003>
- Seo, K., Tang, J., Roll, I., Fels, S. y Yoon, D. (2021). The impact of artificial intelligence on learner-instructor interaction in online learning. *International Journal of Educational Technology in Higher Education*, 18(1), 54. <https://doi.org/10.1186/s41239-021-00292-9>
- Sun, J. (2005). Assessing goodness of fit in confirmatory factor analysis. *Measurement and Evaluation in Counseling and Development*, 37(4), 240-256. <https://doi.org/10.1080/07481756.2005.11909764>

- Teeluckdharry, N., Teeroovengadam, V. y Seebaluck, A. (2021). Scale development in marketing research. En R. Nunkoo, V. Teeroovengadam y C. M. Ringle (Eds.), *Handbook of research methods for marketing management* (pp. 17-50). Edward Elgar. <https://doi.org/10.4337/9781788976954.00007>
- Tinajero, C., Mayo, M. E., Villar, E. y Martínez-López, Z. (2024). Classic and modern models of self-regulated learning: Integrative and componential analysis. *Frontiers in Psychology*, 15, 1307574. <https://doi.org/10.3389/fpsyg.2024.1307574>
- Walter, Y. (2024). Embracing the future of artificial intelligence in the classroom: The relevance of AI literacy, prompt engineering, and critical thinking in modern education. *International Journal of Educational Technology in Higher Education*, 21(1), 15. <https://doi.org/10.1186/s41239-024-00448-3>
- Wang, C. Y. y Lin, J. J. H. (2023). Utilizing artificial intelligence to support analyzing self-regulated learning: A preliminary mixed-methods evaluation from a human-centered perspective. *Computers in Human Behavior*, 144, 107721. <https://doi.org/10.1016/j.chb.2023.107721>
- Wu, X. Y. y Chiu, T. K. F. (2025). Integrating learner characteristics and generative AI affordances to enhance self-regulated learning: A configurational analysis. *Journal of New Approaches in Educational Research*, 14(1). <https://doi.org/10.1007/s44322-025-00028-x>
- Xia, Q., Chiu, T. K. F., Chai, C. S. y Xie, K. (2023). The mediating effects of needs satisfaction on the relationships between prior knowledge and self-regulated learning through artificial intelligence chatbot. *British Journal of Educational Technology*, 54(4), 967–986. <https://doi.org/10.1111/bjet.13305>
- Yot-Domínguez, C. y Marcelo, C. (2017). University students' self-regulated learning using digital technologies. *International Journal of Educational Technology in Higher Education*, 14, 38. <https://doi.org/10.1186/s41239-017-0076-8>
- Zimmerman, B. J. (1989). Models of self-regulated learning and academic achievement. En B. J. Zimmerman y D. H. Schunk (Eds.), *Self-regulated learning and academic achievement: Theory, research, and practice* (pp. 1-25). Springer. https://doi.org/10.1007/978-1-4612-3618-4_1

APÉNDICES

Apéndice A: Ítems de la Escala de Aprendizaje Autorregulado Potenciado por IA (Escala AI-SRL)

Factor/ Ítem	Descripción	Escala de respuesta 1 = Totalmente en desacuerdo 5 = Totalmente de acuerdo
Competencia en IA		1 - 2 - 3 - 4 - 5
1.	Uso fácilmente herramientas de IA con diferentes interfaces.	1 - 2 - 3 - 4 - 5
2.	El uso activo de herramientas de IA mejora mi capacidad de aprendizaje.	1 - 2 - 3 - 4 - 5
3.	Puedo utilizar eficientemente las herramientas de IA para encontrar información relevante para mis estudios.	1 - 2 - 3 - 4 - 5
4.	Confío en mi capacidad para aprender a través de nuevas herramientas de IA.	1 - 2 - 3 - 4 - 5
5.	Las instrucciones de las herramientas de IA son fáciles de entender.	1 - 2 - 3 - 4 - 5
6.	Interpreto fácilmente la información generada por IA en mi proceso de aprendizaje.	1 - 2 - 3 - 4 - 5
Conciencia del aprendizaje		1 - 2 - 3 - 4 - 5
7.	La retroalimentación de las herramientas de IA me ayuda a comprender mis fortalezas de aprendizaje.	1 - 2 - 3 - 4 - 5
8.	La retroalimentación proporcionada por la IA me ayuda a identificar áreas de mejora.	1 - 2 - 3 - 4 - 5
9.	Evalúo la eficacia de las herramientas de IA para ayudarme a alcanzar mis objetivos de aprendizaje.	1 - 2 - 3 - 4 - 5
10.	Reflexiono críticamente sobre mi dependencia de las herramientas de IA para aprender.	1 - 2 - 3 - 4 - 5
Estrategias de aprendizaje		1 - 2 - 3 - 4 - 5
11.	Adapto mis métodos de estudio según las recomendaciones de las herramientas de IA.	1 - 2 - 3 - 4 - 5
12.	Uso herramientas de IA para encontrar las formas más eficaces de aprender temas nuevos.	1 - 2 - 3 - 4 - 5
13.	Utilizo la información generada por IA para mejorar mis habilidades de resolución de problemas.	1 - 2 - 3 - 4 - 5

14.	Al usar herramientas de IA para analizar diferentes perspectivas, mejoro mis habilidades de pensamiento crítico.	1 - 2 - 3 - 4 - 5
Implicación y eficiencia		1 - 2 - 3 - 4 - 5
15.	Mi participación en las actividades de aprendizaje aumenta con el uso de la IA.	1 - 2 - 3 - 4 - 5
16.	Las herramientas de IA me ayudan a lograr un aprendizaje más permanente.	1 - 2 - 3 - 4 - 5
17.	Creo que aprendo mejor cuando uso herramientas de IA.	1 - 2 - 3 - 4 - 5
18.	Creo que las herramientas de IA que se adaptan a mi estilo de aprendizaje aumentan mi implicación en el aprendizaje.	1 - 2 - 3 - 4 - 5
Colaboración ética		1 - 2 - 3 - 4 - 5
19.	Sé que debo asumir toda la responsabilidad cuando uso herramientas de IA para aprender.	1 - 2 - 3 - 4 - 5
20.	Soy consciente de las preocupaciones de privacidad en las herramientas de IA.	1 - 2 - 3 - 4 - 5
21.	Soy consciente de los posibles sesgos en las herramientas de IA.	1 - 2 - 3 - 4 - 5
22.	Soy consciente de la seguridad de la información que proporcione a las herramientas de IA.	1 - 2 - 3 - 4 - 5

Apéndice B: Ítems eliminados del modelo final con justificación empírica y conceptual

Fase	Ítem (redacción completa)	Factor original	Carga	Motivo de eliminación
AFE	Uso herramientas de IA para comprobar la eficacia de mi aprendizaje.	Probablemente Conciencia del Aprendizaje	.463/.439	Carga cruzada con diferencia < 0.10; con cargas de .463 y .439 en dos factores.
AFE	Reflexionar profundamente sobre las razones para usar herramientas de IA me ayuda a aplicarlas mejor en mis estudios.	Probablemente Estrategias de Aprendizaje	.285/.463	Carga cruzada en dos ítems; similar a otros ítems de integridad académica, también disminuyó la VME en el AFC.
AFE	Sé cómo usar éticamente la información generada por IA al aprender con IA.	Probablemente Colaboración Ética	.329/- .260/.491	Carga cruzada con diferencia < 0.10; con cargas de .329, -.260 y .491 en tres factores.

Fase	Ítem (redacción completa)	Factor original	Carga	Motivo de eliminación
AFC	Me resulta fácil adaptarme a las características cambiantes de las herramientas de IA.	Competencia en IA	.66	Disminuyó la VME; concepto cubierto por ítems más fuertes de Competencia en IA.
AFC	Soy capaz de usar las funciones específicas de las herramientas de IA (como análisis de datos o recomendación de contenido) para aprender.	Competencia en IA	.64	Disminuyó la validez discriminante; probablemente vago.
AFC	Las herramientas de IA me ayudan a priorizar mis objetivos de aprendizaje.	Conciencia del Aprendizaje	.64	Carga baja, disminuyó la VME y la validez discriminante.
AFC	Las herramientas de IA me ayudan a acceder a una amplia gama de recursos de aprendizaje.	Conciencia del Aprendizaje	.62	Disminuyó la VME; probablemente vago.
AFC	Las herramientas de IA me hacen más autónomo (independiente) en mi proceso de aprendizaje.	Conciencia del Aprendizaje	.59	Carga baja; representación débil del constructo.
AFC	Las herramientas de IA me ayudan a gestionar mejor mi tiempo de aprendizaje.	Conciencia del Aprendizaje	.63	Carga baja; disminuyó la VME.
AFC	Las herramientas de IA me ayudan a desarrollar estrategias para las tareas de aprendizaje.	Conciencia del Aprendizaje	.65	Carga baja; concepto cubierto por otros ítems de autosupervisión.
AFC	Las herramientas de IA me ayudan a entender temas complejos más fácilmente.	Conciencia del Aprendizaje	.64	Disminuyó la validez discriminante; mejor representado por otros ítems de supervisión del aprendizaje.
AFC	Soy escéptico/a sobre la capacidad de las herramientas de IA para proporcionar información precisa.	Colaboración Ética	.65	Carga marginal; probablemente vago.

Apéndice C: Cargas factoriales del modelo de AFE inicial

	Factor 1	Factor 2	Factor 3	Factor 4	Factor 5
Ítem 1	.860				
Ítem 2	.853				
Ítem 3	.555				
Ítem 4	.698				
Ítem 5	.693				
Ítem 6	.690				
Ítem 7	.672				
Ítem 8	.628				
Ítem 9		.665			
Ítem 10		.464			
Ítem 11		.676			
Ítem 12		.776			
Ítem 13		.489			
Ítem 14		.449			
Ítem 15				.725	
Ítem 16				.751	
Ítem 17				.835	
Ítem 18				.589	
Ítem 19		.684			
Ítem 20		.571			
Ítem 22		.498			
Ítem 23		.669			
Ítem 25					.636
Ítem 26					.916
Ítem 27					.861
Ítem 28					.669
Ítem 30			.625		
Ítem 31			.867		
Ítem 32			.789		
Ítem 33			.729		
Ítem 34			.850		

Nota: Todas las cargas son significativas a $p < .001$. Los errores estándar oscilaron entre .028 y .045.

Apéndice D: Alfa de Cronbach para cada factor y correlaciones ítem-factor

Factores/Descripción del ítem	Corre- lación ítem-total corregida	Alfa de Cronbach si se elimi- na el ítem	Alfa de Cronbach
Factor 1. Competencia en IA			.91
1. Uso fácilmente herramientas de IA con diferentes interfaces.	.60	.94	
2. El uso activo de herramientas de IA mejora mi capacidad de aprendizaje.	.60	.94	
3. Utilizo eficientemente las herramientas de IA para encontrar información relevante para mis estudios.	.66	.93	
4. Confío en mi capacidad para aprender a través de nuevas herramientas de IA.	.66	.93	
5. Las instrucciones de las herramientas de IA son fáciles de entender.	.64	.93	
6. Interpreto fácilmente la información generada por IA en mi proceso de aprendizaje.	.72	.93	
Factor 2. Conciencia del Aprendizaje			.88
7. La retroalimentación de las herramientas de IA me ayuda a comprender mis fortalezas de aprendizaje.	.61	.94	
8. La retroalimentación proporcionada por la IA me ayuda a identificar áreas de mejora.	.62	.93	
9. Evalúo la eficacia de las herramientas de IA para ayudarme a alcanzar mis objetivos de aprendizaje.	.65	.93	
10. Reflexiono críticamente sobre mi dependencia de las herramientas de IA para aprender.	.67	.93	
Factor 3. Estrategias de Aprendizaje			.84
11. Adapto mis métodos de estudio según las recomendaciones de las herramientas de IA.	.66	.93	
12. Uso herramientas de IA para encontrar las formas más eficaces de aprender temas nuevos.	.71	.93	
13. Utilizo la información generada por IA para mejorar mis habilidades de resolución de problemas.	.70	.93	
14. Al usar herramientas de IA para analizar diferentes perspectivas, mejoro mis habilidades de pensamiento crítico.	.56	.94	
Factor 4. Implicación y Eficiencia			.86
15. Mi participación en las actividades de aprendizaje aumenta con el uso de la IA.	.64	.93	

Factores/Descripción del ítem	Corre- lación ítem-total corregida	Alfa de Cronbach si se elimi- na el ítem	Alfa de Cronbach
16. Las herramientas de IA me ayudan a lograr un aprendizaje más permanente.	.60	.94	
17. Creo que aprendo mejor cuando uso herramientas de IA.	.63	.93	
18. Creo que las herramientas de IA que se adaptan a mi estilo de aprendizaje aumentan mi implicación en el aprendizaje.	.74	.93	
Factor 5. Colaboración Ética			.87
19. Sé que debo asumir toda la responsabilidad cuando uso herramientas de IA para aprender.	.58	.94	
20. Soy consciente de las preocupaciones de privacidad en las herramientas de IA.	.54	.94	
21. Soy consciente de los posibles sesgos en las herramientas de IA.	.60	.94	
22. Soy consciente de la seguridad de la información que proporciono a las herramientas de IA.	.55	.94	
Escala Completa			.94

Nota: IC del 95% calculados usando 5000 muestras bootstrap. Todas las correlaciones ítem-total son significativas a $p < .001$.

Fecha de recepción del artículo: 1 de junio de 2025

Fecha de aceptación del artículo: 27 de agosto de 2025

Fecha de aprobación para maquetación: 25 de septiembre de 2025

Fecha de publicación en OnlineFirst: 16 de octubre de 2025

Fecha de publicación: 1 de enero de 2026