

Pillars of Artificial Intelligence for Enhancing Reading Comprehension in Formal Education: A Scoping Review

Kenji Alberto Chung Sanchez¹; Steve Jason Umán Juarez²; Giovanna Irayda Alcántara Cuba de Byrne³; Carmen Rosa Hurtado Laura de Mera⁴; Luis Alberto Byrne Jaramillo⁵

¹Universidad Cesar Vallejo, Perú, kchungc@ucvvirtual.edu.pe

^{2,3,4,5}Universidad San Ignacio de Loyola, Perú, steve.umana@epg.usil.pe, giovanna.alcantara@epg.usil.pe, carmen.hurtadol@usil.pe, luis.byrne@epg.usil.pe

Abstract— Although Artificial Intelligence (AI) has shown a significant impact in various educational fields, its specific application in enhancing reading comprehension remains limited and fragmented. Most existing studies focus on isolated tools rather than offering an integrated perspective on how AI technologies can support reading processes across formal education levels. To address this gap, the present study aimed to identify and systematize the fundamental AI pillars with potential application in reading comprehension. A scoping review was conducted following the Arksey and O’Malley framework, comprising five stages. A total of 696 documents were retrieved from Scopus and Web of Science, from which 8 empirical studies were ultimately selected based on their practical evidence of AI use in literacy-related educational contexts. Using co-occurrence analysis through VOSviewer and qualitative synthesis, four key pillars were identified: (1) generative models for text simplification, (2) automatic question generation and narrative datasets, (3) personalized adaptive learning platforms, and (4) AI-supported moderation in online discussion environments. These pillars reflect a shift from instrumental to cognitively supportive uses of AI in educational settings. The findings offer both theoretical insights and practical guidance for educators, policymakers, and researchers interested in the ethical, inclusive, and meaningful integration of AI to foster reading comprehension.

Keywords-- Artificial Intelligence, Reading Comprehension, Adaptive Learning, Generative Models, Educational Technology.

Pilares de la Inteligencia Artificial para el Fortalecimiento de la Comprensión Lectora en la Educación Formal: Una Revisión de Alcance

Kenji Alberto Chung Sanchez¹; Steve Jason Umán Juarez²; Giovanna Irayda Alcántara Cuba de Byrne³; Carmen Rosa Hurtado Laura de Mera⁴; Luis Alberto Byrne Jaramillo⁵

¹Universidad Cesar Vallejo, Perú, kchungc@ucvvirtual.edu.pe

^{2,3,4,5}Universidad San Ignacio de Loyola, Perú, steve.umman@epg.usil.pe, giovanna.alcantara@epg.usil.pe, carmen.hurtadol@usil.pe, luis.byrne@epg.usil.pe

Resumen— Aunque la inteligencia artificial (IA) ha demostrado un impacto significativo en diversos ámbitos educativos, su aplicación específica en el fortalecimiento de la comprensión lectora sigue siendo incipiente y dispersa. La mayoría de los estudios se enfocan en herramientas aisladas, sin ofrecer una visión integradora sobre cómo estas tecnologías pueden apoyar los procesos de lectura en los distintos niveles educativos formales. Ante esta brecha, el presente estudio tuvo como objetivo identificar y sistematizar los pilares fundamentales de la IA con potencial de aplicación en la comprensión lectora. Para ello, se realizó una revisión de alcance siguiendo el marco metodológico de Arksey y O’Malley, que abarcó cinco etapas. Se analizaron 696 documentos provenientes de las bases de datos Scopus y Web of Science, seleccionando finalmente 8 estudios empíricos que evidencian el uso de la IA en prácticas educativas vinculadas a la lectura. A partir de un análisis de coocurrencia con el software VOSviewer y una síntesis cualitativa, se identificaron cuatro pilares clave: (1) modelos generativos para la simplificación de textos, (2) generación automática de preguntas y datasets narrativos, (3) plataformas personalizadas de aprendizaje adaptativo, y (4) moderación automatizada en entornos de discusión en línea. Estos pilares evidencian una transición de la IA desde funciones instrumentales hacia un acompañamiento activo en procesos cognitivos complejos. Los hallazgos aportan una base teórica y práctica para promover una integración ética, inclusiva y significativa de la IA en los procesos de enseñanza y aprendizaje de la comprensión lectora.

Palabras clave-- Inteligencia Artificial, Comprensión Lectora, Aprendizaje Adaptativo, Modelos Generativos, Tecnología Educativa.

I. INTRODUCCIÓN

La inteligencia artificial (IA) es una rama de la informática orientada al desarrollo de sistemas computacionales capaces de ejecutar tareas que tradicionalmente requerían la intervención de la inteligencia humana, como el razonamiento, la resolución de problemas, la toma de decisiones y el aprendizaje [1]. Su impacto ha sido transversal a múltiples sectores: en salud, ha optimizado el diagnóstico clínico y la monitorización de pacientes [2], en la industria, ha impulsado la automatización de procesos y el aumento de la eficiencia operativa [3], en el marketing, permite la personalización de contenidos para mejorar la experiencia del cliente [4], y en ciberseguridad, se emplea en la detección proactiva de amenazas, fortaleciendo la protección de sistemas digitales [5].

En el ámbito educativo, la IA está transformando los métodos tradicionales de enseñanza y aprendizaje mediante propuestas más dinámicas, adaptativas y centradas en el estudiante. [6] destaca que la IA posibilita experiencias personalizadas de aprendizaje al ajustar el contenido educativo según las necesidades, preferencias y ritmos de cada estudiante. Esta personalización se apoya en tecnologías como los sistemas de aprendizaje adaptativo y los tutores inteligentes, que brindan retroalimentación automatizada y apoyo individualizado.

No obstante, pese a su potencial disruptivo, la aplicación de la IA en los sistemas educativos, especialmente en lo referente al desarrollo de competencias lectoras, sigue siendo incipiente. Si bien algunos estudios se concentran en componentes específicos, como el aprendizaje automático o los agentes conversacionales, persiste una ausencia de enfoques integradores que permitan comprender cómo estas tecnologías pueden apoyar efectivamente los procesos de comprensión lectora en distintos niveles educativos.

Ante esta brecha, el presente estudio propone identificar y sistematizar los pilares de la Inteligencia Artificial con potencial de aplicación en el fortalecimiento de las competencias lectoras. Se parte de la premisa de que una adecuada integración de la IA en la educación puede no solo optimizar la enseñanza, sino también favorecer aprendizajes más significativos, inclusivos y contextualizados. Este trabajo aspira a ser una contribución sustantiva a la comunidad académica mediante una revisión de alcance [7] y crítica de las tendencias emergentes, desafíos éticos, y oportunidades tecnológicas que rodean el uso de la IA en el ámbito educativo.

Para entender con mayor claridad el propósito del estudio, es necesario precisar el significado de “pilar”. En este contexto, se considera pilar a un componente esencial que sustenta la integración de la inteligencia artificial en la educación universitaria en ciencias. Cada pilar agrupa conceptos, herramientas o enfoques clave que son fundamentales para aplicar la IA de manera efectiva en los procesos de enseñanza y aprendizaje [8]. Finalmente, La

pregunta que orienta esta revisión de alcance es: ¿Cuáles son los pilares de la Inteligencia Artificial (IA) que se están aplicando, o que poseen un potencial de aplicación, para mejorar la comprensión lectora en los distintos niveles formales de la educación?

II. METODOLOGÍA

Se empleó uno de los métodos más ampliamente utilizados para la realización de revisiones de alcance (scoping reviews), un enfoque investigativo que ha sido ampliamente aceptado debido a su capacidad para proporcionar una visión exhaustiva de la literatura relevante sobre un tema específico [7]. A continuación, se describen las etapas del marco metodológico adoptado para la ejecución del presente estudio de alcance:

Etapa 1: Identificación de la pregunta de investigación

¿Cuáles son los pilares de la Inteligencia Artificial (IA) que se están aplicando, o que tienen el potencial de aplicarse, para mejorar la comprensión lectora en los distintos niveles formales de la educación?

Etapa 2: Identificación de estudios relevantes

Para la identificación de estudios pertinentes, se exploraron inicialmente bases de datos académicas como Scopus, Web of Science, SCIELO, DOAJ, LATINDEX y REDALYC. Entre estas, se identificó que Scopus y Web of Science presentaban la mayor representatividad de publicaciones relevantes al objeto de estudio. En contraste, en las bases de datos SCIELO, DOAJ, LATINDEX y REDALYC se registró un número bajo o nulo de publicaciones relacionadas.

La ecuación de búsqueda se estructuró a partir de tres bloques temáticos directamente vinculados al estudio: Comprensión Lectora (block 1), Inteligencia Artificial (block 2) y formal education (block 3). Para ello, se combinaron descriptores y operadores booleanos de manera estratégica con el fin de identificar estudios pertinentes. Los bloques fueron enlazados mediante el operador booleano “AND”, y se consideraron los campos de búsqueda “TITLE-ABS-KEY”, como se detalla a continuación.

Block 1. Reading comprehension

"Reading comprehension*" OR "Text comprehension" OR "Reading skill*" OR "Reading literac*" OR "Reading proficient*" OR "Reading understand*" OR "Text understand*" OR "Reading abil*" OR "Literacy skill*" OR "Comprehension skill*" OR "Reading strateg*" OR "Reading competenc*") AND TITLE-ABS-KEY ("Artificial intelligence" OR "AI" OR "machine intelligence" OR "intelligent support" OR "intelligent agent*" OR "expert system" OR "neural network" OR "machine learning" OR "natural language processing" OR "ChatGPT" OR "educational AI" OR "chatbot*" OR "automated tutor" OR "personal tutor* " OR "intelligent virtual reality") AND TITLE-ABS-KEY ("early childhood education*" OR "preschool*" OR "nursery school*" OR "kindergarten*" OR "pre-primary education*" OR "childcare center*" OR "daycare*" OR "primary school*" OR "elementary school*" OR "grade school*" OR "basic education*" OR "secondary school*" OR "high school*" OR "middle school*" OR "secondary education*" OR "upper secondary school*" OR "K-12 education*" OR "compulsory education*" OR "general education*" OR "university*" OR "higher education*" OR "college*" OR "undergraduate education*" OR "tertiary education*" OR "bachelor degree*" OR "academic institution*" OR "post-secondary education*")

"Artificial intelligence" OR "AI" OR "machine intelligence" OR "intelligent support" OR "intelligent agent*" OR "expert system" OR "neural network" OR "machine learning" OR "natural language processing" OR "ChatGPT" OR "educational AI" OR "chatbot*" OR "automated tutor" OR "personal tutor* " OR "intelligent virtual reality"

Block 3. Formal education

"early childhood education*" OR "preschool*" OR "nursery school*" OR "kindergarten*" OR "pre-primary education*" OR "childcare center*" OR "daycare*" OR "primary school*" OR "elementary school*" OR "grade school*" OR "basic education*" OR "secondary school*" OR "high school*" OR "middle school*" OR "secondary education*" OR "upper secondary school*" OR "K-12 education*" OR "compulsory education*" OR "general education*" OR "university*" OR "higher education*" OR "college*" OR "undergraduate education*" OR "tertiary education*" OR "bachelor degree*" OR "academic institution*" OR "post-secondary education*")

Estrategia de búsqueda para Block 1, Block 2 and Block 3

(TITLE-ABS-KEY ("Reading comprehension*" OR "Text comprehension" OR "Reading skill*" OR "Reading literac*" OR "Reading proficient*" OR "Reading understand*" OR "Text understand*" OR "Reading abil*" OR "Literacy skill*" OR "Comprehension skill*" OR "Reading strateg*" OR "Reading competenc*") AND TITLE-ABS-KEY ("Artificial intelligence" OR "AI" OR "machine intelligence" OR "intelligent support" OR "intelligent agent*" OR "expert system" OR "neural network" OR "machine learning" OR "natural language processing" OR "ChatGPT" OR "educational AI" OR "chatbot*" OR "automated tutor" OR "personal tutor* " OR "intelligent virtual reality") AND TITLE-ABS-KEY ("early childhood education*" OR "preschool*" OR "nursery school*" OR "kindergarten*" OR "pre-primary education*" OR "childcare center*" OR "daycare*" OR "primary school*" OR "elementary school*" OR "grade school*" OR "basic education*" OR "secondary school*" OR "high school*" OR "middle school*" OR "secondary education*" OR "upper secondary school*" OR "K-12 education*" OR "compulsory education*" OR "general education*" OR "university*" OR "higher education*" OR "college*" OR "undergraduate education*" OR "tertiary education*" OR "bachelor degree*" OR "academic institution*" OR "post-secondary education*"))

En total, tomando el 31 del marzo del 2025 como fecha de corte, se obtuvieron un total de 318 en Scopus y 476 de web of science (WOS) documentos con lo cual finaliza la etapa inicial de identificación.

Etapa 3: Selección de estudios

Posteriormente se desarrolló la fase de selección, en la que se aplicó un proceso de depuración inicial mediante la

detección de duplicados en ambas bases de datos, utilizando el software RAYYAN AI. Este procedimiento permitió identificar y eliminar 98 registros repetidos, obteniéndose un total de 696 documentos únicos. Dado que la producción científica recuperada se encontraba distribuida en diversas áreas temáticas e idiomas, se aplicaron filtros por idioma (inglés y español) y por categoría temática: “Social Science” en Scopus, y “Social Sciences Citation Index (SSCI)” en Web of Science, seleccionando específicamente las categorías Education Educational Research, Linguistics y Language Linguistics. Tras esta depuración temática y lingüística, se excluyeron 511 registros, quedando 185 documentos pertinentes.

En la fase de elegibilidad, se incorporó el criterio de “acceso abierto” (OPEN ACCESS), lo que redujo el corpus a 67 documentos con texto completo disponible. Estos fueron exportados en formato RIS e importados al gestor bibliográfico Zotero para la revisión detallada de sus resúmenes. Finalmente, la fase de inclusión se basó en la verificación exhaustiva de los textos completos, considerando como principal criterio la presencia de evidencia práctica sobre el uso de inteligencia artificial como herramienta para el fortalecimiento de las competencias lectoras. Este análisis culminó con la inclusión de 8 estudios que cumplían con dicho criterio, los cuales fueron objeto de lectura integral y sistematización para su posterior síntesis cualitativa.

Siguiendo las directrices de [7], se establece una distinción clara entre las revisiones sistemáticas de la literatura y las revisiones de alcance. El presente estudio se adhiere a dicha distinción, dejando en claro que se trata de una revisión de alcance y no de una revisión sistemática. No obstante, se empleó el diagrama de flujo PRISMA 2020 [9] para mejorar la transparencia del proceso de selección y revisión (Fig. 1).

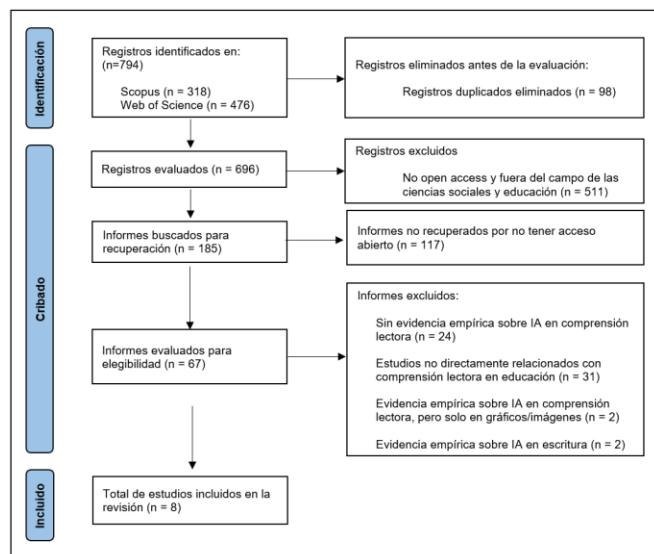


Figura 1. Diagrama de flujo PRISMA 2020 para nuevas revisiones sistemáticas, que incluyó búsquedas en bases de datos, registros y otras fuentes

Etapa 4: Representación gráfica de los datos

A partir del enfoque “analítico descriptivo” propuesto por [7], se elaboró un modelo analítico compartido que permitió organizar de manera coherente los datos obtenidos.

Para la redacción de la síntesis final de los estudios seleccionados, se empleó un marco analítico común que incluyó los elementos de objetivo, metodología, resultados y conclusiones. Posteriormente, con el fin de sistematizar la información y explorar las relaciones entre los términos más relevantes, se exportaron los estudios seleccionados en formato RIS y se analizaron mediante el software VOSviewer 1.6.20. A partir de este proceso, se generó un mapa de coocurrencia de términos basado en los textos completos o en los resúmenes de los artículos.

El análisis se centró en la identificación del nodo central del mapa, seguido del reconocimiento de clústeres diferenciados por colores, lo que permitió observar agrupaciones temáticas y relaciones significativas entre los términos. Asimismo, se consideró la conectividad entre los nodos como un indicador de la frecuencia y fuerza de las asociaciones entre conceptos. Con base en estos resultados, se procedió a la categorización de los hallazgos, lo que contribuyó a una interpretación más profunda de las temáticas abordadas en los estudios revisados.

Etapa 5: Recopilar, resumir e informar los resultados

La base de datos fue analizada en dos etapas. En la primera etapa, con el objetivo de obtener un primer acercamiento a los artículos evaluados para su elegibilidad, se exportaron en formato RIS e importaron posteriormente en el software VOSviewer 1.6.20. Este software permitió identificar relaciones y agrupar múltiples códigos en categorías temáticas. Tras la revisión de los artículos seleccionados, se logró identificar un total de 63 códigos, los cuales fueron organizados en 8 categorías iniciales (Fig. 2).

En la segunda etapa, utilizando la base de datos conformada exclusivamente por los estudios finalmente incluidos en la revisión, se llevó a cabo un análisis detallado y exhaustivo de cada artículo. Este proceso permitió refinar las categorías previamente identificadas y seleccionar las más representativas. Como resultado, se definieron las categorías emergentes, las cuales constituyen los cuatro pilares fundamentales sobre los que se sustenta el presente estudio.

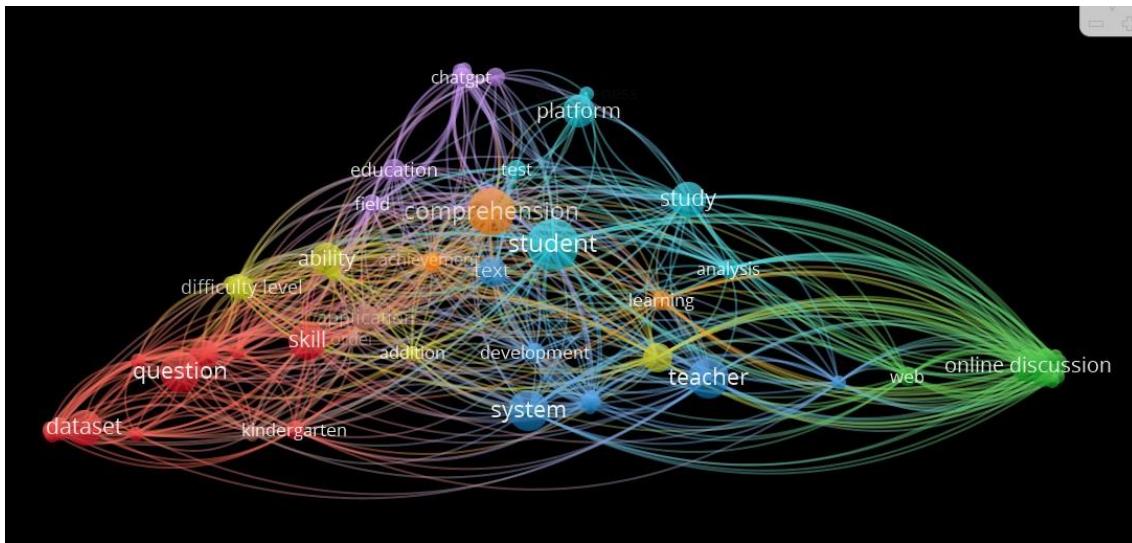


Figura 2. Gráfico de co-ocurrencia software VOSviewer 1.6.20

III. RESULTADOS

Los hallazgos de este estudio se organizaron en torno a cuatro ejes analíticos fundamentales. El análisis de los artículos seleccionados, descrito previamente en la Etapa 4 del marco metodológico, permitió identificar las principales categorías emergentes relacionadas con la IA en el campo de la comprensión lectora en el contexto educativo. Con el propósito de asegurar la trazabilidad y replicabilidad del proceso investigativo, los resultados se obtuvieron en dos etapas la primera a partir del análisis de coocurrencia de términos mediante el software VOSviewer 1.6.20.

Uno de los primeros pasos para interpretar el software consistió en la identificación del nodo central del mapa de coocurrencia, así como de los términos con mayor tamaño y centralidad visual. Los conceptos comprehension, student y text sobresalieron por su prominencia y frecuencia de aparición, lo que indicó una fuerte concentración temática en torno a la comprensión lectora desde la perspectiva del estudiante universitario, con el texto como eje estructural del análisis. Esta relación validó y reforzó el núcleo teórico de la investigación.

Posteriormente, se identificaron diversas agrupaciones temáticas representadas por colores distintos, cada una conformada por términos que coocurrieron con alta frecuencia dentro del corpus analizado. La agrupación asociada al color rojo estuvo conformada por términos como dataset, question y kindergarten, la agrupación amarilla incluyó palabras clave como ability, skill y difficulty level, asociadas a investigaciones que abordaron las capacidades lectoras, el nivel de dificultad textual y el desarrollo progresivo de

habilidades cognitivas. Por su parte, la agrupación azul estuvo compuesta por términos como system, teacher y development, lo que reflejó un enfoque vinculado al desarrollo docente, la mejora de los sistemas educativos y la integración tecnológica en la enseñanza. La agrupación verde incorporó conceptos como online discussion y web, lo que denotó la influencia de entornos digitales y plataformas virtuales en los procesos educativos. Finalmente, la agrupación violeta reunió términos como chatgpt, platform y education, lo que evidenció un interés emergente por la aplicación de herramientas de inteligencia artificial en contextos formativos, con especial atención a la evaluación automatizada y al aprendizaje asistido por tecnología.

En cuanto a la conectividad entre nodos, las líneas que vincularon los términos representaron la fuerza y frecuencia de sus relaciones semánticas. Se observó que el término student mantuvo una red densa de conexiones con otros conceptos, consolidándose como eje articulador dentro de los estudios analizados. Asimismo, el término teacher se relacionó con learning y system, lo que evidenció su rol clave como mediador entre los procesos educativos y el uso de tecnologías emergentes. Por otro lado, el término chatgpt mostró conexiones significativas con education, platform y test, lo que permitió inferir su reciente incorporación en prácticas pedagógicas, particularmente en contextos evaluativos mediados por inteligencia artificial.

En la segunda etapa, el análisis global del mapa de coocurrencias permitió identificar tendencias temáticas relacionadas con el uso de la inteligencia artificial en la comprensión lectora. Sin embargo, para fundamentar la elección de los pilares conceptuales, fue necesario complementar dicho análisis con una sistematización detallada

de los estudios seleccionados. A partir del análisis del contenido, propósitos, enfoques metodológicos y resultados de estos estudios, se identificaron cuatro categorías emergentes que agrupan de manera coherente los aportes más relevantes. Estas categorías emergentes encontradas son los pilares se presentan en la tabla I como una síntesis estructurada de los hallazgos

TABLA I
CATEGORÍAS EMERGENTES IDENTIFICADAS EN ESTUDIOS RECIENTES SOBRE COMPRENSIÓN LECTORA

Categorías emergentes	Artículos relacionados
Modelos de lenguaje basados en IA generativa	[10]
Datasets y sistemas de generación automática de preguntas (QG) y pares pregunta-respuesta (QAG)	[11], [12], [13]
Plataformas adaptativas basadas en IA	[14], [15]
Moderación y apoyo docente en entornos de discusión en línea	[16], [17]

III. DISCUSIÓN

Esta sección se centró en la sistematización de los alcances de la Inteligencia Artificial (IA) en la mejora de la comprensión lectora, basándose en buenas prácticas y evidencia empírica que respaldan cada uno de los pilares identificados. Asimismo, se consideraron los análisis y resultados de diversos estudios relacionados con la educación en diferentes niveles formales.

Es importante destacar que estos pilares no responden a una única tipología ni a un nivel específico de desarrollo de la IA, sino que comprenden una diversidad de elementos que incluyen subdisciplinas, recursos, herramientas, técnicas y componentes tecnológicos. Estos pueden ser aplicados de forma independiente o combinada para fortalecer procesos de comprensión lectora.

A. Modelos de lenguaje generativo: simplificación y accesibilidad del texto

El primer pilar se fundamenta en el uso de modelos de lenguaje generativo, como ChatGPT, que permiten reescribir y simplificar textos de forma automatizada. Estas herramientas son especialmente valiosas para adaptar materiales auténticos a niveles adecuados de comprensión, lo cual contribuye a reducir la carga cognitiva y la ansiedad lectora en los estudiantes. En esta línea, el estudio de [10] demuestra que la simplificación automatizada de blogs auténticos mediante ChatGPT mejora significativamente la comprensión y la capacidad inferencial en estudiantes de inglés como lengua extranjera.

Asimismo, las tecnologías basadas en inteligencia artificial generativa, como ChatGPT, han mostrado potencial para hacer más legibles y accesibles los textos académicos,

incluso para estudiantes con trastornos de lectura, como la dislexia [18]. Diversas estrategias de estimulación pueden emplearse para personalizar el proceso de simplificación textual según las necesidades individuales del alumnado, destacando el uso del estímulo meta como el más eficaz para mejorar la legibilidad. Por otro lado, los modelos de lenguaje de gran escala, como GPT-4o, han demostrado su capacidad para reducir la complejidad textual en los niveles léxico, sintáctico y discursivo. No obstante, aún se requiere un mayor refinamiento para igualar el desempeño de expertos humanos en la generación de textos con estructuras sintácticas más simples [19].

Finalmente, los modelos generativos aplicados a la comprensión lectora han evolucionado hacia enfoques más integrados, capaces de generar respuestas completas y naturales en lugar de limitarse a la extracción de información literal. Esta estrategia, en combinación con el aprendizaje multitarea, ha demostrado mejoras sustantivas en el rendimiento de los sistemas de comprensión lectora automatizada [20].

B. Generación automática de preguntas y datasets narrativos

El segundo pilar se sustenta en la aplicación de la inteligencia artificial para la generación automática de preguntas (QG) y de pares pregunta-respuesta (QAG), a partir de conjuntos de datos diseñados para evaluar distintos niveles de comprensión lectora. Estas herramientas permiten a los sistemas generar preguntas relevantes y alineadas con los contenidos y objetivos educativos, promoviendo procesos de evaluación más dinámicos y personalizados.

Diversos estudios han evidenciado el potencial de estos modelos. Por ejemplo, [11], [12], [13] demuestran cómo los modelos entrenados con bases de datos especializadas pueden formular preguntas que no solo evalúan el contenido literal, sino que también estimulan la reflexión y el pensamiento crítico, especialmente en contextos educativos donde el docente puede utilizar dichas herramientas tecnológicas con niños. En esta línea, el FairytaleQA Dataset se destaca como un referente: contiene 278 libros de cuentos infantiles con un total de 10,580 pares de preguntas y respuestas, diseñados para medir diversas dimensiones de la comprensión lectora. La riqueza y variedad de preguntas presentes en este conjunto permite entrenar modelos capaces de generar ítems más complejos e implícitos, cuyas respuestas no están directamente expresadas en el texto [21].

Otro ejemplo relevante complementario dentro de esta categoría es CoAsker, una herramienta de cocreación que permite a los estudiantes generar preguntas en colaboración con sistemas de IA. El cual ha demostrado mejorar tanto el compromiso estudiantil como la adquisición de conocimientos, en comparación con los métodos tradicionales [22]. Además de sus aplicaciones pedagógicas directas, los

sistemas de QG también representan una ventaja significativa en términos de gestión docente, la generación automatizada de preguntas de comprensión lectora y gramática contribuye a reducir la carga de trabajo de los docentes, facilitando la preparación de materiales y ejercicios para el autoaprendizaje [23].

Finalmente, esta tecnología puede integrarse en plataformas de tutoría de lectura, adaptando el nivel de dificultad de las preguntas a las características individuales de cada estudiante. Este tipo de personalización ha demostrado mejorar la eficiencia del aprendizaje y apoyar el desarrollo progresivo de habilidades lectoras [24].

C. Plataformas personalizadas adaptativas con IA para el desarrollo lector

El tercer pilar se centra en la implementación de plataformas adaptativas personalizadas basadas en inteligencia artificial, diseñadas para ajustar automáticamente los contenidos, las actividades y los niveles de dificultad de acuerdo con el rendimiento individual de cada estudiante. Estas plataformas integran tecnologías como motores de recomendación, redes bayesianas y otros algoritmos de aprendizaje automático, permitiendo un monitoreo preciso y continuo del progreso lector. Investigaciones recientes han evidenciado los beneficios de estas soluciones tecnológicas en el ámbito educativo. Por ejemplo, los estudios de [14], [15] destacan cómo estas herramientas pueden optimizar la planificación docente, facilitar la personalización del proceso de enseñanza y fomentar el aprendizaje autónomo, gracias a su capacidad de adaptación en tiempo real.

Además, se ha demostrado empíricamente que los estudiantes que utilizan plataformas basadas en IA obtienen mejores resultados en comprensión lectora en comparación con aquellos que no acceden a dichas tecnologías [15]. Un caso representativo es el del grupo experimental que utilizó la plataforma IAComprehend, el cual registró una mejora del 13,9 % en sus puntuaciones de comprensión lectora, mientras que el grupo de control experimentó una disminución [25]. Asimismo, sistemas de aprendizaje adaptativo como iSTART, que ajustan la complejidad textual según el desempeño del estudiante, han generado mejoras significativas en la comprensión lectora, especialmente entre los lectores con menores habilidades [26].

Finalmente, estos hallazgos sugieren implicancias relevantes para la práctica educativa. Los docentes y gestores educativos deberían considerar la integración de plataformas personalizadas basadas en IA como parte de sus estrategias de enseñanza, con el objetivo de potenciar las habilidades lectoras de los estudiantes. A su vez, los formuladores de políticas y desarrolladores curriculares pueden apoyarse en esta evidencia para diseñar prácticas pedagógicas más

eficaces, que incorporen de manera estratégica las tecnologías de inteligencia artificial [27].

D. Moderación y apoyo docente en entornos de discusión en línea

El cuarto pilar se centra en el uso de herramientas basadas en inteligencia artificial para el análisis y la moderación de discusiones en línea, las cuales brindan apoyo a los docentes en la gestión del aprendizaje colaborativo. Estas tecnologías permiten monitorear la participación estudiantil, identificar desviaciones temáticas y generar sugerencias automáticas para mantener la coherencia pedagógica del debate. Estudios como los de [17], en un enfoque inicial y [16], en un análisis experimental más reciente, evidencian cómo estos sistemas contribuyen al desarrollo del pensamiento crítico y al fortalecimiento del acompañamiento docente, a través de la provisión de retroalimentación lingüística y estructural en entornos virtuales.

Asimismo, se ha demostrado que las herramientas de IA, al integrar representaciones conductuales y cognitivas, pueden potenciar de manera significativa tanto el rendimiento académico como la presencia cognitiva de orden superior en contextos de aprendizaje colaborativo, aunque sus efectos sobre la motivación estudiantil aún no son concluyentes [28]. En este sentido, los asistentes digitales basados en IA han comenzado a desempeñar un rol activo en la moderación de discusiones, mediante el uso de indicaciones personalizadas que fomentan el compromiso del estudiante y mejoran su experiencia de aprendizaje [29].

De manera complementaria, el uso de técnicas como el Análisis Semántico Latente (LSA) ha permitido a estas herramientas supervisar de forma más eficiente la calidad de las interacciones, identificar grupos con dificultades de participación y generar intervenciones oportunas. Este enfoque no solo mejora la calidad de los comentarios generados, sino que también optimiza el tiempo de supervisión docente, permitiendo a los instructores centrarse en actividades pedagógicas de mayor valor agregado [30].

III. CONCLUSIONES

La inteligencia artificial (IA) se está consolidando como una herramienta pedagógica avanzada en el ámbito de la comprensión lectora. Se identificaron cuatro pilares fundamentales en los que se concentra su aplicación: (1) la simplificación de textos mediante modelos generativos, (2) la generación automática de preguntas y datasets narrativos, (3) las plataformas de aprendizaje personalizadas y adaptativas, y (4) la moderación asistida por IA en entornos virtuales colaborativos. Estos ejes evidencian una transición significativa de la IA, desde funciones esencialmente instrumentales hacia un acompañamiento activo en procesos

cognitivos complejos como la lectura crítica, la inferencia textual y el análisis discursivo.

Asimismo, el análisis permitió identificar un conjunto diversificado de herramientas tecnológicas asociadas a la IA educativa. Entre las más relevantes destacan los algoritmos de procesamiento del lenguaje natural, los sistemas de tutoría inteligente, los motores de recomendación, las tecnologías de análisis emocional, las plataformas de gamificación, y los modelos de aprendizaje supervisado y no supervisado. Estas tecnologías demuestran un potencial considerable para personalizar los procesos de enseñanza-aprendizaje, favoreciendo la atención a la diversidad y el fortalecimiento de la equidad educativa.

Entre las principales limitaciones del estudio se destaca la alta heterogeneidad metodológica de los artículos revisados, así como la prevalencia de fuentes de acceso restringido o bajo suscripción, lo que pudo limitar la inclusión de aportes relevantes publicados en otros contextos idiomáticos o académicos. Asimismo, se constata una escasez de investigaciones longitudinales que permitan evaluar de manera robusta el impacto sostenido de la IA en el desarrollo de habilidades lectoras.

A partir de estos hallazgos, se plantea como prioridad avanzar hacia investigaciones más rigurosas y sistemáticas que incorporen metaanálisis, revisiones críticas y evaluaciones empíricas en contextos multilingües y culturalmente diversos. Resulta igualmente fundamental promover estudios que exploren el uso activo de la IA por parte de docentes y estudiantes, especialmente en relación con la producción de textos académicos, la autorregulación del aprendizaje y los procesos de retroalimentación automatizada.

Finalmente, se proponen tres líneas de acción estratégicas orientadas a una integración crítica, ética y sostenible de la inteligencia artificial en los procesos de comprensión lectora: En el plano ético, es imperativo garantizar un uso equitativo, transparente y responsable de las tecnologías basadas en IA, asegurando que su implementación no reproduzca sesgos ni comprometa la autonomía del sujeto lector. Desde la perspectiva pedagógica, se requiere un rediseño curricular que articule de manera transversal el pensamiento crítico, la alfabetización digital y la competencia informacional, promoviendo una ciudadanía digital activa y reflexiva. En el ámbito tecnológico, resulta crucial avanzar hacia el desarrollo de modelos de IA aplicables, adaptativos y robustos, que incorporen estándares estrictos de protección de datos, trazabilidad de decisiones algorítmicas y capacidad de personalización educativa.

Enfrentar estos desafíos requiere el establecimiento de sinergias interdisciplinares entre educadores, desarrolladores tecnológicos y expertos en ciencias cognitivas, con el fin de consolidar un ecosistema educativo que incorpore la

inteligencia artificial de manera consciente, inclusiva y transformadora, al servicio de una comprensión lectora profunda y significativa en la educación del siglo XXI.

REFERENCIAS

- [1] C. Lexcellent, «Artificial Intelligence», en *SpringerBriefs Appl. Sci. Technol.*, Springer Verlag, 2019, pp. 5-21.
- [2] N. Ghavi Hossein-Zadeh, «Artificial intelligence in veterinary and animal science: applications, challenges, and future prospects», *Comput. Electron. Agric.*, vol. 235, 2025.
- [3] S. S. B. T. Lincy, «Artificial intelligence (AI) driven industrial automation», en *Ind. Autom.: The Technol., Platf. and Use Cases*, River Publishers, 2024, pp. 85-100.
- [4] B. Malviya, B. Othman, K. Saxena, y H. A. Almashaqbeh, «An Empirical Analysis in Measuring the Impact of Artificial Intelligence for Better Marketing Communication to the End-Users Effectively in the Digital Era», en *Int. Conf. Adv. Comput. Innov. Technol. Eng., ICACITE*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 2374-2378.
- [5] P. Vähäkainu y M. Lehto, «Artificial intelligence in the cyber security environment», en *Int. Conf. Cyber Warf. Secur., ICCWS*, Leenen L., van der Waag-Cowling N., y van der Waag-Cowling N., Eds., Academic Conferences and Publishing International Limited, 2019, pp. 431-440.
- [6] E. Mupaikwa, «The use of artificial intelligence in education: Applications, challenges, and the way forward», en *Emerg. Technol.-Based Serv. and Syst. in Libr., Educ. Inst., and Non-Profit Organ.*, IGI Global, 2023, pp. 26-50.
- [7] H. Arksey y L. O'Malley, «Scoping studies: towards a methodological framework», *Int. J. Soc. Res. Methodol.*, vol. 8, n.º 1, pp. 19-32, feb. 2005.
- [8] A. Deroncede-Acosta, O. Bellido-Valdiviezo, M. D. L. Á. Sánchez-Trujillo, M. L. Palacios-Núñez, H. Rueda-Garcés, y J. G. Brito-Garcías, «Ten Essential Pillars in Artificial Intelligence for University Science Education: A Scoping Review», *Sage Open*, vol. 14, n.º 3, jul. 2024.
- [9] M. J. Page *et al.*, «Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas», *Rev. Esp. Cardiol.*, vol. 74, n.º 9, pp. 790-799, sep. 2021.
- [10] F. Çelik, C. Y. Ersanlı, y G. Arslanbay, «Does AI Simplification of Authentic Blog Texts Improve Reading Comprehension, Inferencing, and Anxiety? A One-Shot Intervention in Turkish EFL Context», *Int. Rev. Res. Open Distrib. Learn.*, vol. 25, n.º 3, pp. 287-303, 2024.
- [11] Y. Tomikawa, A. Suzuki, y M. Uto, «Adaptive Question-Answer Generation With Difficulty Control Using Item Response Theory and Pretrained Transformer Models», *IEEE Trans. Learn. Technol.*, vol. 17, pp. 2240-2252, 2024.
- [12] Y. Xu *et al.*, «Fantastic Questions and Where to Find Them: FairytaleQA - An Authentic Dataset for Narrative Comprehension», *Proc. Annu. Meet. Assoc. Comput. Linguist.*, vol. 1, pp. 447-460, 2022.
- [13] B. Yao *et al.*, «It is AI's Turn to Ask Humans a Question: Question-Answer Pair Generation for Children's Story Books», *Proc. Annu. Meet. Assoc. Comput. Linguist.*, vol. 1, pp. 731-744, 2022.
- [14] E. U. Rodriguez-barrios *et al.*, «Bayesian approach to analyze reading comprehension: A case study in elementary school children in Mexico», *Sustain. Switz.*, vol. 13, n.º 8, 2021.
- [15] M. T. Hidayat, «Effectiveness of AI-Based Personalised Reading Platforms in Enhancing Reading Comprehension», *J. Learn. Dev.*, vol. 11, n.º 1, pp. 115-125, 2024.
- [16] S. Žitnik y G. Gordon Smith, «Automated analysis of postings in fourth grade online discussions to help teachers keep students on-track», *Interact. Learn. Environ.*, vol. 32, n.º 8, pp. 4587-4612, 2024.
- [17] J. Burstein, J. Shore, J. Sabatini, B. Moulder, S. Holtzman, y T. Pedersen, «The language museum system: linguistically focused instructional authoring», *ETS Res. Rep. Ser.*, vol. 2012, n.º 2, pp. i-36, 2012.

- [18] E. Hedlin, L. Estling, J. Wong, C. Demmans Epp, y O. Viberg, «Got It! Prompting Readability Using ChatGPT to Enhance Academic Texts for Diverse Learning Needs», en *Int. Conf. Learn. Anal. Knowl., LAK*, Association for Computing Machinery, Inc, 2025, pp. 115-125.
- [19] A. Smirnova, K. B. Chun, W. L. Rothman, y S. Sarma, «Text Simplification for Children: Evaluating LLMs vis-à-vis Human Experts», en *Conf Hum Fact Comput Syst Proc*, Association for Computing Machinery, 2025.
- [20] J. Qian, R. Huang, B. Zou, y Y. Hong, «Generative Reading Comprehension via Multi-task Learning», en *Chin. Nat. Conf. Comput. Linguist., CCL*, Sun M., Li S., Zhang Y., y Liu Y., Eds., Chinese National Conference on Computational Linguistic, 2020, pp. 301-312.
- [21] N. A. Kumar, N. Fernandez, Z. Wang, y A. Lan, «Improving Reading Comprehension Question Generation with Data Augmentation and Overgenerate-and-rank», en *Proc. Annu. Meet. Assoc. Comput Linguist.*, Kochmar E., Burstein J., Horbach A., Horbach A., Horbach A., Laarmann-Quante R., Madnani N., Tack A., Yaneva V., Yuan Z., Zesch T., y Zesch T., Eds., Association for Computational Linguistics (ACL), 2023, pp. 247-259.
- [22] M. Liu, J. Zhang, L. M. Nyagoga, y L. Liu, «Student-AI Question Cocreation for Enhancing Reading Comprehension», *IEEE Trans. Learn. Technol.*, vol. 17, pp. 815-826, 2024.
- [23] E. M. Perkoff, A. Bhattacharyya, J. Z. Cai, y J. Cao, «Comparing Neural Question Generation Architectures for Reading Comprehension», en *Proc. Annu. Meet. Assoc. Comput Linguist.*, Kochmar E., Burstein J., Horbach A., Horbach A., Horbach A., Laarmann-Quante R., Madnani N., Tack A., Yaneva V., Yuan Z., Zesch T., y Zesch T., Eds., Association for Computational Linguistics (ACL), 2023, pp. 556-566.
- [24] M. Uto, Y. Tomikawa, y A. Suzuki, «Difficulty-Controllable Neural Question Generation for Reading Comprehension using Item Response Theory», en *Proc. Annu. Meet. Assoc. Comput Linguist.*, Kochmar E., Burstein J., Horbach A., Horbach A., Horbach A., Laarmann-Quante R., Madnani N., Tack A., Yaneva V., Yuan Z., Zesch T., y Zesch T., Eds., Association for Computational Linguistics (ACL), 2023, pp. 119-129.
- [25] D. J. Mondia, K. N. Naranjo, S. T. Galamay, y N. M. C. Tiglao, «AIComprehend: An Adaptive Reading Comprehension Learning Platform Using Machine Learning», en *Int. Symp. Networks, Comput. Commun., ISNCC*, Institute of Electrical and Electronics Engineers Inc., 2023.
- [26] K. S. McCarthy, M. Watanabe, J. Dai, y D. S. McNamara, «Personalized learning in iSTART: Past modifications and future design», *J. Res. Technol. Educ.*, vol. 52, n.º 3, pp. 301-321, 2020.
- [27] H. Shafee Rad, «Reinforcing L2 reading comprehension through artificial intelligence intervention: refining engagement to foster self-regulated learning», *Smart Learn. Environ.*, vol. 12, n.º 1, 2025.
- [28] X. Kong, Z. Liu, C. Chen, S. Liu, Z. Xu, y Q. Tang, «Exploratory study of an AI-supported discussion representational tool for online collaborative learning in a Chinese university», *Internet High. Educ.*, vol. 64, 2025.
- [29] J. Lantz y J. C. Liu, «Student perceptions of learning with instructional AI assistance in online discussions: A case study», en *Handb. of Res. in Online Learn.: Insights and Adv.*, Brill, 2024, pp. 552-575.
- [30] N. Lavoie *et al.*, «Automating expertise in collaborative learning environments», *J. Asynchronous Learn. Netw.*, vol. 14, n.º 4, pp. 97-119, 2010.