



Metodología de la Investigación Científica en la Era de la Inteligencia Artificial

Enfoques, Herramientas y Desafíos para la
Generación del Conocimiento



Autores:

Ericka Torres Gaytan | Arturo Navarrete Sánchez | Moisés Malpica Córdova

Rufino III Contreras De León | Luis Alberto Limón Montelongo | Ivette Amalia Talavera Cortez






**Metodología de la investigación
científica en la era de la inteligencia
artificial: enfoques, herramientas y
desafíos para la generación del
conocimiento**

Autores:

Dra. Ericka Torres Gaytan
Mtro. Arturo Navarrete Sánchez
Mtro. Moisés Malpica Córdova
Mtro. Rufino III Contreras De León
Dr. Luis Alberto Limón Montelongo
Mtra. Ivette Amalia Talavera Cortez





PUERTO MADERO EDITORIAL

**Metodología de la investigación
científica en la era de la inteligencia
artificial: enfoques, herramientas y
desafíos para la generación del
conocimiento**

ISBN: 978-631-6557-97-1



Metodología de la investigación científica en la era de la inteligencia artificial: enfoques, herramientas y desafíos para la generación del conocimiento

Ericka Torres Gaytan... [et al.]

1a ed. - La Plata : Puerto Madero Editorial Académica, 2026.

Libro digital, PDF/A

Archivo Digital: descarga y online

ISBN **978-631-6960-02-3**

1. Metodología de la Investigación. 2. Inteligencia Artificial. 3. Educación Superior.

CDD 300

Forma sugerida de citación:

Torres Gaytan, E., Navarrete Sanchez, A., Malpica Córdova, M., Contreras de León, R. III, Limón Montelongo, L. A., & Talavera Cortez, I. A. (2026). *Metodología de la investigación científica en la era de la inteligencia artificial: Enfoques, herramientas y desafíos para la generación del conocimiento*. Puerto Madero Editorial Académica.



Licencia Creative Commons:

Atribución-NoComercial-SinDerivar 4.0 Internacional

(CC BY-NC-SA 4.0)



Primera Edición, septiembre 2026

Metodología de la investigación científica en la era de la inteligencia artificial: enfoques, herramientas y desafíos para la generación del conocimiento

ISBN: 978-631-6557-97-1

DOI: <https://doi.org/10.55204/PMEA.159>

Editado por:

Sello editorial: ©Puerto Madero Editorial Académica

Nº de Alta: 933832

Editorial: © Puerto Madero Editorial Académica

CUIL: 20630333971

Calle 45 N491 entre 4 y 5

Dirección de Publicaciones Científicas

La Plata, Buenos Aires, Argentina

Teléfono: +54 9 221 314 5902

Código Postal: AR1900



Diseño y Producción Editorial: Msc. Santillán, José Luis

Editor: PhD. Verenice Sánchez Castillo

Este libro se sometió a arbitraje bajo el sistema de doble ciego (peer review)

Revisado y publicado en Argentina



AUTORES

Ericka Torres Gaytan

Universidad Autónoma de Tamaulipas, UAMRR, México.

✉ eritgaytan@gmail.com

id <https://orcid.org/0009-0007-8978-3599>

Arturo Navarrete Sánchez

Instituto Mexicano del Seguro Social, México.

✉ arturo.navarretes@imss.gob.mx

id <https://orcid.org/0009-0004-3758-6268>

Moisés Malpica Córdova

Instituto Mexicano del Seguro Social (Jubilado) / Asesor Legislativo del Congreso del Estado de Tamaulipas / Fortis M&M Consultoría Jurídica y Estratégica, México.

✉ moimalpica10@gmail.com

id <https://orcid.org/0009-0007-81-9281>

Rufino III Contreras De León

Instituto Mexicano del Seguro Social, México.

✉ rufinocontreras@yahoo.com.mx

id <https://orcid.org/0009-0007-7396-3229>

Luis Alberto Limón Montelongo

Instituto Mexicano del Seguro Social, México.

✉ drlimon2106@outlook.com

id <https://orcid.org/0009-0002-8409-0324>

Ivette Amalia Talavera Cortez

Investigador Independiente, México.

✉ ivettetctz@gmail.com

id <https://orcid.org/0009-0008-7846-4012>

DEDICATORIA

Ericksa Torres Gaytan

A Dios, por acompañarme en cada paso, darme fortaleza en los momentos difíciles y regalarme la oportunidad de hacer realidad este sueño. A mi familia, mi mayor inspiración y mi refugio. Gracias por su amor, por creer en mí aun cuando yo dudaba, por su paciencia y por estar siempre a mi lado. Cada página de este libro lleva un pedacito de su amor y de todo lo que significan para mí. Con todo mi corazón, gracias por ser parte de este sueño.

Arturo Navarrete Sánchez

La participación en este libro está dedicado a mi esposa, por su amor, comprensión y apoyo incondicional; a mis tres hijos, por ser mi mayor inspiración y motivación para seguir creciendo; y a mis padres, por su amor, enseñanzas y por haber sembrado en mí los valores que me han acompañado a lo largo de la vida. Con todo mi amor y gratitud, este logro también es de ustedes.

Moisés Malpica Córdova

He comenzado oficialmente el proceso de coautoría de un nuevo libro, y es dedicado a la memoria de mi padre Dr. Moisés Malpica López, quien con la misma entrega que defendió la salud de sus pacientes como médico, guió los derechos contractuales de los trabajadores del IMSS en Tamaulipas y legisló con honor por su estado. Su vida fue un testimonio de servicio, liderazgo y vocación inquebrantable. Este libro es el reflejo de la inspiración y los valores que sembró en mí. Su legado sigue vivo en cada página.

Rufino III Contreras de León

Agradezco infinitamente a mis padres Rufino Contreras Cantu + y Gloria de León Ruiz + que siempre fueron mi apoyo, sin ellos no podría tener mis logros, a mi esposa Daniela mis hijas Valentina, Sophia Y Regina que son mi motivación para seguir adelante.

Luis Alberto Limón Montelongo

Agradezco primeramente a Dios por guiarme, a mi familia pero en especial a mi madre, Lic. Rosa Ma. Montelongo Villegas, su apoyo incondicional y presencia constante en cada etapa de mi vida. Gracias por creer siempre en mí, acompañar cada proyecto e impulsarme a alcanzar nuevas metas. Mi profunda gratitud por caminar a mi lado y ser parte esencial de mi historia.

Ivette Amalia Talavera Cortez

A Dios, por ser mi guía, mi fortaleza y la luz que ilumina cada paso de mi camino. A mis amadas hijas, Fernanda y Alexa, por ser mi mayor inspiración, mi motivo para seguir adelante y la razón de muchos de mis sueños. Que cada logro alcanzado sea también un reflejo del amor que siento por ustedes. Con todo mi amor, por ustedes y para ustedes.

“Que cada página de esta obra inspire nuevas preguntas, nuevas ideas y formas de comprender el conocimiento.”

- Los Autores

PRÓLOGO

La investigación científica se encuentra en un momento de profunda transformación. La expansión de la inteligencia artificial ha incorporado nuevas posibilidades para buscar información, organizar literatura, analizar datos, formular hipótesis, apoyar la escritura académica y comunicar resultados. Sin embargo, estos avances también exigen una reflexión rigurosa sobre sus límites, riesgos y responsabilidades.

Este libro surge con el propósito de ofrecer una mirada actualizada sobre la metodología de la investigación en un contexto donde las herramientas inteligentes comienzan a formar parte del trabajo científico cotidiano. A lo largo de sus capítulos se articulan fundamentos metodológicos, análisis de datos, búsqueda de evidencia, escritura científica, ética, transparencia y reproducibilidad, manteniendo siempre al investigador como responsable último del proceso.

La obra no propone sustituir el razonamiento humano por automatización. Por el contrario, parte de la convicción de que el verdadero valor de la inteligencia artificial aparece cuando fortalece la capacidad crítica, metodológica y analítica de quien investiga.

En una época caracterizada por abundancia de información y creciente automatización, la ciencia necesita más que nunca preguntas pertinentes, evidencia verificable y decisiones transparentes. Desde esa perspectiva, este libro invita a comprender la inteligencia artificial no como un reemplazo del investigador, sino como una herramienta que debe integrarse con rigor, ética y responsabilidad para contribuir a una generación de conocimiento científicamente sólida y socialmente relevante.

Investigar en educación es comprender la realidad para transformarla con conocimiento, reflexión y evidencia.

-Los autores

RESUMEN

El libro *Metodología de la investigación científica en la era de la inteligencia artificial: enfoques, herramientas y desafíos para la generación del conocimiento* analiza la transformación de los procesos investigativos ante la incorporación de tecnologías inteligentes. La obra aborda los fundamentos de la investigación científica, la formulación de problemas, preguntas, objetivos e hipótesis, así como la selección de enfoques, diseños, muestras e instrumentos. Asimismo, examina el uso de inteligencia artificial en la búsqueda, revisión y gestión de literatura científica, destacando su aplicación en revisiones sistemáticas y procesos de recuperación de información. También estudia la preparación, análisis e interpretación de datos mediante estadística, aprendizaje automático, análisis predictivo y procesamiento del lenguaje natural. Finalmente, profundiza en la escritura científica asistida por IA, la autoría, citación, transparencia, privacidad, sesgos, propiedad intelectual, reproducibilidad y ciencia abierta. Desde una perspectiva crítica, el libro propone integrar la inteligencia artificial como apoyo transversal, manteniendo la responsabilidad humana, el rigor metodológico, la ética y la verificación como principios esenciales para producir conocimiento científico confiable, transparente, pertinente y socialmente responsable.

Palabras clave: Metodología de la investigación, inteligencia artificial, conocimiento científico, integridad científica.

ABSTRACT

The book *Scientific Research Methodology in the Era of Artificial Intelligence: Approaches, Tools, and Challenges for Knowledge Generation* analyzes the transformation of research processes resulting from the incorporation of intelligent technologies. The work addresses the foundations of scientific research, the formulation of problems, research questions, objectives, and hypotheses, as well as the selection of approaches, designs, samples, and instruments. It also examines the use of artificial intelligence in the search, review, and management of scientific literature, highlighting its application in systematic reviews and information retrieval processes. In addition, the book explores data preparation, analysis, and interpretation through statistics, machine learning, predictive analysis, and natural language processing. Finally, it discusses AI-assisted scientific writing, authorship, citation, transparency, privacy, bias, intellectual property, reproducibility, and open science. From a critical perspective, the book proposes integrating artificial intelligence as a cross-cutting support tool while preserving human responsibility, methodological rigor, ethics, and verification as essential principles for producing reliable, transparent, relevant, and socially responsible scientific knowledge.

Keywords: Research methodology, artificial intelligence, scientific knowledge, research integrity.

INTRODUCCIÓN

La investigación científica constituye uno de los principales medios para comprender la realidad, explicar fenómenos, resolver problemas y generar conocimiento capaz de contribuir al desarrollo social, educativo, tecnológico y productivo. Sin embargo, las formas de investigar se encuentran atravesando una transformación profunda como consecuencia de la expansión de los entornos digitales, el crecimiento exponencial de la información disponible y la incorporación de sistemas de inteligencia artificial en distintas etapas del proceso científico.

En este escenario, investigar ya no implica únicamente dominar métodos cuantitativos, cualitativos o mixtos, diseñar instrumentos y analizar resultados. También supone aprender a interactuar con herramientas capaces de buscar literatura, clasificar documentos, generar hipótesis, procesar grandes volúmenes de datos, identificar patrones, apoyar la escritura académica y automatizar determinadas tareas. La inteligencia artificial ha comenzado a integrarse de manera progresiva en estas actividades, ampliando las posibilidades del investigador y modificando la manera en que se organiza, analiza y comunica el conocimiento.

No obstante, la incorporación de estas tecnologías también plantea nuevos desafíos. La velocidad con la que una herramienta puede producir una respuesta no garantiza su validez científica; un modelo puede generar textos coherentes y, al mismo tiempo, incluir errores, sesgos o referencias inexistentes. Del mismo modo, un algoritmo puede identificar relaciones estadísticas relevantes sin explicar necesariamente su significado o causalidad. Por esta razón, el uso de inteligencia artificial en investigación exige fortalecer, y no debilitar, competencias como el pensamiento crítico, la evaluación de fuentes, la transparencia metodológica, la reproducibilidad y la responsabilidad ética.

Este libro, titulado *Metodología de la investigación científica en la era de la inteligencia artificial: enfoques, herramientas y desafíos para la generación del conocimiento*, parte precisamente de esta concepción. Su propósito es ofrecer una visión actualizada de la metodología científica en un contexto donde las herramientas inteligentes comienzan a integrarse en diferentes momentos de la investigación.

El **Capítulo 1, Investigación científica y generación del conocimiento en la era de la inteligencia artificial**, introduce las principales transformaciones que atraviesa actualmente la actividad científica. Se analizan los cambios en los paradigmas y formas de producción del conocimiento, la importancia del pensamiento crítico y la creatividad científica, así como el papel de la inteligencia artificial dentro de los nuevos ecosistemas digitales de investigación. El capítulo destaca que la generación de conocimiento continúa dependiendo de la capacidad humana para cuestionar, interpretar y valorar críticamente la evidencia.

El **Capítulo 2, Diseño metodológico de investigaciones científicas apoyadas por inteligencia artificial**, aborda la construcción del problema científico, las preguntas de investigación, los objetivos, las hipótesis y las variables. Asimismo, desarrolla los principales enfoques metodológicos, los diseños experimentales y no experimentales, y las decisiones relacionadas con población, muestra, muestreo e instrumentos. Se enfatiza la importancia de mantener una adecuada coherencia metodológica aun cuando se utilicen herramientas inteligentes como apoyo.

El **Capítulo 3, Inteligencia artificial para la búsqueda, revisión y gestión de la literatura científica**, examina las transformaciones en los procesos de recuperación y organización de información académica. Se estudian estrategias avanzadas de búsqueda, bases de datos, motores inteligentes, sistemas de recomendación y aplicaciones de IA en revisiones sistemáticas y revisiones de alcance. El objetivo es mostrar que

la automatización puede incrementar la eficiencia, pero que la selección y evaluación final de la evidencia requiere criterios científicos claros.

El **Capítulo 4, Análisis, interpretación y comunicación de datos con inteligencia artificial**, profundiza en la preparación y depuración de bases de datos, la estadística descriptiva e inferencial, el aprendizaje automático, el análisis predictivo y el procesamiento del lenguaje natural. Se analiza la posibilidad de integrar técnicas tradicionales y emergentes para trabajar con información cuantitativa y cualitativa, destacando que la identificación de patrones no sustituye la interpretación científica ni la comprensión contextual.

El **Capítulo 5, Escritura científica, ética e integridad en investigaciones mediadas por inteligencia artificial**, aborda uno de los campos de mayor debate contemporáneo. Se analizan la escritura académica asistida por IA, la elaboración de artículos, libros, tesis e informes, así como cuestiones vinculadas con autoría, citación, transparencia, privacidad, sesgos algorítmicos, propiedad intelectual, reproducibilidad y ciencia abierta. Este capítulo sostiene que el uso responsable de estas tecnologías debe fundamentarse en la supervisión humana y en la capacidad del investigador para responder por cada decisión científica adoptada.

Finalmente, el **Capítulo 6, Innovación, automatización y nuevas fronteras de la investigación científica con inteligencia artificial**, analiza las transformaciones emergentes que están redefiniendo la forma de investigar. Se abordan la automatización inteligente de procesos y flujos de trabajo, el uso de agentes de inteligencia artificial y asistentes parcialmente autónomos, los laboratorios digitales, la simulación científica y las nuevas formas de experimentación asistida por IA. Asimismo, se examina la colaboración humano-IA, la investigación interdisciplinaria y las competencias que deberá desarrollar el investigador frente a estos nuevos escenarios.

ÍNDICE

Dedicatoria	11
Prólogo	14
Resumen	15
Abstract	16
Introducción	18
Índice	22
 Capítulo 1. Investigación científica y generación del conocimiento en la era de la inteligencia artificial	24
1.1. Transformaciones contemporáneas de la investigación científica	25
1.2. Paradigmas, enfoques y nuevas formas de producción del conocimiento	30
1.3. Pensamiento crítico, creatividad científica y formulación de problemas de investigación	32
1.4. Inteligencia artificial como apoyo al proceso investigativo	34
1.5. El investigador ante los nuevos ecosistemas digitales de conocimiento	37
Reflexión final del capítulo	42
 Capítulo 2. Diseño metodológico de investigaciones científicas apoyadas por inteligencia artificial	45
2.1. Del problema científico a la construcción de preguntas de investigación	46
2.2. Formulación de objetivos, hipótesis y variables con apoyo de herramientas inteligentes	49
2.3. Enfoques cuantitativo, cualitativo y mixto en entornos digitales	52
2.4. Diseños experimentales, no experimentales y emergentes	55
2.5. Población, muestra, muestreo e instrumentos de recolección de datos	59
Reflexión final del capítulo	64
 Capítulo 3. Inteligencia artificial para la búsqueda, revisión y gestión de la literatura científica	68
3.1. Estrategias avanzadas de búsqueda y recuperación de información científica	69
3.2. Bases de datos académicas, motores inteligentes y sistemas de recomendación	73
3.3. Inteligencia artificial aplicada a revisiones sistemáticas y revisiones de alcance	78
Reflexión final del capítulo	83
 Capítulo 4. Análisis, interpretación y comunicación de datos con inteligencia artificial	87

4.1. Preparación, depuración y gestión de datos de investigación	88
4.2. Estadística descriptiva e inferencial asistida por herramientas digitales	91
4.3. Inteligencia artificial, aprendizaje automático y análisis predictivo en investigación	94
4.4. Análisis cualitativo, procesamiento de lenguaje natural y extracción de patrones	99
Reflexión final del capítulo	104
Capítulo 5. Escritura científica, ética e integridad en investigaciones mediadas por inteligencia artificial	107
5.1. Escritura académica y científica asistida por inteligencia artificial generativa	108
5.2. Construcción de artículos, libros, tesis e informes científicos	109
5.3. Autoría, citación, transparencia y declaración del uso de inteligencia artificial	116
5.4. Sesgos algorítmicos, privacidad, propiedad intelectual e integridad científica	117
5.5. Reproducibilidad, ciencia abierta y futuro de la investigación científica	119
Reflexión final del capítulo	121
Capítulo 6. Innovación, automatización y nuevas fronteras de la investigación científica con inteligencia artificial	124
6.1. Automatización inteligente de procesos y flujos de investigación	125
6.2. Agentes de inteligencia artificial y asistentes autónomos para la investigación científica	127
6.3. Laboratorios digitales, simulación científica y experimentación asistida por IA	128
6.4. Investigación interdisciplinaria, colaboración humano-IA y generación de nuevo conocimiento	130
6.5. Tendencias emergentes, desafíos futuros y competencias del investigador en la era de la inteligencia artificial	133
Reflexión final del capítulo	134
Referencias bibliográficas	137

CAPÍTULO 1

Investigación científica y generación del conocimiento en la era de la inteligencia artificial



— Autora: —

Ericka Torres Gaytan

Capítulo 1

Investigación científica y generación del conocimiento en la era de la inteligencia artificial

La investigación científica atraviesa una transformación que supera la simple incorporación de nuevas herramientas tecnológicas. La digitalización de la información, el crecimiento de las bases de datos, la expansión de la ciencia abierta, el aprendizaje automático y, de manera más reciente, la inteligencia artificial generativa está modificando las formas de buscar antecedentes, formular preguntas, analizar grandes volúmenes de información, construir modelos, interpretar resultados y comunicar hallazgos. La inteligencia artificial comienza así a integrarse en distintas etapas del ciclo científico, aunque con niveles de desarrollo y apropiación diferentes entre disciplinas. Gao y Wang (2024), al estudiar cuantitativamente este fenómeno, encontraron que el uso y los beneficios potenciales de la IA se extienden ampliamente por las ciencias y han crecido con especial rapidez desde 2015.

Este escenario no significa que el método científico haya perdido vigencia. Por el contrario, obliga a fortalecer sus fundamentos. La posibilidad de obtener respuestas, clasificaciones, resúmenes, predicciones o visualizaciones en pocos segundos no elimina la necesidad de construir problemas pertinentes, definir métodos coherentes, evaluar evidencias y justificar las decisiones adoptadas. Una respuesta tecnológicamente sofisticada puede ser metodológicamente débil si parte de datos inadecuados, preguntas mal formuladas o supuestos no examinados.

Wang et al. (2023) sostienen que la inteligencia artificial está adquiriendo un papel creciente en el descubrimiento científico y muestran su aplicación en ámbitos tan diversos como el diseño de

moléculas y materiales, la predicción de estructuras y el desarrollo de nuevas estrategias para analizar fenómenos complejos. Su planteamiento permite comprender que la IA no debe observarse solamente como un recurso para redactar textos, sino como una tecnología capaz de intervenir en procesos de descubrimiento y generación de conocimiento.

Sin embargo, el entusiasmo tecnológico debe coexistir con una postura crítica. Resnik y Hosseini (2024) sintetizan esta tensión cuando afirman que utilizar inteligencia artificial en investigación, pero también genera cuestiones éticas nuevas y complejas. La cuestión central ya no consiste únicamente en determinar si la IA puede utilizarse, sino en establecer para qué, cómo, bajo qué criterios, con qué grado de supervisión humana y con qué mecanismos de transparencia.

Desde la perspectiva de este capítulo, la transformación contemporánea de la investigación puede entenderse como una transición desde un modelo predominantemente lineal hacia un ecosistema investigativo ampliado, caracterizado por la interacción entre investigadores, literatura científica, datos, infraestructuras digitales, algoritmos, herramientas generativas, comunidades académicas y sistemas abiertos de conocimiento. El desafío consiste en aprovechar esta capacidad tecnológica sin delegar aquello que constituye el núcleo intelectual de la investigación: pensar, cuestionar, contrastar, interpretar y asumir responsabilidad sobre las conclusiones alcanzadas.

1.1. Transformaciones contemporáneas de la investigación científica

Durante décadas, las transformaciones metodológicas de la ciencia estuvieron asociadas principalmente a la especialización disciplinar, al perfeccionamiento de técnicas estadísticas, al desarrollo de instrumentos de medición y a la aparición de nuevas aproximaciones epistemológicas. Actualmente, a estos procesos se añade un cambio de escala provocado

por la capacidad de almacenar, procesar y relacionar cantidades de información que difícilmente podrían ser examinadas de forma manual.

La incorporación de la inteligencia artificial amplía esta capacidad. Los sistemas computacionales pueden identificar asociaciones entre variables, clasificar documentos, reconocer patrones, procesar imágenes, trabajar con lenguaje natural y generar modelos predictivos. Resnik y Hosseini (2024) documentan que la IA ya se emplea en investigación para tareas relacionadas con el análisis y la interpretación de datos e imágenes, entre otras aplicaciones científicas. Esto evidencia que su influencia excede ampliamente la generación de textos mediante modelos conversacionales.

Gao y Wang (2024) ofrecen evidencia especialmente relevante al mostrar que la presencia de la inteligencia artificial dentro de la investigación científica no constituye un fenómeno marginal. Los autores encontraron un crecimiento sostenido de su aplicación en diferentes campos y, al mismo tiempo, identificaron una brecha entre la formación especializada en IA y su utilización efectiva dentro de la investigación. Además, advirtieron desigualdades disciplinarias y demográficas en la distribución de sus beneficios.

Esta observación introduce una dimensión que merece especial atención. La transformación tecnológica de la ciencia no ocurre de manera uniforme. Existen universidades con infraestructuras avanzadas, repositorios robustos, acceso a bases especializadas y equipos multidisciplinarios, mientras otras instituciones afrontan limitaciones económicas, tecnológicas y formativas. La democratización aparente de herramientas generativas no debe confundirse, por tanto, con una democratización completa de las capacidades científicas.

Otro cambio significativo se encuentra en la velocidad con la cual pueden ejecutarse determinadas actividades. La revisión inicial de una literatura extensa, la clasificación de documentos o el reconocimiento de

relaciones conceptuales pueden acelerarse mediante sistemas automatizados. Bolaños et al. (2024), por ejemplo, analizaron el empleo de inteligencia artificial en revisiones sistemáticas de literatura y señalaron el desarrollo de herramientas orientadas a apoyar y automatizar parcialmente diferentes fases del proceso, particularmente el cribado y la extracción de información.

No obstante, acelerar una actividad científica no significa necesariamente mejorar su calidad. La eficiencia solo representa un avance cuando se encuentra subordinada al rigor. Una revisión realizada con mayor rapidez puede continuar siendo deficiente si sus criterios de inclusión son ambiguos, si las fuentes consultadas son inadecuadas o si las decisiones automatizadas no son comprobadas por el investigador.

Tabla 1. Transformaciones de la investigación científica en el contexto de la inteligencia artificial

La Tabla 1 sintetiza algunas de las transformaciones más importantes que caracterizan la actividad investigativa contemporánea. La comparación permite apreciar que la modificación no se limita a las herramientas utilizadas, sino que alcanza la organización misma del trabajo científico.

Dimensión	Investigación convencional	Investigación en ecosistemas mediados por IA	Implicación metodológica
Acceso a información	Búsqueda principalmente manual y secuencial	Recuperación, clasificación y recomendación automatizada	Requiere mejorar estrategias de búsqueda y verificación
Revisión de literatura	Lectura y organización fundamentalmente manual	Cribado, extracción y síntesis parcialmente asistidos	La selección final debe mantener supervisión humana

Análisis de datos	Estadística y software especializado	Estadística, aprendizaje automático y modelos predictivos	Aumentan las exigencias de transparencia y reproducibilidad
Generación de hipótesis	Predominio del razonamiento del investigador	Exploración de relaciones y patrones apoyada por algoritmos	Las hipótesis deben conservar fundamentación teórica
Escritura científica	Elaboración íntegramente humana	Edición, síntesis y apoyo generativo	Es indispensable declarar y supervisar el uso de IA
Colaboración	Equipos institucionales y disciplinares	Redes globales, plataformas y entornos colaborativos	Se amplían los modelos interdisciplinarios
Reproducibilidad	Disponibilidad variable de procedimientos y datos	Código, modelos, datos y flujos computacionales compartibles	Mayor exigencia de documentación
Responsabilidad	Centrada en los autores	Continúa siendo humana aun cuando intervengan sistemas de IA	La tecnología no sustituye la responsabilidad científica

Fuente: elaboración propia a partir del análisis de Wang et al. (2023), Gao y Wang (2024), Heil et al. (2021), Bolaños et al. (2024) y Resnik y Hosseini (2024).

Como se observa, el cambio central reside en la ampliación de las capacidades disponibles para el investigador. Sin embargo, cada nueva posibilidad incorpora también nuevas responsabilidades. Si un algoritmo participa en el análisis, deben documentarse sus características; si una herramienta generativa interviene en la elaboración textual, su resultado necesita revisión; y si se utilizan datos complejos o modelos computacionales, la reproducibilidad adquiere una importancia todavía mayor.

Heil et al. (2021) sintetizan una idea fundamental mediante una expresión breve aluce sobre la confianza científica no se obtiene por la sofisticación del software utilizado, sino por la posibilidad de comprender, examinar y eventualmente reproducir los procedimientos que condujeron a determinado resultado. Por ello, los autores defienden estándares vinculados con la publicación de datos, modelos y código, así como mejores prácticas de programación y automatización de flujos de trabajo.

A mi juicio, esta es una de las transformaciones más importantes de la ciencia contemporánea: el investigador del futuro no será necesariamente quien utilice más inteligencia artificial, sino quien sea capaz de integrarla sin perder trazabilidad metodológica. La automatización puede ampliar la capacidad humana, pero cuando convierte el procedimiento en una caja negra termina debilitando precisamente aquello que pretende fortalecer.

1.2. Paradigmas, enfoques y nuevas formas de producción del conocimiento

La incorporación de inteligencia artificial ocurre dentro de una ciencia que ya se caracteriza por la diversidad metodológica. Los enfoques cuantitativos, cualitativos y mixtos responden a preguntas distintas y utilizan formas específicas de construir y analizar evidencia. La aparición de herramientas computacionales no invalida esta diversidad ni constituye por sí misma un nuevo paradigma metodológico universal.

En la investigación cuantitativa, los sistemas inteligentes pueden apoyar la identificación de patrones, clasificación, predicción y construcción de modelos. En determinados campos científicos, estas capacidades permiten explorar conjuntos de datos cuya magnitud excede las posibilidades del análisis tradicional. Wang et al. (2023) muestran cómo las técnicas de IA participan actualmente en procesos científicos

relacionados con distintas fases del descubrimiento, evidenciando su capacidad para ampliar la exploración del espacio de posibles soluciones.

En los estudios cualitativos, la inteligencia artificial abre posibilidades diferentes. Los modelos de lenguaje pueden ayudar a organizar grandes corpus documentales, sugerir agrupaciones temáticas, reconocer regularidades lingüísticas o facilitar una exploración preliminar de textos. Sin embargo, la interpretación contextual, cultural y teórica exige especial cautela. Un sistema puede reconocer regularidades estadísticas en el lenguaje sin compartir las experiencias humanas, sociales o históricas desde las cuales esos discursos adquieren significado.

Esta distinción es esencial. Procesar información no equivale automáticamente a comprender un fenómeno. En ciencias sociales, educación, salud, comunicación o humanidades, la explicación de los resultados necesita vincular los datos con contextos, teorías y sujetos concretos. Por ello, cualquier uso de IA debe responder primero a la naturaleza del problema investigado y no a la disponibilidad de una herramienta.

Los métodos mixtos también pueden beneficiarse de estas tecnologías, especialmente cuando una investigación necesita relacionar información cuantitativa con documentos, entrevistas, registros textuales o evidencia multimodal. En estos casos, la IA puede contribuir a manejar la complejidad de la información, aunque la integración entre tipos de evidencia sigue constituyendo una decisión metodológica del investigador.

Feuerriegel et al. (2024) explican que la IA generativa representa una categoría tecnológica capaz de producir contenido nuevo a partir de patrones aprendidos durante su entrenamiento. Sus posibilidades se extienden a texto, imágenes y otros tipos de información, lo cual explica

el rápido crecimiento de aplicaciones profesionales y científicas asociadas a estos modelos.

Sin embargo, desde una perspectiva epistemológica, resulta importante diferenciar entre generación de contenido y generación de conocimiento científico. Un modelo generativo puede producir una explicación lingüísticamente coherente, pero esa producción no adquiere automáticamente el estatus de conocimiento científico. Para ello debe insertarse en procesos de fundamentación, contrastación, validación, discusión y crítica.

Desde mi perspectiva como investigador, esta diferencia debería convertirse en uno de los principios rectores del uso académico de la IA. La fluidez de una respuesta puede producir una falsa sensación de certeza. Un párrafo bien escrito puede contener relaciones incorrectas; una referencia aparentemente convincente puede no existir; una síntesis puede omitir una posición científica relevante. Por ello, el investigador debe preguntarse permanentemente: ¿qué evidencia respalda esta afirmación?, ¿cómo fue obtenida?, ¿puede verificarse?, ¿qué supuestos contiene?, ¿qué interpretación alternativa sería posible?

Las nuevas formas de producción de conocimiento, por tanto, deberían entenderse como modelos de inteligencia ampliada, en los que las capacidades computacionales complementan —pero no anulan— el razonamiento científico humano.

1.3. Pensamiento crítico, creatividad científica y formulación de problemas de investigación

La disponibilidad creciente de sistemas inteligentes paradójicamente aumenta la importancia del pensamiento crítico. Cuando obtener información era difícil, una parte considerable del esfuerzo investigativo se concentraba en localizarla. En el escenario actual, el problema se desplaza hacia la capacidad de seleccionar,

evaluar, relacionar y cuestionar cantidades cada vez mayores de información.

Esto modifica incluso la concepción de competencia investigativa. Ya no resulta suficiente conocer procedimientos técnicos o dominar determinados programas. El investigador necesita distinguir evidencia científica de información superficial, reconocer limitaciones metodológicas, identificar inconsistencias y examinar críticamente resultados generados por sistemas automatizados.

La formulación del problema adquiere especial relevancia. Una inteligencia artificial puede sugerir preguntas, pero determinar cuáles poseen relevancia científica requiere comprender el estado del conocimiento y las necesidades del contexto. Un problema de investigación sólido emerge de una tensión identificable entre lo conocido y aquello que todavía necesita explicación, comprensión, contraste o transformación.

En este sentido, Bolaños et al. (2024) muestran que la IA puede apoyar procesos relacionados con la revisión de literatura y facilitar diferentes fases de una revisión sistemática. Esta capacidad puede contribuir a reconocer tendencias, vacíos y concentraciones temáticas; sin embargo, la decisión acerca de cuál vacío constituye un problema científicamente valioso continúa dependiendo del análisis del investigador.

La creatividad científica tampoco debería entenderse como improvisación. Supone establecer conexiones novedosas entre conceptos, observar un fenómeno desde perspectivas diferentes, construir nuevas hipótesis y diseñar procedimientos capaces de someter esas ideas a contraste. La IA puede ampliar el repertorio de alternativas consideradas, pero su utilidad será mayor cuando interactúe con un investigador que posea suficiente conocimiento para distinguir una asociación interesante de una relación conceptualmente inconsistente.

Puede proponerse, entonces, una secuencia crítica para la formulación de problemas mediados por herramientas inteligentes:

explorar → contrastar → delimitar → cuestionar → justificar → formular.

La IA puede intervenir especialmente en las primeras fases, pero las etapas relacionadas con pertinencia, viabilidad y justificación requieren razonamiento científico y comprensión contextual.

Resnik y Hosseini (2024) advierten, además, que los sistemas de aprendizaje automático pueden reproducir o amplificar sesgos presentes en los datos. Por tanto, el pensamiento crítico no debe aplicarse solamente a las conclusiones, sino también a los datos utilizados, a las categorías construidas, a las variables seleccionadas y a las decisiones incorporadas en los modelos.

En investigación, formular una pregunta correcta puede ser intelectualmente más importante que producir cien respuestas rápidas. Desde mi criterio, una de las mayores amenazas de la IA generativa no es que piense demasiado por el investigador, sino que el investigador se acostumbre a preguntar poco. La investigación comienza precisamente cuando una respuesta disponible deja de resultar suficiente y surge la necesidad de comprobarla, cuestionarla o ampliarla.

1.4. Inteligencia artificial como apoyo al proceso investigativo

La inteligencia artificial puede incorporarse prácticamente en todo el ciclo investigativo, aunque su función y el nivel de supervisión requerido varían entre etapas. Utilizada con criterios metodológicos claros, puede convertirse en un recurso para reducir tareas repetitivas y dedicar mayor atención a procesos de interpretación, diseño y razonamiento.

Durante la exploración inicial del problema, los sistemas generativos pueden contribuir a identificar conceptos relacionados,

organizar ideas preliminares o construir términos de búsqueda. En la revisión bibliográfica, pueden asistir en clasificación, cribado y extracción de información. Bolaños et al. (2024) analizaron precisamente la evolución de herramientas que utilizan inteligencia artificial para apoyar revisiones sistemáticas y encontraron una tendencia hacia procesos parcialmente automatizados, especialmente en actividades que demandan grandes volúmenes de revisión documental.

Durante el análisis de datos, el aprendizaje automático puede identificar estructuras y asociaciones difíciles de reconocer mediante aproximaciones convencionales. Resnik y Hosseini (2024) destacan que una de las ventajas potenciales de estos sistemas es precisamente su capacidad para identificar patrones y relaciones que podrían no resultar evidentes para los seres humanos.

En la escritura científica, Salvagno, Taccone y Gerli (2023) señalan que herramientas como ChatGPT pueden apoyar tareas de organización del material, elaboración de borradores y revisión lingüística. Sin embargo, concluyen con una delimitación particularmente importante y pueden asistir al investigador, pero no reemplazar su experiencia, juicio ni personalidad.

Esta idea debería mantenerse durante todas las etapas de una investigación: la IA funciona mejor como asistente metodológico y cognitivo, no como sustituto del investigador.

Tabla 2. Integración responsable de inteligencia artificial en el proceso investigativo

La Tabla 2 presenta una propuesta para organizar el uso de inteligencia artificial a lo largo del ciclo de investigación, diferenciando su posible aporte de las decisiones que deben mantenerse bajo responsabilidad humana.

Etapas investigativas	Posible apoyo de IA	Responsabilidad del investigador	Riesgo que debe controlarse
Identificación del tema	Explorar tendencias y conceptos relacionados	Determinar pertinencia científica y social	Elegir temas únicamente por popularidad
Formulación del problema	Generar preguntas preliminares	Delimitar, contextualizar y justificar el problema	Preguntas genéricas o sin vacío científico
Revisión de literatura	Buscar, clasificar, resumir y relacionar documentos	Verificar fuentes y evaluar evidencia	Referencias inexistentes o síntesis incorrectas
Diseño metodológico	Comparar métodos y apoyar planificación	Seleccionar y justificar el diseño	Utilizar procedimientos sin comprensión
Construcción de instrumentos	Sugerir dimensiones e ítems preliminares	Validar contenido y pertinencia	Sesgos y preguntas descontextualizadas
Gestión de datos	Clasificar, depurar y estructurar información	Garantizar calidad, privacidad y trazabilidad	Pérdida o exposición de información sensible
Análisis	Detectar patrones y construir modelos	Seleccionar técnicas e interpretar resultados	Sobreajuste, sesgo y análisis de caja negra
Discusión	Contrastar resultados preliminarmente	Interpretar desde teoría y contexto	Explicaciones plausibles, pero no demostradas
Escritura	Organizar, revisar y mejorar claridad textual	Comprobar contenido y asumir autoría	Plagio, errores y homogeneización del discurso
Publicación	Apoyar formato y comprobaciones	Declarar el uso de IA cuando corresponda	Falta de transparencia

Fuente: elaboración propia con base en Bolaños et al. (2024), Salvagno et al. (2023), Heil et al. (2021) y Resnik y Hosseini (2024).

La tabla evidencia una cuestión transversal: puede automatizarse una tarea, pero no debería automatizarse la responsabilidad sobre esa tarea. Si una herramienta propone una referencia inexistente y esta se incorpora a un artículo, la responsabilidad continúa correspondiendo al autor. Lo mismo ocurre con un análisis estadístico incorrecto, un sesgo inadvertido o una interpretación sin fundamento.

Resnik y Hosseini (2024) proponen precisamente que los investigadores describan y expliquen el uso de IA, identifiquen y controlen errores y sesgos relacionados con estos sistemas y comuniquen sus limitaciones de manera comprensible. Los autores también sostienen que los sistemas de IA no deberían figurar como autores, inventores o titulares de derechos, aunque sus contribuciones deben ser declaradas cuando corresponda.

En consecuencia, hablar de investigación asistida por IA debería implicar también hablar de trazabilidad. El investigador necesita poder explicar qué herramienta utilizó, para qué propósito, qué información proporcionó, qué resultado recibió, qué modificaciones realizó y cómo comprobó su validez cuando esta información resulte metodológicamente relevante.

1.5. El investigador ante los nuevos ecosistemas digitales de conocimiento

El investigador contemporáneo trabaja dentro de un ecosistema mucho más amplio que el conformado tradicionalmente por biblioteca, laboratorio y comunidad disciplinar. Bases bibliográficas globales, repositorios de datos, plataformas de preprints, identificadores digitales, gestores bibliográficos, repositorios de código, sistemas de colaboración y modelos de inteligencia artificial constituyen hoy parte de la infraestructura intelectual de numerosas disciplinas.

Este cambio exige competencias distintas. Saber utilizar herramientas tecnológicas resulta necesario, pero insuficiente. La

competencia esencial consiste en comprender cómo y cuándo utilizarlas, reconocer sus limitaciones y decidir cuándo el procedimiento tradicional es metodológicamente más adecuado.

También emerge una nueva relación entre productividad y calidad. Las herramientas generativas permiten producir textos, síntesis y materiales a una velocidad difícil de alcanzar mediante procesos exclusivamente manuales. Sin embargo, Watermeyer et al. (2024), a partir de un estudio con académicos del Reino Unido, advierten que la incorporación de IA generativa no necesariamente reduce las presiones asociadas con la intensificación del trabajo académico.

Esta reflexión resulta especialmente relevante para la investigación. Si la IA únicamente se emplea para producir más artículos, más rápido y con menos reflexión, su impacto puede terminar reforzando algunos de los problemas que ya enfrenta el sistema científico. En cambio, si permite disminuir tareas mecánicas y liberar tiempo para leer con profundidad, revisar datos, discutir resultados, formular mejores preguntas y fortalecer la escritura, puede convertirse en un verdadero apoyo al conocimiento.

La reproducibilidad también se convierte en una competencia central. Heil et al. (2021) argumentan que los análisis basados en aprendizaje automático necesitan estándares que permitan a terceros obtener resultados equivalentes mediante datos, modelos y código disponibles. Su planteamiento recuerda que un algoritmo sofisticado no adquiere valor científico únicamente porque alcance elevados niveles de desempeño; necesita insertarse en procedimientos suficientemente documentados y examinables.

A esta dimensión se suman los desafíos de equidad. Gao y Wang (2024) identificaron diferencias entre disciplinas y grupos en el aprovechamiento de los beneficios asociados con IA. Esto obliga a considerar que la transformación científica mediada por tecnología

también puede reproducir desigualdades vinculadas con infraestructura, capacitación, recursos y acceso a sistemas avanzados.

Por ello, considero que el perfil del investigador contemporáneo debería construirse alrededor de cinco capacidades integradas: competencia metodológica, pensamiento crítico, alfabetización en inteligencia artificial, integridad científica y capacidad interpretativa. Ninguna de ellas puede sustituir completamente a las demás.

Un investigador tecnológicamente competente pero metodológicamente débil podrá generar análisis sofisticados sin saber si responden adecuadamente al problema. Un investigador con buena formación metodológica pero sin alfabetización digital podría desaprovechar recursos capaces de ampliar su trabajo. Y quien domine ambos campos pero carezca de integridad científica puede utilizar la tecnología para acelerar prácticas que deterioren la credibilidad de la ciencia.

El desafío, por tanto, no consiste en formar investigadores dependientes de herramientas inteligentes, sino investigadores capaces de ejercer agencia intelectual sobre ellas. Esto supone decidir cuándo utilizar IA, cuándo cuestionarla, cuándo verificarla y, también, cuándo prescindir de ella.

A partir de los elementos desarrollados en este capítulo, resulta necesario comprender la generación del conocimiento científico como un proceso integrado en el que convergen la formulación rigurosa de problemas, la solidez metodológica, el pensamiento crítico, la ética y el uso responsable de herramientas de inteligencia artificial. La IA puede ampliar las capacidades del investigador en tareas de búsqueda, organización, análisis y comunicación; sin embargo, su incorporación adquiere verdadero valor científico únicamente cuando se encuentra acompañada por criterios de validación, trazabilidad y responsabilidad humana.

La Figura 1 sintetiza esta relación mediante un modelo que articula los principales componentes que intervienen en la investigación contemporánea.




Figura 1. Modelo integrador para la generación responsable del conocimiento científico en la era de la inteligencia artificial.

Como se observa en la Figura 1, la inteligencia artificial constituye solo uno de los componentes que participan en la generación del conocimiento científico. Su aporte se fortalece cuando interactúa con una adecuada problematización, un fundamento metodológico coherente, procesos de pensamiento crítico y principios de ética y transparencia. Esta integración evidencia que el uso de tecnologías inteligentes no sustituye las etapas esenciales de la investigación, sino que puede enriquecerlas cuando existe una conducción metodológica consciente.

Desde una perspectiva investigativa, el aspecto más relevante del modelo es que sitúa la responsabilidad científica en el ser humano. Explorar, formular, diseñar, analizar, interpretar, comunicar y verificar continúan siendo acciones que requieren juicio, criterio y capacidad de decisión.

Por ello, la incorporación de inteligencia artificial debe orientarse hacia una lógica de complementariedad, en la que la tecnología amplíe las posibilidades de análisis y procesamiento sin desplazar la reflexión crítica que otorga sentido y validez al conocimiento producido.

Reflexión final del capítulo

La inteligencia artificial marca una etapa relevante en la evolución de la investigación científica, pero sería reduccionista interpretarla únicamente como una revolución tecnológica. Su verdadero impacto se encuentra en las preguntas epistemológicas, metodológicas y éticas que obliga a reconsiderar: qué significa producir conocimiento, quién responde por las decisiones algorítmicas, cómo se garantiza la reproducibilidad y qué capacidades continuará necesitando el investigador.

La evidencia examinada permite sostener que la IA ya participa en diferentes ámbitos de la actividad científica. Wang et al. (2023) muestran su creciente relevancia en el descubrimiento científico; Gao y Wang (2024) documentan su expansión en múltiples campos; Bolaños et al. (2024) evidencian su potencial en la revisión de literatura; Salvagno et al. (2023) analizan su contribución a la escritura; Heil et al. (2021) recuerdan la centralidad de la reproducibilidad; mientras que Resnik y Hosseini (2024) sitúan en primer plano la transparencia, la responsabilidad y la ética.

Mi criterio es que la inteligencia artificial no disminuye la importancia del investigador; incrementa las exigencias sobre él. Cuando una máquina puede generar una respuesta en segundos, el valor científico se desplaza hacia la capacidad humana de establecer si esa respuesta es válida, pertinente, reproducible y significativa. Cuando miles de documentos pueden procesarse automáticamente, aumenta la importancia de saber cuáles fuentes merecen confianza. Cuando un modelo puede encontrar patrones que un ser humano no observa, se

vuelve todavía más importante comprender qué representan esos patrones y cuáles son sus límites.

Por ello, el futuro de la metodología científica no debería plantearse como una confrontación entre inteligencia humana e inteligencia artificial. El escenario más productivo será aquel en el cual ambas capacidades se articulen bajo principios científicos claramente definidos. La IA puede ampliar la exploración, acelerar determinados procesos y revelar relaciones difíciles de identificar; pero la formulación de preguntas relevantes, la interpretación contextual, la valoración ética y la responsabilidad sobre el conocimiento producido continúan perteneciendo al investigador.

En definitiva, investigar en la era de la inteligencia artificial implica aprender a trabajar con sistemas capaces de procesar y generar información sin renunciar al ejercicio crítico que define a la ciencia. La tecnología puede ampliar las posibilidades del descubrimiento; el rigor metodológico determina si ese descubrimiento puede convertirse realmente en conocimiento científico.

CAPÍTULO 2

Diseño metodológico de investigaciones científicas apoyadas por **inteligencia artificial**



Autor:

Arturo Navarrete Sánchez

Capítulo 2.

Diseño metodológico de investigaciones científicas apoyadas por inteligencia artificial

El diseño metodológico constituye uno de los núcleos fundamentales de toda investigación científica, porque transforma una inquietud inicial en un proceso estructurado de generación de conocimiento. Definir con precisión el problema, formular preguntas pertinentes, establecer objetivos coherentes, seleccionar variables, elegir un enfoque metodológico y determinar la población, la muestra y los instrumentos son decisiones que condicionan la calidad de los resultados obtenidos.

En la actualidad, estas decisiones se desarrollan dentro de un entorno caracterizado por una disponibilidad creciente de información, grandes volúmenes de datos, plataformas digitales y herramientas basadas en inteligencia artificial. Wang et al. (2023) señalan que la IA se está integrando progresivamente al descubrimiento científico y puede apoyar actividades como la generación de hipótesis, el diseño de experimentos, el análisis de grandes conjuntos de datos y la interpretación de resultados. Esto evidencia que su aplicación metodológica va mucho más allá de la asistencia en la escritura académica.

Sin embargo, incorporar inteligencia artificial en el diseño de una investigación no significa delegar las decisiones científicas a un algoritmo. Las herramientas inteligentes pueden ampliar el espacio de alternativas, detectar relaciones potenciales, organizar información o sugerir procedimientos, pero la correspondencia entre problema, objetivos, método y evidencia debe seguir siendo evaluada por el investigador. Resnik y Hosseini (2025) sostienen precisamente que los

investigadores conservan la responsabilidad de identificar y controlar errores y sesgos relacionados con la utilización de IA.

Desde esta perspectiva, el diseño metodológico contemporáneo puede concebirse como una interacción entre razonamiento científico, decisiones metodológicas y capacidades computacionales. La inteligencia artificial ofrece oportunidades para mejorar determinadas fases del proceso, pero esas oportunidades solo adquieren valor cuando se subordinan al rigor, la transparencia, la reproducibilidad y la comprensión del fenómeno investigado.

2.1. Del problema científico a la construcción de preguntas de investigación

Toda investigación comienza con una situación que demanda explicación, comprensión, contraste o transformación. No obstante, un tema de interés no constituye automáticamente un problema científico. El problema emerge cuando el investigador identifica una brecha entre el conocimiento disponible y aquello que todavía necesita ser comprendido o demostrado.

Por ejemplo, hay que afirmar que se desea investigar la inteligencia artificial en educación delimita apenas un campo temático. Un problema científico requeriría precisar qué dimensión se desconoce, cuál es su contexto, quiénes están involucrados, qué evidencia existe y qué aspecto continúa insuficientemente explicado.

La delimitación del problema exige, por tanto, un proceso de exploración documental y conceptual. En esta fase, las herramientas de inteligencia artificial pueden contribuir a organizar literatura, reconocer conceptos recurrentes, identificar líneas temáticas o descubrir relaciones entre investigaciones previas. Bolaños et al. (2024) explican que los sistemas de IA destinados a revisiones de literatura ya apoyan procesos como la búsqueda, el cribado y la extracción de información, aunque

advierten que estas herramientas todavía presentan desafíos relacionados con usabilidad, evaluación y transparencia.

El valor de la IA en esta fase se encuentra principalmente en su capacidad de ampliar la exploración. Frente a un campo con miles de publicaciones, un investigador puede utilizar herramientas automatizadas para reconocer tendencias iniciales, autores relevantes, conceptos vinculados o posibles vacíos. Sin embargo, identificar una ausencia documental no significa automáticamente haber encontrado un vacío científico.

Un vacío adquiere relevancia cuando puede justificarse su importancia teórica, metodológica, social o práctica.

Desde mi perspectiva, esta diferenciación es esencial porque existe una tendencia a confundir “tema poco estudiado” con “problema científicamente relevante”. No todo aquello sobre lo cual existen pocas publicaciones merece una investigación; en algunos casos, la escasez puede responder simplemente a una baja pertinencia científica. El investigador debe demostrar por qué estudiar ese fenómeno produciría conocimiento significativo.

La construcción de preguntas de investigación representa el siguiente paso. Una buena pregunta debe ser comprensible, delimitada, viable y coherente con el tipo de evidencia que se pretende obtener.

Las preguntas pueden cumplir diferentes funciones:

- **Descriptivas:** ¿qué características presenta determinado fenómeno?
- **Relacionales:** ¿qué asociación existe entre determinadas variables?
- **Explicativas:** ¿por qué ocurre determinado fenómeno?
- **Comparativas:** ¿qué diferencias existen entre grupos o condiciones?

- **Predictivas:** ¿en qué medida determinadas variables permiten anticipar un resultado?
- **Comprensivas:** ¿cómo interpretan los participantes determinada experiencia?

La inteligencia artificial puede ayudar a transformar ideas generales en preguntas más precisas, comparar diferentes formulaciones o advertir inconsistencias terminológicas. Sin embargo, la pertinencia científica de la pregunta no puede determinarse exclusivamente por su forma lingüística.

Wang et al. (2023) muestran que los sistemas de IA pueden apoyar incluso la generación de hipótesis y el descubrimiento de relaciones complejas. No obstante, los propios autores advierten sobre problemas asociados con la calidad de los datos y la necesidad de comprender cuándo estos enfoques necesitan mejoras.

Por ello, formular preguntas con apoyo de IA requiere trabajar desde una lógica de **asistencia crítica**. El investigador puede solicitar alternativas, pero debe contrastarlas con teoría, antecedentes y contexto.

Una secuencia metodológicamente recomendable sería:

**Tema general → revisión preliminar → situación problemática
→ vacío de conocimiento → delimitación → pregunta de
investigación.**

Desde mi criterio, la calidad de una investigación puede anticiparse en buena medida observando la calidad de su pregunta. Una pregunta confusa suele conducir a objetivos ambiguos, diseños poco coherentes y resultados difíciles de interpretar. Por el contrario, una pregunta bien construida funciona como eje articulador de todo el estudio.

2.2. Formulación de objetivos, hipótesis y variables con apoyo de herramientas inteligentes

Una vez formulada la pregunta de investigación, el siguiente paso consiste en traducirla en objetivos operativamente realizables. El objetivo general expresa la finalidad principal del estudio, mientras que los objetivos específicos descomponen esa finalidad en acciones concretas.

La relación entre problema, pregunta y objetivo debe mantener coherencia lógica.

Puede representarse de la siguiente manera:

**Problema → pregunta → objetivo general → objetivos
específicos → método → resultados esperados.**

Las herramientas inteligentes pueden apoyar esta fase mediante la comparación de formulaciones, detección de redundancias, análisis de coherencia terminológica o identificación de verbos que no correspondan con el alcance real del estudio.

Por ejemplo, una IA puede señalar que el verbo *determinar* quizá no sea adecuado para una investigación puramente exploratoria o advertir que dos objetivos específicos expresan prácticamente la misma acción. Sin embargo, estas sugerencias deben analizarse críticamente.

La tecnología no conoce automáticamente las restricciones institucionales, la disponibilidad de participantes, el acceso a datos, el tiempo disponible ni las condiciones reales del investigador.

- **Objetivos**

Los objetivos deben responder a cuatro criterios centrales: claridad, coherencia, viabilidad y verificabilidad.

Un objetivo como *analizar el impacto de la inteligencia artificial en la educación mundial* resulta excesivamente amplio. Una formulación metodológicamente más adecuada delimitaría población, contexto, variable o dimensión analizada y periodo.

La IA puede contribuir a ese proceso de refinamiento, pero el investigador debe evitar aceptar formulaciones artificialmente sofisticadas que pierdan relación con aquello que realmente puede estudiar.

- **Hipótesis**

Las hipótesis cumplen una función diferente. Constituyen proposiciones provisionales que plantean relaciones esperadas entre variables y que posteriormente serán sometidas a contrastación.

La incorporación de herramientas inteligentes permite explorar relaciones potenciales en grandes volúmenes de información. Wang et al. (2023) destacan precisamente que la IA puede apoyar a los científicos en la generación de hipótesis y en la identificación de patrones que podrían resultar difíciles de detectar mediante procedimientos tradicionales.

Sin embargo, aquí aparece una precaución metodológica importante: una relación estadística identificada algorítmicamente no debería convertirse automáticamente en hipótesis científica.

La hipótesis debe poseer:

**fundamentación teórica + plausibilidad científica +
posibilidad de contrastación.**

De lo contrario, podría transformarse en una simple correlación encontrada retrospectivamente.

- **Variables**

Las variables representan características que pueden adoptar diferentes valores y cuya operacionalización permite llevar conceptos teóricos a dimensiones observables.

En estudios cuantitativos, pueden clasificarse de distintas maneras:

- ✓ variable independiente → posible factor explicativo
- ✓ variable dependiente → resultado observado
- ✓ variables intervinientes → factores que pueden influir en la relación
- ✓ variables de control → elementos mantenidos o considerados analíticamente

La IA puede ayudar a revisar definiciones conceptuales, comparar dimensiones identificadas en literatura previa y sugerir indicadores iniciales. No obstante, la operacionalización constituye una decisión metodológica altamente dependiente del contexto.

Una herramienta generativa podría sugerir, por ejemplo, que la variable *competencia investigativa* incluye búsqueda de información, análisis de datos, escritura científica y pensamiento crítico. Esa propuesta puede resultar razonable, pero tendría que contrastarse con modelos teóricos y evidencia previa antes de utilizarse en una investigación.

Esta responsabilidad es especialmente importante cuando la IA interviene en decisiones sobre variables, categorías o indicadores, porque un sistema puede reproducir sesgos presentes en sus datos de entrenamiento.

Desde mi punto de vista, la IA resulta especialmente útil en esta fase cuando se utiliza como instrumento de contraste, no como fuente de

autoridad. Puede ayudar al investigador a preguntar: ¿existe otra manera de medir esta variable?, ¿hay dimensiones que estoy omitiendo?, ¿mis indicadores realmente representan el constructo? Pero la decisión final necesita fundamentación metodológica independiente.

2.3. Enfoques cuantitativo, cualitativo y mixto en entornos digitales

La elección del enfoque metodológico debe responder a la naturaleza del problema y no a la herramienta tecnológica disponible.

La presencia de inteligencia artificial no convierte automáticamente una investigación en cuantitativa, ni utilizar grandes cantidades de texto la transforma en cualitativa. El enfoque se define según el tipo de pregunta, evidencia, razonamiento y procedimiento de análisis adoptado.

- **Enfoque cuantitativo**

El enfoque cuantitativo se orienta al análisis de variables medibles, relaciones, diferencias y patrones susceptibles de representación numérica.

La incorporación de IA puede fortalecer este enfoque mediante:

- ✓ clasificación automática;
- ✓ reconocimiento de patrones;
- ✓ predicción;
- ✓ procesamiento de grandes bases de datos;
- ✓ aprendizaje automático;
- ✓ detección de anomalías;
- ✓ modelamiento de relaciones complejas.

Gao y Wang (2024) demostraron que la utilización de inteligencia artificial en investigación científica se ha expandido notablemente entre diferentes disciplinas y que sus beneficios potenciales están vinculados,

entre otros factores, con la capacidad de ampliar la productividad y abordar problemas complejos.

Sin embargo, un modelo complejo no es necesariamente un modelo mejor. Las técnicas de aprendizaje automático pueden aumentar capacidad predictiva mientras disminuyen interpretabilidad. Heil et al. (2021) advierten que algunos modelos de aprendizaje automático son más difíciles de interpretar que modelos simples y que esa opacidad puede ocultar sesgos.

Por ello, la selección entre una regresión convencional, un modelo de clasificación o un algoritmo más avanzado debería responder al problema y no a la novedad tecnológica.

- **Enfoque cualitativo**

El enfoque cualitativo busca comprender experiencias, significados, discursos, procesos, prácticas o dinámicas sociales desde una perspectiva contextual.

La IA puede apoyar especialmente:

**transcripción → organización documental → codificación
exploratoria → identificación de recurrencias → agrupamiento
temático.**

No obstante, identificar palabras recurrentes no equivale a comprender su significado.

Un sistema puede reconocer que determinadas expresiones aparecen juntas, pero comprender por qué un participante utiliza cierto concepto implica considerar contexto, trayectoria, relaciones sociales y marcos culturales.

Por ello, la interpretación cualitativa no debería quedar reducida al análisis automatizado de texto.

Las herramientas de IA pueden resultar particularmente útiles como mecanismo de segunda lectura: el investigador realiza una codificación inicial y posteriormente compara sus categorías con agrupaciones sugeridas por el sistema. Esta estrategia puede ayudar a detectar omisiones, pero no sustituye la interpretación.

- **Enfoque mixto**

Los diseños mixtos combinan evidencias cuantitativas y cualitativas buscando una comprensión más amplia de un fenómeno.

En entornos digitales, esta integración puede fortalecerse porque actualmente es posible trabajar simultáneamente con:

datos numéricos + textos + imágenes + registros digitales + información longitudinal.

Aquí la inteligencia artificial posee un potencial considerable, particularmente para estructurar información multimodal.

Sin embargo, la integración metodológica continúa siendo fundamental. No basta con realizar una encuesta y varias entrevistas para afirmar que existe un diseño mixto. Es necesario demostrar cómo ambos tipos de evidencia se relacionan y qué comprensión adicional emerge de esa integración.

Desde mi criterio, la IA abre una oportunidad para superar cierta división tradicional entre datos cuantitativos y cualitativos. Los ecosistemas digitales producen información cada vez más compleja, y los futuros diseños de investigación probablemente integrarán con mayor frecuencia múltiples tipos de evidencia. Pero esa evolución requiere todavía más conocimiento metodológico, no menos.

2.4. Diseños experimentales, no experimentales y emergentes

Una vez definido el enfoque, el investigador debe seleccionar un diseño que determine cómo se obtendrá la evidencia necesaria para responder la pregunta planteada.

- **Diseños experimentales**

Los diseños experimentales buscan establecer relaciones causales mediante manipulación de variables y control de determinadas condiciones.

En términos generales, implican:

intervención → comparación → control → medición.

Las herramientas de IA pueden contribuir a la planificación experimental mediante simulación, selección de configuraciones, predicción de posibles resultados o identificación de combinaciones prometedoras.

Wang et al. (2023) documentan aplicaciones en las que la IA apoya el diseño experimental y procesos de descubrimiento en campos científicos complejos. Los autores describen que estos sistemas pueden ayudar a generar diseños y explorar espacios de posibilidades difíciles de abordar manualmente.

Esto plantea una transformación significativa. Tradicionalmente, muchos experimentos estaban limitados por la cantidad de combinaciones que podían ser evaluadas. Los modelos computacionales pueden priorizar cuáles experimentar primero, optimizando recursos.

No obstante, una predicción algorítmica continúa siendo diferente de una comprobación experimental.

- **Diseños no experimentales**

Los diseños no experimentales analizan fenómenos tal como ocurren sin manipulación deliberada de variables.

Entre ellos se encuentran estudios: descriptivos, correlacionales, comparativos, transversales y longitudinales.

La IA puede aportar capacidades para analizar grandes conjuntos de datos observacionales y encontrar asociaciones complejas. Sin embargo, este potencial también incrementa el riesgo de interpretar asociaciones como causalidad.

La existencia de patrones no demuestra necesariamente que una variable cause otra. Por ello, cuanto mayor sea la capacidad tecnológica de encontrar relaciones, mayor debe ser el cuidado epistemológico para interpretarlas.

- **Diseños emergentes**

La investigación contemporánea está generando configuraciones que no siempre encajan completamente dentro de las clasificaciones tradicionales.

Entre ellas pueden mencionarse:

- ✓ investigaciones basadas en grandes datos;
- ✓ experimentos computacionales;
- ✓ simulaciones;
- ✓ análisis de redes complejas;
- ✓ minería de textos;
- ✓ estudios con datos multimodales;
- ✓ investigación con datos sintéticos;
- ✓ diseños híbridos humano-IA.

Resnik y Hosseini (2025) prestan especial atención al uso de datos sintéticos y recomiendan que los investigadores indiquen claramente qué partes del conjunto de datos son sintéticas, cómo fueron generadas y por qué fueron utilizadas.

Este tipo de prácticas demuestra que la metodología necesita incorporar nuevos niveles de documentación. Ya no basta con describir quiénes participaron y qué instrumento se aplicó; en determinadas investigaciones también será necesario documentar versiones de modelos, parámetros, procesos computacionales, conjuntos de entrenamiento y procedimientos algorítmicos.

Sänger et al. (2024), al analizar cualitativamente el uso de ChatGPT para desarrollar flujos de trabajo científicos, examinaron hasta qué punto un modelo de lenguaje podía contribuir a tareas asociadas con procesos de investigación. Su trabajo constituye un ejemplo de cómo los modelos generativos comienzan a incorporarse a flujos científicos más amplios y no exclusivamente a tareas de redacción.

Desde mi análisis, los diseños emergentes no deberían sustituir las clasificaciones tradicionales, sino ampliarlas. Lo fundamental continúa siendo responder preguntas metodológicas clásicas: ¿qué se observa?, ¿cómo se observa?, ¿qué evidencia permitirá sostener una conclusión?, ¿qué sesgos pueden intervenir?, ¿hasta dónde pueden generalizarse los resultados?

2.5. Población, muestra, muestreo e instrumentos de recolección de datos

Toda investigación empírica necesita delimitar con precisión de dónde proviene la evidencia.

La población corresponde al conjunto de unidades sobre el cual se pretende producir conocimiento, mientras que la muestra constituye la porción seleccionada para participar efectivamente en el estudio.

La elección entre estudiar toda la población o seleccionar una muestra depende del tamaño, disponibilidad, recursos y características del fenómeno.

- **Muestreo probabilístico**

Los procedimientos probabilísticos buscan ofrecer a las unidades de la población una probabilidad conocida de selección.

Entre los principales se encuentran: aleatorio simple, sistemático, estratificado y por conglomerados. Son especialmente importantes cuando se busca realizar inferencias hacia una población mayor.

- **Muestreo no probabilístico**

En otras investigaciones, especialmente cualitativas o exploratorias, pueden emplearse procedimientos como: intencional, por conveniencia, bola de nieve o selección teórica.

Estos procedimientos responden a finalidades diferentes y no deberían evaluarse utilizando exactamente los mismos criterios de representatividad estadística.

En entornos digitales, el muestreo adquiere nuevos desafíos. Un estudio puede trabajar con usuarios de plataformas digitales, registros de interacción, publicaciones públicas o grandes bases secundarias. En estos casos, disponer de millones de observaciones no elimina automáticamente los problemas de selección.

Una base enorme puede continuar estando sesgada si representa principalmente a determinados grupos.

Gao y Wang (2024) muestran que los beneficios de la IA en investigación no se distribuyen uniformemente y encuentran desigualdades según campos científicos y características de los

investigadores. Este hallazgo permite recordar que los datos científicos y tecnológicos tampoco se producen en contextos neutrales.

- **Instrumentos de recolección de datos**

Los instrumentos permiten obtener la evidencia necesaria y deben seleccionarse según el problema, enfoque y diseño.

Algunos de los más frecuentes son: cuestionarios, escalas, entrevistas, guías de observación, pruebas, registros documentales y bases digitales.

La inteligencia artificial puede apoyar diferentes fases:

construcción preliminar → revisión de redacción → detección de ambigüedades → organización de respuestas → procesamiento posterior.

Sin embargo, generar veinte preguntas mediante una herramienta de IA no significa haber construido un instrumento científico.

Todo instrumento necesita demostrar, según corresponda, propiedades como: validez → confiabilidad → pertinencia → claridad → coherencia.

Una herramienta puede sugerir ítems, pero la validación debe apoyarse en procedimientos metodológicos, evidencia previa y, cuando corresponda, juicio de expertos y análisis estadístico.

Antes de integrar herramientas inteligentes al diseño metodológico conviene identificar con claridad cuáles decisiones pueden ser asistidas y cuáles deben permanecer bajo responsabilidad directa del investigador. La Tabla 3 sintetiza esta relación en las principales fases del diseño de una investigación.

Tabla 3. Decisiones metodológicas y posibilidades de apoyo de inteligencia artificial

Componente metodológico	Decisión científica principal	Posible apoyo de IA	Riesgo metodológico	Criterio del investigador
Problema científico	Identificar y delimitar el vacío de conocimiento	Explorar literatura, tendencias y conceptos	Confundir ausencia documental con relevancia científica	Justificar pertinencia y contexto
Pregunta de investigación	Formular aquello que se pretende responder	Proponer formulaciones alternativas	Preguntas genéricas o desconectadas de la evidencia	Evaluar claridad, viabilidad y valor científico
Objetivos	Precisar resultados investigativos esperados	Revisar coherencia y redacción	Objetivos sofisticados pero inviables	Comprobar correspondencia con problema y método
Hipótesis	Proponer relaciones susceptibles de contrastación	Detectar asociaciones potenciales	Convertir correlaciones algorítmicas en explicaciones	Fundamentar desde teoría y antecedentes
Variables	Definir constructos, dimensiones e indicadores	Comparar categorías y modelos conceptuales	Introducir variables descontextualizadas o sesgadas	Realizar operacionalización fundamentada
Enfoque	Seleccionar lógica cuantitativa, cualitativa o mixta	Analizar ventajas de diferentes alternativas	Elegir el enfoque por disponibilidad tecnológica	Priorizar la naturaleza de la pregunta
Diseño	Determinar cómo será obtenida la evidencia	Simular escenarios y apoyar planificación	Adoptar diseños que no se comprenden completamente	Justificar cada decisión

Población y muestra	Delimitar unidades y estrategia de selección	Apoyar cálculos y segmentaciones	Sesgos de representación	Evaluar cobertura y representatividad
Instrumentos	Obtener evidencia válida y confiable	Generar borradores, revisar ítems y organizar información	Utilizar preguntas sin validación	Validar contenido y propiedades métricas
Análisis	Seleccionar procedimiento analítico	Automatizar cálculos y reconocer patrones	Caja negra, sobreajuste o conclusiones espurias	Interpretar y verificar los resultados
Documentación	Garantizar trazabilidad	Registrar procedimientos y automatizar flujos	Uso opaco de herramientas	Declarar y explicar la intervención de IA

Fuente: elaboración propia a partir de Wang et al. (2023), Heil et al. (2021), Bolaños et al. (2024), Gao y Wang (2024) y Resnik y Hosseini (2025).

La Tabla 3 permite observar que prácticamente todas las etapas del diseño metodológico pueden recibir algún tipo de apoyo tecnológico. Sin embargo, también evidencia que las decisiones científicas esenciales continúan dependiendo del investigador. La IA puede generar alternativas, clasificar información o identificar patrones, pero no posee por sí misma conocimiento suficiente sobre las condiciones particulares en las que cada investigación se desarrolla.

Por ello, un diseño metodológico apoyado por IA debería incorporar desde su planificación mecanismos de documentación y verificación. El investigador necesita conservar evidencia de las decisiones relevantes, especificar qué herramientas fueron utilizadas y evitar que etapas fundamentales se conviertan en procesos inaccesibles para terceros.



Figura 2. Modelo de coherencia metodológica para investigaciones científicas apoyadas por inteligencia artificial.

Como se observa en la Figura 2, la coherencia metodológica depende de la articulación lógica entre el problema científico, la pregunta de investigación, los objetivos e hipótesis, el enfoque y diseño, la población y muestra, los instrumentos y la obtención de evidencia. Cada una de estas decisiones mantiene una relación de interdependencia, de modo que una debilidad en cualquiera de ellas puede afectar la solidez general del estudio.

Reflexión final del capítulo

El diseño metodológico continúa siendo el espacio donde una intención científica se convierte en una investigación verificable. La inteligencia artificial modifica las herramientas disponibles, pero no

elimina la necesidad de coherencia entre problema, pregunta, objetivos, hipótesis, enfoque, diseño, muestra, instrumentos y procedimientos analíticos.

La evidencia revisada demuestra que la IA puede intervenir en múltiples momentos del proceso. Wang et al. (2023) muestran su potencial para apoyar la formulación de hipótesis, el diseño experimental y la interpretación de datos; Bolaños et al. (2024) evidencian su creciente utilización en búsqueda, clasificación y síntesis de literatura; Gao y Wang (2024) muestran su expansión dentro de la actividad científica; mientras que Resnik y Hosseini (2025) recuerdan que estos avances requieren nuevas orientaciones vinculadas con responsabilidad, transparencia y sesgos.

También considero fundamental diferenciar entre automatización y autonomía. Automatizar una tarea repetitiva puede resultar beneficioso; conceder autonomía completa a un sistema para decidir qué estudiar, cómo medirlo y cómo interpretar los resultados plantea problemas mucho más profundos. La investigación científica implica decisiones que contienen presupuestos teóricos, culturales, éticos y sociales que no pueden reducirse únicamente a operaciones computacionales.

El investigador del presente necesita, entonces, desarrollar una doble competencia: comprender sólidamente los fundamentos metodológicos y saber interactuar críticamente con tecnologías inteligentes. Una sin la otra resulta insuficiente. La formación metodológica sin alfabetización digital corre el riesgo de quedar limitada frente a nuevos escenarios científicos; pero el dominio tecnológico sin comprensión metodológica puede producir análisis sofisticados carentes de fundamento.

CAPÍTULO 3

Inteligencia artificial para la búsqueda, revisión y gestión de la literatura científica



○ Autor: ○

Moisés Malpica Córdova

Capítulo 3.

Inteligencia artificial para la búsqueda, revisión y gestión de la literatura científica

La revisión de la literatura constituye una de las etapas más determinantes del proceso investigativo, porque permite reconocer qué se sabe sobre un fenómeno, cuáles son los principales enfoques utilizados para estudiarlo, qué resultados han sido obtenidos y qué vacíos permanecen abiertos. Una investigación sólida difícilmente puede construirse sin una comprensión suficiente del conocimiento precedente.

Sin embargo, el crecimiento acelerado de la producción científica ha convertido esta tarea en un desafío cada vez mayor. Los investigadores deben enfrentarse a miles de publicaciones, múltiples bases de datos, diferentes sistemas de indexación y una enorme diversidad terminológica. De la Torre-López, Ramírez y Romero (2023) explican que la elaboración manual de una revisión sistemática exige considerable tiempo y esfuerzo, especialmente cuando las búsquedas recuperan cientos o miles de documentos que posteriormente deben filtrarse y analizarse.

En este contexto, la inteligencia artificial está transformando las estrategias utilizadas para localizar, organizar y evaluar literatura científica. Técnicas de procesamiento del lenguaje natural, aprendizaje automático y modelos generativos pueden apoyar la construcción de consultas, la identificación de documentos potencialmente relevantes, el cribado de resultados, la extracción de información y la síntesis inicial de grandes corpus documentales.

Ofori-Boateng et al. (2024) identificaron que la automatización de revisiones sistemáticas mediante inteligencia artificial se concentra

especialmente en cuatro etapas: búsqueda, cribado, extracción de datos y evaluación del riesgo de sesgo. Los autores destacan que el crecimiento continuo de la literatura científica hace especialmente relevante el desarrollo de sistemas capaces de reducir la carga de trabajo asociada con estas actividades.

No obstante, la automatización introduce también un riesgo metodológico: confundir rapidez de recuperación con calidad de la evidencia. Una herramienta puede encontrar cientos de documentos en segundos, pero la decisión acerca de cuáles son pertinentes, confiables y metodológicamente sólidos continúa requiriendo criterios científicos.

Desde mi perspectiva, este constituye uno de los cambios más importantes de la investigación contemporánea. El problema ya no consiste exclusivamente en encontrar información, sino en desarrollar la capacidad para filtrarla, contrastarla, jerarquizarla y convertirla en evidencia útil para la investigación. La inteligencia artificial puede ampliar enormemente las capacidades de búsqueda; sin embargo, esa ampliación solamente mejora la ciencia cuando se acompaña de estrategias transparentes y decisiones metodológicas justificadas.

3.1. Estrategias avanzadas de búsqueda y recuperación de información científica

La búsqueda bibliográfica no debería reducirse a introducir algunas palabras en un buscador académico. En una investigación científica, constituye un procedimiento planificado mediante el cual se traducen conceptos teóricos en términos capaces de recuperar evidencia pertinente.

Una estrategia de búsqueda rigurosa comienza por identificar los conceptos centrales derivados del problema y de la pregunta de investigación. Posteriormente, esos conceptos deben transformarse en palabras clave, sinónimos, variantes terminológicas y descriptores específicos de cada disciplina.

Puede representarse mediante la siguiente secuencia:

Problema → conceptos centrales → términos clave → sinónimos → operadores → bases de datos → filtrado → evidencia relevante.

La selección terminológica es especialmente importante porque un mismo concepto puede aparecer denominado de maneras diferentes. Por ejemplo, una investigación relacionada con inteligencia artificial generativa podría necesitar términos como:

“generative artificial intelligence”, “generative AI”, “large language models”, “LLM” o nombres de tecnologías específicas.

Si la búsqueda utiliza solamente una expresión, existe el riesgo de excluir investigaciones relevantes que emplean otra terminología.

Los operadores booleanos continúan siendo recursos fundamentales para estructurar búsquedas:

- **AND** permite relacionar conceptos.
- **OR** amplía la búsqueda incorporando términos equivalentes.
- **NOT** excluye conceptos que no corresponden con el propósito del estudio.

Por ejemplo: ("artificial intelligence" OR "generative AI") AND ("scientific research" OR "research methodology")

La diferencia entre una búsqueda simple y una búsqueda científica radica precisamente en esta capacidad de construir una estrategia reproducible.

Ofori-Boateng et al. (2024) reportan que en los estudios orientados a automatizar la fase de búsqueda mediante procesamiento del lenguaje natural aparecen tres grandes grupos de técnicas: priorización de búsquedas, clasificación de textos y recuperación de información. Este

hallazgo muestra que la IA está pasando de ser únicamente un mecanismo complementario para intervenir directamente en la selección y ordenamiento inicial de literatura.

- **De la búsqueda por palabras a la búsqueda semántica**

Una transformación especialmente relevante es el paso progresivo desde la coincidencia estricta de palabras hacia mecanismos de recuperación semántica.

La búsqueda tradicional se apoya principalmente en términos explícitos. En cambio, los sistemas inteligentes pueden intentar reconocer relaciones conceptuales incluso cuando dos documentos no utilizan exactamente las mismas palabras.

Por ejemplo, un artículo podría referirse a automatización de la evaluación académica sin utilizar explícitamente la expresión inteligencia artificial educativa, aunque conceptualmente exista una relación importante.

La recuperación semántica puede ayudar a descubrir este tipo de conexiones.

Sin embargo, existe una consecuencia metodológica importante: cuanto más sofisticado sea el sistema de recomendación o recuperación, menos evidente puede resultar por qué determinado artículo fue presentado al investigador.

Por esta razón, la IA debería complementar y no sustituir completamente las estrategias explícitas de búsqueda.

Una práctica recomendable consiste en combinar tres niveles:
búsqueda estructurada + recuperación semántica + revisión manual.

La primera aporta reproducibilidad; la segunda amplía el descubrimiento; la tercera permite valorar pertinencia.

- **Estrategias iterativas**

Las búsquedas científicas raramente quedan perfectas en el primer intento. Es frecuente comenzar con una ecuación preliminar, examinar los resultados obtenidos, reconocer nuevos términos y posteriormente refinar la estrategia.

La inteligencia artificial puede resultar especialmente útil en esta fase mediante:

- identificación de sinónimos;
- traducción de conceptos;
- propuesta de términos relacionados;
- agrupación temática;
- comparación de ecuaciones;
- análisis inicial de títulos y resúmenes.

No obstante, un investigador debe evitar delegar completamente la construcción de la ecuación de búsqueda.

Una consulta generada automáticamente podría incluir términos excesivamente generales, omitir expresiones propias de determinada disciplina o producir una estrategia que parezca correcta sin recuperar adecuadamente la literatura relevante.

De la Torre-López et al. (2023) recuerdan que iniciar una investigación implica realizar un análisis profundo de la literatura relacionada para comprender el contexto y reconocer trabajos relevantes que hayan estudiado problemas semejantes.

Desde mi criterio, una buena estrategia de búsqueda no debería valorarse por la cantidad de documentos recuperados, sino por su capacidad para equilibrar amplitud y precisión. Recuperar miles de

artículos irrelevantes no representa una búsqueda eficiente, mientras que una estrategia excesivamente restrictiva podría excluir estudios decisivos.

Por ello, buscar científicamente implica también aprender a excluir.

3.2. Bases de datos académicas, motores inteligentes y sistemas de recomendación

Las bases de datos académicas constituyen uno de los principales puntos de entrada al conocimiento científico. Sin embargo, no todas cumplen exactamente las mismas funciones ni ofrecen idéntica cobertura.

Un investigador puede trabajar con bases bibliográficas multidisciplinares, repositorios especializados, índices de citación, motores académicos y plataformas editoriales.

Entre los recursos habitualmente utilizados se encuentran: Scopus, Web of Science, PubMed, IEEE Xplore, ERIC, ScienceDirect, SpringerLink y Google Scholar, dependiendo de la disciplina y del propósito de la búsqueda.

Ofori-Boateng et al. (2024), por ejemplo, señalan que en su propia revisión utilizaron recursos como PubMed, Scopus, Google Scholar, IEEE, Elsevier, Springer, ACM y ScienceDirect para identificar estudios relacionados con la automatización de revisiones sistemáticas.

Esto evidencia un principio metodológico importante: una única base de datos difícilmente representa de manera exhaustiva toda la producción científica relevante para un problema complejo.

Cada sistema posee criterios de indexación, cobertura disciplinar y mecanismos de búsqueda específicos.

- **Bases de datos y trazabilidad**

Para investigaciones destinadas a revisiones sistemáticas o revisiones de alcance, resulta fundamental registrar:

- base consultada;
- fecha de búsqueda;
- ecuación empleada;
- filtros aplicados;
- número de resultados obtenidos;
- criterios posteriores de selección.

Esta documentación permite reproducir el proceso.

La aparición de motores inteligentes no elimina esta necesidad. Al contrario, la vuelve todavía más importante.

Cuando una plataforma recomienda documentos utilizando algoritmos propietarios, el investigador puede desconocer parcialmente cuáles criterios determinaron el orden de los resultados.

Aquí surge una diferencia fundamental entre recuperación sistemática y descubrimiento asistido. La primera necesita procedimientos documentables. La segunda puede emplear recomendaciones algorítmicas para encontrar literatura adicional.

Ambas pueden complementarse, pero no deberían confundirse.

- **Sistemas de recomendación científica**

Los sistemas de recomendación utilizan diferentes señales para sugerir literatura relacionada, como: similitud textual, relaciones de citación, coautoría, términos compartidos, comportamiento de usuarios o proximidad semántica.

Su ventaja consiste en facilitar el descubrimiento de publicaciones que podrían pasar inadvertidas mediante búsquedas convencionales. Por ejemplo, después de encontrar un artículo particularmente relevante, un sistema puede ayudar a identificar:

trabajos que lo citan → referencias que utiliza → artículos conceptualmente similares → autores relacionados.

Este procedimiento permite construir redes de conocimiento. Bolaños et al. (2024) analizaron 21 herramientas utilizadas para apoyar revisiones sistemáticas y, adicionalmente, 11 herramientas recientes basadas en grandes modelos de lenguaje orientadas a búsqueda de literatura y apoyo a la escritura académica. Los autores consideran que la expansión de estas tecnologías apunta hacia una mayor semi-automatización de los procesos de revisión.

La expresión utilizada por Bolaños et al. (2024) resulta particularmente reveladora, porque representa una transición hacia sistemas en los que algunas tareas pueden ser ejecutadas automáticamente mientras otras permanecen bajo decisión del investigador. Sin embargo, esta facilidad también introduce el llamado riesgo de burbuja algorítmica científica.

Si el investigador acepta exclusivamente documentos recomendados a partir de los textos que ya ha leído, puede terminar recorriendo una misma comunidad temática y reducir la posibilidad de encontrar perspectivas discrepantes. Desde mi punto de vista, esto exige diversificar deliberadamente la búsqueda.

- **Selección crítica de fuentes**

Una herramienta de IA puede recomendar un artículo, pero no debería decidir automáticamente que ese documento constituye evidencia de alta calidad.

El investigador necesita comprobar aspectos como: revista, autoría, fecha, metodología, muestra, datos, resultados, limitaciones, DOI, pertinencia.

También debe diferenciar entre publicación revisada por pares, preprint, documento institucional y contenido generado en plataformas no académicas. Desde la perspectiva metodológica, la procedencia de la fuente forma parte de la evaluación de la evidencia. La rapidez proporcionada por la IA puede ser especialmente útil para localizar posibilidades; la valoración científica continúa requiriendo lectura crítica.

Tabla 4. Integración de estrategias tradicionales e inteligencia artificial en la búsqueda científica

La incorporación de inteligencia artificial no debería desplazar las técnicas bibliográficas consolidadas, sino complementarlas. La Tabla 4 resume esta relación y permite identificar el valor específico de cada modalidad.

Proceso	Estrategia convencional	Apoyo de IA	Control necesario
Definición de términos	Palabras clave y descriptores	Generación de sinónimos y relaciones conceptuales	Verificar pertinencia
Recuperación	Operadores y filtros	Búsqueda semántica y priorización	Evitar omisiones
Exploración	Referencias y citas	Recomendación de documentos relacionados	Diversificar fuentes
Cribado	Lectura de títulos y resúmenes	Clasificación y priorización automática	Confirmación humana
Organización	Gestores bibliográficos	Agrupamiento y extracción asistida	Comprobar exactitud

Fuente: elaboración propia a partir de de la Torre-López et al. (2023), Bolaños et al. (2024) y Ofori-Boateng et al. (2024).

Como evidencia la Tabla 4, la mayor utilidad de la inteligencia artificial aparece cuando se emplea para ampliar la capacidad del

investigador y reducir tareas repetitivas sin eliminar los controles metodológicos. La búsqueda semántica puede complementar las ecuaciones booleanas; la clasificación automatizada puede acelerar el cribado; y los sistemas de recomendación pueden descubrir conexiones adicionales. Sin embargo, la decisión de incorporar un documento a la base de evidencia debe responder a criterios previamente establecidos y no únicamente a la recomendación de un algoritmo.

3.3. Inteligencia artificial aplicada a revisiones sistemáticas y revisiones de alcance

Las revisiones sistemáticas representan uno de los escenarios en los que la inteligencia artificial posee mayor potencial debido al volumen de trabajo requerido para identificar, seleccionar, evaluar y sintetizar investigaciones.

Una revisión sistemática no consiste simplemente en recopilar artículos. Su propósito es responder una pregunta mediante un procedimiento previamente definido, transparente y reproducible.

Entre sus etapas generales pueden distinguirse:

pregunta → protocolo → búsqueda → eliminación de duplicados → cribado → elegibilidad → extracción → evaluación → síntesis → reporte.

Las revisiones de alcance o *scoping reviews*, por su parte, suelen orientarse a mapear un campo, identificar conceptos, caracterizar la evidencia disponible y reconocer vacíos, especialmente cuando la literatura es heterogénea o todavía se encuentra en desarrollo. En ambos casos, el crecimiento de la producción científica ha aumentado considerablemente la carga de trabajo.

De la Torre-López et al. (2023) analizaron 34 estudios primarios relacionados con técnicas de inteligencia artificial para apoyar revisiones

sistemáticas. Los autores observaron que diversas actividades repetitivas del proceso presentan condiciones adecuadas para automatización, particularmente cuando deben manejarse grandes cantidades de documentos.

Ofori-Boateng et al. (2024), a partir del análisis de 52 trabajos, identificaron aplicaciones de procesamiento del lenguaje natural, aprendizaje automático y aprendizaje profundo destinadas fundamentalmente a:

búsqueda → cribado → extracción de datos → evaluación del riesgo de sesgo.

Este punto resulta particularmente importante porque muestra que la automatización no se limita a una sola etapa.

- **IA en el cribado**

El cribado puede convertirse en una de las etapas más demandantes de una revisión sistemática. Después de ejecutar una búsqueda amplia, pueden aparecer cientos o miles de referencias. Tradicionalmente, los investigadores revisan títulos y resúmenes para determinar cuáles cumplen los criterios de inclusión.

Los modelos de aprendizaje automático pueden aprender de decisiones previas y priorizar documentos que tienen mayor probabilidad de resultar relevantes. Esto permite organizar el trabajo de manera más eficiente. Sin embargo, priorizar no equivale necesariamente a excluir. Un sistema puede considerar poco relevante un estudio que en realidad debería formar parte de la revisión. Por ello, la automatización debe utilizarse con procedimientos que reduzcan el riesgo de falsos negativos.

Extracción automatizada de información

Otra aplicación importante consiste en identificar automáticamente información dentro de los documentos seleccionados.

Por ejemplo:

**autor → año → muestra → diseño → variables →
intervención → resultados.**

Los sistemas de procesamiento del lenguaje natural pueden localizar algunos de estos elementos y estructurarlos para facilitar la síntesis.

Bolaños et al. (2024) señalan que gran parte de las herramientas de IA analizadas se concentra precisamente en las fases de screening y extraction, es decir, cribado y extracción.

No obstante, la extracción automática necesita comprobación.

Un modelo podría confundir el tamaño inicial de una muestra con el número final de participantes, interpretar incorrectamente una medida estadística o atribuir un resultado a un grupo equivocado.

La velocidad obtenida no elimina, por tanto, la necesidad de verificación.

- **Automatización y calidad metodológica**

La discusión actual ya no se limita a determinar si la inteligencia artificial puede acelerar una revisión, sino si puede hacerlo sin disminuir su calidad metodológica.

Tomczyk (2026) analizó específicamente la relación entre inteligencia artificial, automatización y revisiones sistemáticas, identificando siete temas principales, entre ellos la colaboración humano-máquina, el ahorro de tiempo, la calidad metodológica, las herramientas analíticas y las revisiones sistemáticas vivas.

Esta última categoría resulta especialmente interesante.

Las revisiones sistemáticas vivas buscan actualizarse conforme aparecen nuevas investigaciones. En áreas de evolución rápida, esperar varios años para actualizar una revisión puede hacer que sus conclusiones queden desfasadas. La automatización puede ayudar a detectar nuevos estudios y facilitar actualizaciones periódicas.

Desde mi perspectiva, este podría ser uno de los usos más relevantes de la inteligencia artificial en los próximos años. En lugar de entender la revisión sistemática como un documento que termina con su publicación, podría convertirse progresivamente en una estructura dinámica de evidencia que se actualiza bajo reglas metodológicas previamente establecidas.

- **El límite de la automatización**

A pesar de estos avances, existen fases difíciles de automatizar completamente.

Por ejemplo, valorar la relevancia conceptual de un estudio, interpretar sus limitaciones, comprender diferencias contextuales o determinar hasta qué punto resultados aparentemente contradictorios pueden coexistir requiere un nivel de razonamiento que excede la clasificación textual básica.

Ofori-Boateng et al. (2024) muestran que la automatización actual todavía presenta vacíos y desafíos, incluso después de los progresos alcanzados mediante NLP, aprendizaje automático y aprendizaje profundo.

De manera similar, Bolaños et al. (2024) destacan oportunidades importantes, pero también desafíos relacionados con el desarrollo y evaluación de herramientas para revisiones de literatura.

Por ello, considero más apropiado hablar actualmente de revisión aumentada por inteligencia artificial que de revisión completamente automatizada.

La diferencia no es únicamente terminológica. En una revisión automatizada, el algoritmo tendería a reemplazar etapas completas.

En una revisión aumentada, las herramientas inteligentes ayudan a gestionar complejidad mientras el investigador mantiene el control de las decisiones metodológicas.

Este segundo modelo ofrece, al menos por ahora, un equilibrio más consistente entre eficiencia y rigor.



Figura 3. Ruta inteligente para la búsqueda, selección y síntesis de evidencia científica asistida por inteligencia artificial.

Como se observa en la Figura 3, la construcción de una revisión científica rigurosa requiere mucho más que localizar documentos. El proceso comienza con una adecuada definición de la necesidad de información y avanza mediante la recuperación, exploración, selección, evaluación y síntesis de la evidencia. Cada una de estas etapas cumple

una función específica y contribuye a reducir progresivamente el volumen inicial de información hasta conformar un cuerpo documental pertinente y metodológicamente útil.

Reflexión final del capítulo

La inteligencia artificial está modificando profundamente la relación del investigador con la literatura científica. Buscar evidencia ya no significa únicamente introducir palabras clave en una base de datos; implica interactuar con sistemas capaces de recomendar documentos, reconocer similitudes semánticas, clasificar publicaciones, extraer información y priorizar aquellas fuentes que parecen más relevantes.

La evidencia revisada muestra que esta transformación ya se encuentra en marcha. De la Torre-López et al. (2023) documentan el desarrollo progresivo de técnicas de IA para automatizar distintas actividades de las revisiones sistemáticas; Ofori-Boateng et al. (2024) identifican aplicaciones concretas en búsqueda, cribado, extracción y evaluación del riesgo de sesgo; Bolaños et al. (2024) describen la transición hacia revisiones parcialmente automatizadas; mientras que Tomczyk (2026) sitúa la colaboración entre seres humanos y máquinas entre los ejes centrales de esta transformación.

A mi juicio, el avance más importante no consiste en que una inteligencia artificial pueda leer miles de resúmenes, sino en la posibilidad de que el investigador pueda dedicar menos tiempo a actividades mecánicas y más tiempo a evaluar críticamente la evidencia. Sin embargo, esta oportunidad puede convertirse en una debilidad si la velocidad reemplaza a la reflexión.

La búsqueda automatizada introduce también una paradoja. Cuanto mayor sea la capacidad de los sistemas para decidir qué información mostrar primero, mayor debe ser la conciencia del investigador acerca de aquello que podría permanecer invisible. Los algoritmos de recomendación facilitan el descubrimiento, pero también

pueden reforzar determinadas rutas intelectuales y reducir la exposición a perspectivas diferentes.

Por ello, considero que el investigador contemporáneo necesita evolucionar desde una alfabetización bibliográfica hacia una alfabetización bibliográfica-algorítmica. Esto significa comprender tanto las estrategias tradicionales de recuperación como los principios básicos mediante los cuales los sistemas inteligentes encuentran, ordenan y recomiendan literatura.

CAPÍTULO 4

Análisis, interpretación y comunicación de datos con inteligencia artificial



— Autor: —

Rufino III Contreras de León

Capítulo 4.

Análisis, interpretación y comunicación de datos con inteligencia artificial

En El análisis de datos representa uno de los momentos más sensibles de cualquier investigación científica, porque es allí donde la información recolectada comienza a transformarse en evidencia susceptible de interpretación. La calidad de esta fase depende no solo de la técnica estadística o analítica empleada, sino también de la manera en que los datos fueron obtenidos, organizados, depurados y documentados.

La expansión de la inteligencia artificial ha ampliado considerablemente las posibilidades disponibles para los investigadores. Hoy es posible procesar grandes volúmenes de información, identificar patrones complejos, construir modelos predictivos, analizar textos y generar representaciones de datos con una rapidez que hace pocos años resultaba difícil de alcanzar. Gao y Wang (2024) encontraron que el uso de inteligencia artificial se ha extendido ampliamente entre distintas áreas científicas y que sus beneficios potenciales han aumentado de manera significativa desde 2015. Este crecimiento evidencia que la IA está dejando de ser una herramienta especializada para convertirse progresivamente en parte de la infraestructura analítica de la investigación contemporánea.

Sin embargo, disponer de algoritmos más potentes no elimina los principios clásicos del análisis científico. Una base de datos con errores, valores faltantes mal gestionados o categorías inconsistentes continuará produciendo resultados débiles aunque posteriormente se utilice un modelo sofisticado. De igual manera, una asociación estadística detectada por una herramienta automatizada no constituye por sí misma una explicación científica.

Wang et al. (2023) muestran que la inteligencia artificial posee capacidad para apoyar diferentes etapas del descubrimiento científico, incluyendo la identificación de patrones complejos, la construcción de modelos y el análisis de información de gran escala. Al mismo tiempo, su revisión advierte que estas herramientas necesitan integrarse con conocimiento científico y procesos de validación adecuados.

Desde mi perspectiva, la transformación más importante no consiste en sustituir el análisis convencional por inteligencia artificial, sino en construir un modelo analítico ampliado en el que estadística, aprendizaje automático, procesamiento del lenguaje natural y juicio científico interactúen de forma complementaria. El objetivo sigue siendo el mismo: obtener conclusiones justificables a partir de evidencia verificable.

4.1. Preparación, depuración y gestión de datos de investigación

Antes de aplicar cualquier procedimiento estadístico o modelo de inteligencia artificial, los datos necesitan ser preparados. Esta fase suele recibir menos atención que los resultados finales, aunque en realidad condiciona buena parte de su validez.

Un conjunto de datos puede contener:

- valores ausentes;
- registros duplicados;
- errores de digitación;
- categorías inconsistentes;
- unidades diferentes;
- valores extremos;
- respuestas incompletas;
- errores de codificación;
- información irrelevante.

La preparación comienza con la construcción de una estructura ordenada que permita identificar claramente qué representa cada variable, cómo fue medida y qué valores puede adoptar.

Una secuencia recomendable puede expresarse de la siguiente manera:

Recolección → estructuración → depuración → transformación → validación → documentación → análisis

Esta secuencia adquiere todavía mayor importancia cuando se pretende utilizar aprendizaje automático. Los modelos aprenden a partir de los datos que reciben; por ello, los errores presentes en estos pueden incorporarse posteriormente a las predicciones.

Heil et al. (2021) advierten que los modelos de aprendizaje automático poseen capacidad para afrontar la escala y complejidad de grandes datos, pero también pueden ser más difíciles de interpretar que los modelos simples. Los autores señalan que esta opacidad puede ocultar sesgos aprendidos durante el procesamiento.

- **Depuración de datos**

La depuración implica examinar sistemáticamente la calidad de la información antes de analizarla.

Entre los procedimientos básicos se encuentran:

Detección de duplicados. Dos registros idénticos pueden alterar frecuencias, medias o modelos predictivos.

Revisión de valores faltantes. Es necesario determinar si su ausencia es aleatoria o responde a un patrón específico.

Identificación de valores atípicos. Un valor extremo puede representar un error, pero también un caso científicamente relevante.

Homogeneización de formatos. Fechas, unidades, nombres de categorías y códigos deben seguir criterios consistentes.

Verificación de rangos. Las respuestas deben mantenerse dentro de los valores permitidos por el instrumento.

La inteligencia artificial puede ayudar a detectar anomalías, identificar registros sospechosos o proponer transformaciones. Sin embargo, estas sugerencias deben ser revisadas antes de modificar la base original.

Por ejemplo, un algoritmo puede identificar una edad de 95 años como valor atípico dentro de una muestra universitaria. Estadísticamente podría parecer anómala, pero no necesariamente incorrecta. El investigador necesita revisar la fuente antes de decidir si debe conservarse, corregirse o eliminarse.

Este ejemplo muestra una idea importante: anomalía estadística y error no son sinónimos.

- **Gestión y trazabilidad**

Una buena práctica consiste en conservar siempre una versión original de la base y realizar las modificaciones en copias controladas.

La trazabilidad debería permitir responder:

¿Qué se modificó? ¿Por qué se modificó? ¿Cuándo? ¿Con qué procedimiento? ¿Quién tomó la decisión?

Heil et al. (2021) proponen estándares de reproducibilidad sustentados en la publicación o documentación de datos, modelos y código, así como en buenas prácticas de programación y automatización de flujos. Para los autores, la reproducibilidad computacional constituye una condición importante para construir investigación verificable.

Su afirmación resume una cuestión central: la confianza científica no depende únicamente del resultado, sino de la posibilidad de examinar cómo fue obtenido.

Desde mi criterio, esta fase debería considerarse parte explícita de la metodología y no una actividad técnica secundaria. Un investigador puede aplicar correctamente un modelo muy avanzado y obtener, aun así, conclusiones defectuosas si los datos fueron preparados de manera inadecuada. En investigación asistida por IA, la calidad del resultado comienza mucho antes del algoritmo.

4.2. Estadística descriptiva e inferencial asistida por herramientas digitales

La estadística continúa siendo una de las principales herramientas para organizar, resumir y analizar información cuantitativa. La incorporación de software y sistemas inteligentes ha simplificado considerablemente los cálculos, pero comprender el significado de cada procedimiento continúa siendo responsabilidad del investigador.

La estadística descriptiva permite caracterizar los datos obtenidos mediante indicadores como:

**frecuencias → porcentajes → media → mediana → moda →
desviación estándar → rango**

Estos resultados proporcionan una primera aproximación a la distribución y comportamiento de las variables.

Por ejemplo, en una investigación educativa, calcular que el 72 % de los estudiantes utiliza herramientas de inteligencia artificial no explica por qué las emplean ni permite establecer automáticamente efectos sobre su aprendizaje. Describe una característica de la muestra.

La estadística inferencial persigue un objetivo diferente. Busca utilizar información obtenida en una muestra para evaluar hipótesis o realizar inferencias respecto de una población.

Entre los procedimientos más habituales se encuentran:

- prueba t ;
- análisis de varianza;
- chi-cuadrado;
- correlaciones;
- regresión;
- pruebas no paramétricas;
- intervalos de confianza.

Las herramientas digitales actuales pueden ejecutar estos cálculos en segundos. Incluso determinados sistemas de IA pueden sugerir qué prueba utilizar a partir de una descripción de las variables. Sin embargo, esta facilidad introduce un riesgo: aplicar correctamente una operación matemática sin comprender si corresponde metodológicamente al estudio.

Elegir una prueba estadística implica considerar:

tipo de variables + distribución + tamaño muestral + independencia + hipótesis + diseño de investigación.

Una herramienta puede realizar un ANOVA perfectamente, aunque los datos no cumplan los supuestos necesarios.

- **La IA como asistente estadístico**

Utilizada de forma adecuada, la IA puede apoyar en:

- identificación preliminar de procedimientos;
- explicación de resultados;
- detección de inconsistencias;

- elaboración de código estadístico;
- exploración de alternativas;
- organización de tablas y visualizaciones.

Su papel resulta especialmente útil para reducir errores operativos y facilitar el acceso a técnicas que anteriormente requerían una especialización considerable.

No obstante, no debería convertirse en un mecanismo para seleccionar automáticamente una prueba sin justificación.

Resnik y Hosseini (2025) señalan que la utilización de IA en investigación aporta beneficios importantes, pero también introduce problemas éticos asociados con errores, sesgos y transparencia. La responsabilidad de detectar y controlar estos problemas permanece en quienes desarrollan y utilizan dichas herramientas.

Esta responsabilidad se extiende a la interpretación estadística. Un resultado estadísticamente significativo no necesariamente posee relevancia práctica. De forma esquemática: significación estadística $\neq$ importancia científica

Un valor p puede indicar que un resultado sería poco probable bajo determinadas condiciones, pero no determina por sí mismo la magnitud o utilidad del efecto observado.

Por ello, es recomendable acompañar la inferencia con: tamaño del efecto, intervalos de confianza, contexto, conocimiento disciplinar.

Desde mi perspectiva, la inteligencia artificial puede convertirse en un excelente tutor estadístico cuando ayuda a comprender por qué una técnica resulta adecuada. Se vuelve problemática cuando simplemente entrega una prueba, un valor y una conclusión aparentemente terminada. La diferencia entre ambos usos está en si fortalece el razonamiento o lo reemplaza.

4.3. Inteligencia artificial, aprendizaje automático y análisis predictivo en investigación

El aprendizaje automático constituye una de las áreas de mayor impacto dentro de la inteligencia artificial aplicada a la ciencia. A diferencia de los procedimientos basados exclusivamente en reglas definidas de antemano, los algoritmos de *machine learning* pueden aprender estructuras y relaciones a partir de los datos.

Entre sus principales aplicaciones se encuentran:

clasificación → regresión → agrupamiento → detección de anomalías → predicción → reconocimiento de patrones

Estas posibilidades han ampliado el análisis en campos como salud, biología, ingeniería, ciencias sociales y educación.

Wang et al. (2023) explican que los recientes avances en inteligencia artificial han permitido abordar problemas científicos caracterizados por grandes espacios de búsqueda, estructuras complejas y elevados volúmenes de información. Su revisión muestra aplicaciones en áreas como biología, química, ciencia de materiales y otras disciplinas vinculadas al descubrimiento científico.

Gao y Wang (2024), por su parte, encontraron que el uso y los beneficios potenciales de la IA aparecen distribuidos ampliamente entre las ciencias y han crecido con especial rapidez desde 2015. Esto permite comprender que el análisis computacional avanzado está pasando de áreas altamente especializadas hacia un ecosistema científico mucho más amplio.

Aprendizaje supervisado

En el aprendizaje supervisado, el modelo recibe ejemplos donde el resultado esperado es conocido.

El proceso básico puede representarse así:

Datos históricos → **entrenamiento** → **validación** → **predicción**

Puede utilizarse para:

- predecir abandono estudiantil;
- clasificar imágenes;
- estimar riesgos;
- pronosticar demanda;
- identificar categorías de pacientes.

Aprendizaje no supervisado

En este caso, el sistema analiza información sin contar previamente con una etiqueta de resultado. Este tipo de análisis puede resultar útil cuando el investigador desconoce qué grupos o patrones podrían existir dentro de la información. Sin embargo, los grupos encontrados por un algoritmo no necesariamente representan categorías teóricas con significado.

Un modelo puede dividir una muestra en cuatro conglomerados estadísticamente diferentes; corresponde al investigador determinar si esas agrupaciones poseen sentido científico.

Predicción y explicación

Una de las distinciones más relevantes se encuentra entre predecir y explicar.

Un modelo puede predecir correctamente qué estudiantes presentan mayor probabilidad de abandonar sus estudios, pero ello no significa que haya identificado las causas del abandono.

Del mismo modo:

alta precisión predictiva $\neq$ causalidad

Esta diferenciación adquiere gran importancia porque algunos modelos de IA son extraordinariamente buenos para reconocer relaciones estadísticas sin proporcionar una explicación clara sobre cómo se producen.

Heil et al. (2021) señalan que los modelos de aprendizaje automático pueden ser más difíciles de interpretar y que esta falta de transparencia puede ocultar sesgos aprendidos. En determinados contextos, un modelo ligeramente menos preciso pero explicable puede ofrecer mayor valor científico.

Entrenamiento, validación y prueba

Un error metodológico frecuente consiste en entrenar y evaluar un modelo utilizando exactamente los mismos datos.

Esto puede provocar sobreajuste, es decir, que el algoritmo aprenda demasiado bien los casos de entrenamiento pero tenga dificultades para trabajar con observaciones nuevas.

Una estructura más adecuada consiste en separar:

datos de entrenamiento $\rightarrow$ datos de validación $\rightarrow$ datos de prueba

El propósito final no consiste en memorizar el conjunto original, sino en desarrollar capacidad de generalización.

Heil et al. (2021) insisten en que la reproducibilidad de los análisis de aprendizaje automático necesita documentación suficiente de datos, modelos, código y procedimientos utilizados.

Tabla 5. Modalidades de análisis de datos y papel de la inteligencia artificial

Antes de utilizar herramientas inteligentes conviene diferenciar qué tipo de análisis se pretende realizar y qué límites metodológicos deben considerarse. La Tabla 5 sintetiza esta relación.

Modalidad	Propósito principal	Apoyo de IA	Precaución metodológica
Descriptivo	Caracterizar los datos	Automatizar resúmenes y visualizaciones	No confundir descripción con explicación
Inferencial	Contrastar hipótesis	Apoyar selección y cálculo de pruebas	Verificar supuestos estadísticos
Predictivo	Estimar resultados futuros	Entrenar modelos y detectar patrones	Predicción no implica causalidad
Aprendizaje no supervisado	Descubrir estructuras	Agrupar casos y reconocer anomalías	Validar significado de los patrones
Análisis cualitativo	Interpretar textos y discursos	Clasificar y extraer patrones lingüísticos	Mantener contexto e interpretación humana

Fuente: elaboración propia a partir de Wang et al. (2023), Heil et al. (2021), Gao y Wang (2024), Feuerriegel et al. (2024) y Resnik y Hosseini (2025).

Como muestra la Tabla 5, la inteligencia artificial puede intervenir en diferentes modalidades analíticas, pero su función cambia según el propósito científico. En algunos casos permite automatizar operaciones; en otros facilita la detección de relaciones que difícilmente serían visibles mediante procedimientos manuales. Sin embargo, ninguna de estas posibilidades elimina la necesidad de justificar la técnica seleccionada.

Desde una perspectiva investigativa, considero que uno de los mayores riesgos actuales consiste en utilizar modelos complejos porque parecen metodológicamente más avanzados. La sofisticación computacional no constituye un criterio de calidad por sí misma. Una técnica sencilla, con corrección elegida y claramente interpretada, puede producir conocimiento más valioso que un algoritmo complejo utilizado sin justificación.

4.4. Análisis cualitativo, procesamiento de lenguaje natural y extracción de patrones

La expansión de la inteligencia artificial también está modificando profundamente el análisis cualitativo. Entrevistas, grupos focales, documentos, respuestas abiertas, publicaciones digitales y registros textuales producen grandes cantidades de información que pueden ser procesadas mediante técnicas de lenguaje natural.

El procesamiento de lenguaje natural o *Natural Language Processing* (NLP) busca que los sistemas computacionales puedan trabajar con información expresada mediante lenguaje humano.

Los modelos generativos representan una evolución importante dentro de este ámbito. Feuerriegel et al. (2024) explican que la IA generativa permite crear nuevo contenido a partir de patrones aprendidos y que sus aplicaciones se extienden a múltiples formas de información, especialmente lenguaje e imágenes.

Sengar et al. (2025), en su revisión sistemática, describen la rápida evolución de la IA generativa y sus aplicaciones, mostrando cómo estas tecnologías están ampliando las capacidades de procesamiento, generación y análisis de contenido.

IA y codificación cualitativa

En un análisis cualitativo tradicional, el investigador puede realizar un proceso semejante a:

lectura → codificación → agrupación → categorías → temas → interpretación

Las herramientas inteligentes pueden ayudar especialmente en las primeras etapas. Por ejemplo, frente a cien entrevistas, un sistema puede identificar expresiones recurrentes, proponer agrupaciones iniciales o reconocer determinados conceptos.

Una palabra puede adquirir significados diferentes según quién la pronuncie, en qué contexto, frente a qué experiencia y con qué intención. La frecuencia, por tanto, no determina automáticamente relevancia.

Un término que aparece cientos de veces podría ser metodológicamente menos importante que una experiencia excepcional relatada por pocos participantes.

Análisis de sentimientos y clasificación automática

Otra aplicación frecuente consiste en clasificar textos según determinados criterios.

Por ejemplo:

positivo / negativo / neutral

o:

satisfacción / insatisfacción / incertidumbre

Estos sistemas pueden resultar útiles cuando el volumen de información es muy elevado.

No obstante, presentan dificultades frente a:

- ironía;
- lenguaje figurado;
- ambigüedad;
- expresiones culturales;
- lenguaje especializado;
- contextos locales.

Una afirmación aparentemente positiva podría tener sentido irónico y ser clasificada incorrectamente por un sistema.

Por ello, la validación mediante muestras revisadas manualmente continúa siendo necesaria.

Extracción de patrones

Los sistemas inteligentes también pueden ayudar a identificar relaciones entre palabras, conceptos o categorías.

Esto permite explorar grandes corpus documentales y construir:

**redes semánticas → agrupaciones conceptuales → temas
recurrentes → relaciones discursivas.**

Aquí aparece un punto metodológicamente interesante. En la investigación tradicional, el investigador suele leer primero y construir categorías después. Con herramientas inteligentes también puede producirse una dinámica inversa: el sistema detecta determinados patrones y el investigador posteriormente analiza si poseen significado.

Esta posibilidad puede aumentar la creatividad analítica, pero también introduce el riesgo de interpretar como relevantes patrones producidos únicamente por proximidad estadística.

Desde mi criterio, este modelo resulta especialmente adecuado porque evita dos extremos: rechazar herramientas capaces de ampliar el análisis o entregarles completamente la interpretación.

El contexto como límite de la automatización

Los modelos de lenguaje poseen una capacidad notable para reconocer regularidades textuales. Sin embargo, un análisis científico cualitativo exige también comprender contexto, relaciones sociales, experiencias y marcos teóricos.

Resnik y Hosseini (2025) advierten que el uso de inteligencia artificial en investigación introduce problemas relacionados con sesgo, transparencia y responsabilidad. Estas cuestiones adquieren especial relevancia cuando las decisiones automatizadas afectan la interpretación de discursos humanos.

La IA podría sugerir que determinadas entrevistas comparten un mismo tema, pero corresponde al investigador determinar:

qué significa ese tema, cómo se relaciona con la teoría, por qué emerge y qué revela sobre el problema investigado.

Por esta razón, considero que el procesamiento automatizado de lenguaje debería entenderse principalmente como una estrategia de ampliación analítica, no como interpretación autónoma.



Figura 4. Radar analítico para la transformación de datos en evidencia y conocimiento científico mediante inteligencia artificial.

Como se observa en la Figura 4, la transformación de los datos en conocimiento científico requiere la articulación de diferentes niveles de análisis. La preparación y depuración de la información constituye el punto de partida para garantizar que los datos utilizados sean consistentes y trazables; posteriormente, el análisis estadístico permite describir y contrastar relaciones, mientras que la inteligencia artificial y el aprendizaje automático amplían la posibilidad de identificar patrones y desarrollar modelos predictivos. De manera complementaria, el análisis cualitativo y el procesamiento del lenguaje natural permiten profundizar en significados, categorías y relaciones presentes en información textual.

Reflexión final del capítulo

La inteligencia artificial ha ampliado de forma notable las posibilidades de análisis científico. Desde la depuración de bases hasta la construcción de modelos predictivos y el procesamiento de lenguaje

natural, las herramientas contemporáneas permiten trabajar con volúmenes y tipos de información que anteriormente resultaban difíciles de gestionar.

Wang et al. (2023) muestran que esta capacidad ya está contribuyendo al descubrimiento científico en múltiples disciplinas, mientras que Gao y Wang (2024) documentan la expansión progresiva del uso de IA en la investigación. Paralelamente, Heil et al. (2021) recuerdan que la utilización de aprendizaje automático necesita acompañarse de prácticas que garanticen reproducibilidad y confianza.

A mi juicio, el desafío principal del análisis de datos en la era de la IA no consiste en aprender a utilizar cada nueva herramienta que aparece. Las plataformas cambiarán rápidamente. Lo verdaderamente importante será desarrollar la capacidad para reconocer qué tipo de evidencia existe, qué procedimiento resulta adecuado, qué supuestos contiene el modelo y hasta dónde puede sostenerse una conclusión.

Esta distinción es particularmente relevante frente al análisis predictivo. Un algoritmo puede alcanzar niveles elevados de precisión y, aun así, aportar poco a la explicación científica del fenómeno. La ciencia no busca únicamente anticipar qué ocurrirá; también intenta comprender por qué ocurre, en qué condiciones y con qué limitaciones puede generalizarse.

Algo similar sucede con el análisis cualitativo. La IA puede leer y clasificar miles de textos con rapidez, pero la interpretación de experiencias humanas requiere comprender contextos que no se reducen a patrones lingüísticos. Por ello, el investigador conserva una función central como mediador entre los resultados computacionales y su significado científico.

La reproducibilidad debería convertirse además en un criterio transversal. Si una investigación utiliza algoritmos, modelos o procedimientos automatizados, debería documentarlos con suficiente

precisión para permitir su evaluación. Heil et al. (2021) sostienen que una investigación basada en aprendizaje automático confiable necesita ser computacionalmente reproducible.

Resnik y Hosseini (2025) complementan esta exigencia al recordar que el uso de inteligencia artificial introduce nuevas responsabilidades relacionadas con errores, sesgos y transparencia.

Desde mi perspectiva, estas dos dimensiones reproducibilidad y responsabilidad deberían convertirse en los pilares del análisis científico asistido por IA. No basta con obtener un resultado preciso; necesitamos saber de dónde provino, qué decisiones lo produjeron, cuáles son sus limitaciones y quién responde por su interpretación.

En definitiva, la inteligencia artificial amplía la capacidad de procesar datos, pero la transformación de esos datos en conocimiento continúa requiriendo criterio científico. Un modelo puede encontrar patrones; el investigador debe determinar cuáles merecen atención. Puede producir predicciones; el investigador debe establecer hasta dónde son válidas. Puede analizar lenguaje; el investigador debe comprender su contexto. La fortaleza de la investigación contemporánea surgirá precisamente de esa integración entre capacidad computacional, rigor metodológico e interpretación humana.

CAPÍTULO 5

Escritura científica, ética e integridad en investigaciones mediadas por inteligencia artificial



Autor:

Luis Alberto Limón Montelongo

Capítulo 5.

Escritura científica, ética e integridad en investigaciones mediadas por inteligencia artificial

La inteligencia artificial generativa ha introducido nuevas posibilidades para planificar, redactar, revisar y comunicar productos científicos. Su incorporación puede facilitar tareas relacionadas con la organización de ideas, corrección lingüística, síntesis, estructuración preliminar de documentos y adaptación del lenguaje académico. Sin embargo, también plantea interrogantes relacionados con autoría, transparencia, privacidad, referencias inexistentes, sesgos, propiedad intelectual e integridad científica.

Salvagno, Taccone y Gerli (2023) sostienen que herramientas como ChatGPT pueden apoyar diferentes tareas vinculadas con la escritura científica, aunque enfatizan que su utilización no sustituye la experiencia, el juicio ni la responsabilidad del investigador. De manera complementaria, Resnik y Hosseini (2025) señalan que el uso científico de la IA requiere criterios explícitos de transparencia, supervisión y responsabilidad.

Desde mi perspectiva, el desafío no consiste en impedir la incorporación de inteligencia artificial a la escritura científica, sino en establecer límites claros entre asistencia tecnológica y contribución intelectual. La IA puede mejorar un texto; pero la argumentación, la originalidad, la verificación de las fuentes y la responsabilidad sobre lo publicado continúan correspondiendo al autor.

5.1. Escritura académica y científica asistida por inteligencia artificial generativa

La escritura científica implica comunicar conocimiento de manera clara, argumentada, verificable y coherente con las convenciones de cada disciplina. Los modelos generativos pueden intervenir como asistentes durante diferentes momentos del proceso:

**Planificación → organización → borrador → revisión →
corrección → comunicación**

Salvagno et al. (2023) consideran que la inteligencia artificial puede ser útil para organizar materiales, mejorar el lenguaje y apoyar la elaboración de textos científicos. No obstante, advierten que sus resultados necesitan supervisión especializada.

He et al. (2023) también examinan las oportunidades y riesgos de ChatGPT para la escritura científica. Entre sus posibilidades se encuentra la asistencia lingüística; entre sus peligros destacan errores factuales, información no verificable y dificultades relacionadas con integridad y atribución.

Esto obliga a establecer una diferencia fundamental:

asistencia a la escritura ≠ autoría científica

La IA puede sugerir una reformulación, pero no puede asumir la responsabilidad por aquello que finalmente se afirma.

A mi criterio, uno de los usos más razonables consiste en emplearla como lector crítico preliminar: detectar redundancias, revisar claridad, sugerir estructuras alternativas o identificar posibles inconsistencias. Su función debe fortalecer el pensamiento del investigador y no producir un documento que este acepte sin evaluación.

5.2. Construcción de artículos, libros, tesis e informes científicos

Cada producto académico responde a finalidades, estructuras y niveles de profundidad diferentes. Un artículo científico comunica de manera sintética resultados derivados de una investigación delimitada; una tesis documenta con mayor amplitud el problema, los fundamentos teóricos, el proceso metodológico, los resultados y la discusión; un libro académico permite desarrollar conocimientos, enfoques y argumentos con mayor extensión y articulación temática; mientras que un informe científico suele orientarse a presentar hallazgos, diagnósticos, evaluaciones o recomendaciones vinculadas con necesidades institucionales, profesionales o técnicas.

Esta diversidad implica que la inteligencia artificial no debería utilizarse de la misma manera en todos los productos. Su aporte debe ajustarse al propósito comunicativo, al género académico y al nivel de profundidad esperado. En un artículo, por ejemplo, puede ayudar a organizar la secuencia argumentativa, reducir redundancias o mejorar la claridad del resumen. En una tesis, puede contribuir a revisar la coherencia entre capítulos, identificar vacíos argumentativos o comparar la correspondencia entre objetivos, resultados y conclusiones. En un libro académico, puede apoyar la planificación temática, la organización de capítulos, la detección de repeticiones y la construcción de transiciones. En un informe científico, puede facilitar la síntesis de resultados y su presentación para públicos específicos.

Entre las tareas en las que estas herramientas pueden resultar útiles se encuentran:

- estructuración preliminar de capítulos y apartados;
- síntesis de contenidos extensos;
- organización y jerarquización de argumentos;
- revisión de coherencia interna;

- detección de redundancias;
- adaptación del lenguaje según el tipo de audiencia;
- elaboración preliminar de tablas, esquemas y organizadores;
- comparación entre versiones de un mismo documento;
- revisión de consistencia terminológica;
- generación de propuestas de títulos y subtítulos;
- apoyo en la redacción de transiciones entre secciones;
- identificación de posibles vacíos en la exposición.

Estas posibilidades pueden reducir parte de la carga mecánica asociada con la escritura, pero no resuelven por sí mismas los problemas intelectuales que implica construir un producto científico. La principal dificultad de una tesis, artículo o libro rara vez consiste únicamente en redactar frases correctas; el verdadero desafío está en sostener una línea argumentativa coherente, fundamentar afirmaciones, relacionar resultados con teoría y ofrecer una contribución identificable.

Salvagno et al. (2023) señalan que los modelos generativos pueden funcionar como herramientas de apoyo durante la escritura científica, particularmente en tareas de organización y revisión lingüística. No obstante, los autores recuerdan que estas tecnologías no reemplazan el conocimiento especializado ni el juicio científico de quien investiga. Esta distinción resulta fundamental porque una producción académica puede estar lingüísticamente bien construida y, al mismo tiempo, contener errores conceptuales, metodológicos o bibliográficos.

Currie (2023) advierte precisamente que la utilización de ChatGPT y otras herramientas generativas introduce interrogantes importantes sobre integridad académica, especialmente cuando se vuelve difícil distinguir entre una asistencia legítima y una producción intelectual presentada como propia. Esta preocupación adquiere especial relevancia en documentos como tesis y artículos, donde la originalidad de los planteamientos y la trazabilidad de las fuentes constituyen elementos esenciales de evaluación.

La construcción de un documento científico debería conservar, por tanto, una secuencia claramente humana de razonamiento:

problema → evidencia → argumento → interpretación → conclusión.

La inteligencia artificial puede intervenir en cada una de estas etapas como recurso de apoyo, pero no debería alterar su lógica. Un sistema puede sugerir un argumento, aunque el investigador debe determinar si posee fundamento. Puede producir una conclusión preliminar, pero esta solo será válida si deriva realmente de los resultados obtenidos. Puede generar una referencia, pero esta necesita ser comprobada en la fuente original.

Un riesgo particular aparece cuando los investigadores utilizan herramientas generativas para producir grandes bloques de texto sin una revisión profunda. La fluidez lingüística puede generar una falsa sensación de calidad. Elali y Rachid (2023) advierten que la generación automatizada de textos científicos puede facilitar prácticas problemáticas relacionadas con fabricación, plagio o circulación de contenidos cuya procedencia no resulta completamente clara. Por ello, la revisión humana no debería limitarse a corregir estilo, sino también a verificar contenido, evidencia, coherencia y autenticidad.

Construcción de artículos científicos

En el caso de los artículos, la inteligencia artificial puede apoyar la organización de estructuras como introducción, metodología, resultados y discusión. También puede ayudar a comprobar si el objetivo formulado aparece efectivamente respondido en las conclusiones o si existen repeticiones innecesarias entre resultados y discusión.

Sin embargo, la IA no debería generar resultados que no provengan de la investigación ni completar vacíos empíricos mediante inferencias inventadas. La sección de resultados debe reflejar exclusivamente los

datos obtenidos, mientras que la discusión necesita sustentarse en la interpretación de esos hallazgos y en su contraste con literatura verificable.

A mi criterio, la IA ofrece especial valor en esta etapa cuando funciona como un revisor crítico adicional. Puede preguntarse, por ejemplo: ¿el argumento responde al objetivo?, ¿la conclusión introduce afirmaciones que no fueron demostradas?, ¿existen contradicciones entre metodología y resultados? Estas funciones pueden fortalecer el documento sin sustituir la responsabilidad intelectual.

Construcción de tesis

En una tesis, la extensión y complejidad documental hacen que la IA pueda resultar útil para mantener consistencia entre capítulos. Puede ayudar a comparar conceptos utilizados en el marco teórico con las variables posteriormente analizadas, detectar objetivos que no fueron abordados o identificar secciones desproporcionadas.

Sin embargo, una tesis constituye también evidencia de la formación investigativa de su autor. Por ello, delegar excesivamente la construcción intelectual del documento contradice su propósito formativo. El estudiante debe ser capaz de explicar y defender las decisiones adoptadas, independientemente de las herramientas empleadas para apoyarse.

En este sentido, una tesis asistida por IA debería seguir un principio claro: todo contenido incluido debe poder ser explicado, defendido y verificado por su autor.

Si una persona no puede explicar por qué utilizó determinada técnica, de dónde proviene una afirmación o cómo se obtuvo una conclusión, la existencia de un texto formalmente correcto no compensa esa debilidad.

Construcción de libros académicos

En los libros científicos y académicos, las herramientas inteligentes pueden aportar valor en la planificación global de la obra. La coordinación entre capítulos, la continuidad conceptual, la consistencia terminológica y la reducción de redundancias representan tareas en las que la IA puede colaborar de manera significativa.

También puede ayudar a analizar si el índice mantiene una progresión lógica, si determinados conceptos se repiten excesivamente o si existen temas importantes que necesitan mayor desarrollo.

No obstante, un libro requiere una arquitectura intelectual propia. La simple acumulación de capítulos generados alrededor de un tema no constituye necesariamente una obra académica coherente. El lector debería reconocer una perspectiva, una secuencia argumentativa y una contribución claramente identificable.

Desde mi punto de vista, el mayor riesgo en la escritura de libros asistida por IA es la homogeneización del discurso. Los modelos generativos tienden a producir estructuras y formas de expresión relativamente previsibles. Si no existe suficiente intervención del autor, diferentes capítulos pueden terminar repitiendo patrones, frases y conclusiones similares. La revisión humana debe incorporar diversidad argumentativa, ejemplos pertinentes y una voz académica reconocible.

Construcción de informes científicos

Los informes científicos presentan otra exigencia: transformar evidencia compleja en información útil para la toma de decisiones. Aquí la inteligencia artificial puede ayudar a sintetizar resultados, identificar tendencias y adaptar el lenguaje para diferentes públicos.

Sin embargo, la síntesis no debe simplificar excesivamente las conclusiones. Un informe destinado a responsables institucionales, por

ejemplo, necesita comunicar resultados con claridad, pero también mostrar limitaciones, nivel de incertidumbre y condiciones bajo las cuales pueden aplicarse las recomendaciones.

Esto es especialmente importante cuando las herramientas de IA generan resúmenes. Un sistema puede eliminar matices considerados secundarios desde una perspectiva lingüística, aunque metodológicamente sean esenciales. Por ello, toda síntesis automatizada debe compararse con los datos y documentos originales.

En conjunto, puede proponerse una lógica responsable de construcción:

IA para organizar → investigador para argumentar → fuentes para fundamentar → datos para demostrar → revisión para validar.

Esta secuencia permite aprovechar las ventajas de la inteligencia artificial sin confundir productividad textual con calidad científica. La tecnología puede contribuir a construir documentos más claros, ordenados y consistentes, pero la validez de una obra depende de la relación entre lo que se afirma y la evidencia que permite sostenerlo.

Desde mi criterio, el mejor uso de la IA no consiste en pedirle que “escriba una investigación”, sino en convertirla en un interlocutor que ayude a examinar críticamente el trabajo: cuestionar la coherencia, identificar vacíos, comparar alternativas y mejorar la comunicación. De esta forma, el investigador conserva aquello que ninguna herramienta debería asumir en su lugar: la construcción del argumento, la interpretación de la evidencia y la responsabilidad por el conocimiento comunicado.

En definitiva, un texto científicamente atractivo pero sustentado en referencias inexistentes, interpretaciones erróneas, datos no comprobados o argumentos que el autor no puede defender continúa siendo científicamente inválido. La calidad de un producto académico no

depende únicamente de cómo está escrito, sino de la solidez intelectual, metodológica y ética que sostiene cada una de sus afirmaciones.

5.3. Autoría, citación, transparencia y declaración del uso de inteligencia artificial

La autoría científica implica mucho más que producir palabras. Supone realizar una contribución intelectual, responder por las decisiones metodológicas, verificar los resultados y asumir responsabilidad pública sobre el contenido.

Thorp (2023) sintetizó esta posición desde *Science* al señalar que ChatGPT puede ser una herramienta, pero no un autor. La razón fundamental es que un sistema de IA no puede asumir responsabilidad científica por un artículo ni responder por la veracidad de sus afirmaciones.

Resnik y Hosseini (2025) coinciden en que los sistemas de inteligencia artificial no deberían recibir autoría, aunque el uso relevante de estas tecnologías debe comunicarse de manera transparente.

Una declaración responsable podría especificar:

herramienta utilizada + finalidad + etapa de utilización + nivel de revisión humana

Por ejemplo:

Se utilizó una herramienta de inteligencia artificial generativa como apoyo para la revisión lingüística y organización preliminar del texto. Todas las fuentes, argumentos e interpretaciones fueron verificadas y revisadas por los autores.

La transparencia no debería entenderse como una penalización al investigador, sino como parte de la trazabilidad del trabajo científico.

También resulta indispensable verificar las referencias. Los modelos generativos pueden producir citas aparentemente plausibles que no existen o combinar incorrectamente autor, título, año y DOI.

Por ello:

una referencia proporcionada por IA debe considerarse provisional hasta comprobarse en una fuente académica real.

5.4. Sesgos algorítmicos, privacidad, propiedad intelectual e integridad científica

La utilización de sistemas inteligentes introduce desafíos que exceden la calidad lingüística del texto.

Uno de ellos es el sesgo algorítmico. Resnik y Hosseini (2025) advierten que los modelos pueden reproducir o amplificar sesgos contenidos en los datos con los que fueron desarrollados. Esto puede afectar análisis, recomendaciones y conclusiones.

Otro problema se relaciona con la privacidad. Introducir entrevistas, expedientes, bases de participantes o información confidencial en plataformas externas puede comprometer las obligaciones éticas de una investigación.

Como principio general: los datos sensibles no deberían introducirse en herramientas externas sin conocer sus condiciones de tratamiento, almacenamiento y protección.

La propiedad intelectual representa otro ámbito complejo. Islam y Greenwood (2024) analizan cómo la IA generativa plantea nuevas preguntas relacionadas con autoría y propiedad de los contenidos producidos mediante estos sistemas.

Asimismo, Elali y Rachid (2023) advierten acerca de los riesgos que la generación automatizada de textos puede introducir para la

comunidad científica, especialmente cuando facilita fabricación, plagio o circulación de contenido aparentemente académico.

La integridad científica debe mantenerse, por tanto, por encima de la eficiencia tecnológica.

Tabla 6. Principios para el uso responsable de inteligencia artificial en escritura e investigación científica

La Tabla 6 resume algunos criterios que deberían orientar la incorporación de herramientas generativas en productos científicos.

Dimensión	Uso responsable	Riesgo principal	Criterio esencial
Escritura	Apoyar organización y revisión	Dependencia y errores	Supervisión humana
Citación	Localizar o estructurar referencias	Fuentes inexistentes	Verificación documental
Autoría	Declarar la asistencia tecnológica	Atribución indebida	Responsabilidad humana
Datos	Procesar información autorizada	Pérdida de privacidad	Confidencialidad
Análisis	Explorar patrones y alternativas	Sesgos algorítmicos	Validación
Publicación	Mejorar comunicación	Falta de transparencia	Declaración del uso de IA

Fuente: elaboración propia a partir de Salvagno et al. (2023), Thorp (2023), Currie (2023), Islam y Greenwood (2024) y Resnik y Hosseini (2025).

Como muestra la Tabla 6, los principales riesgos no provienen exclusivamente de la existencia de la inteligencia artificial, sino de la manera en que se utiliza. La misma herramienta que puede contribuir a mejorar la claridad de un manuscrito también puede generar referencias falsas, introducir sesgos o comprometer información confidencial si se emplea sin controles adecuados. Por ello, la transparencia, la verificación y la supervisión humana deben considerarse principios transversales.

5.5. Reproducibilidad, ciencia abierta y futuro de la investigación científica

La transformación digital de la ciencia también está reforzando la necesidad de investigaciones más abiertas y reproducibles.

Heil et al. (2021) sostienen que la investigación basada en aprendizaje automático necesita estándares de reproducibilidad relacionados con datos, modelos, código y documentación de los procedimientos. Esta exigencia adquiere especial relevancia cuando intervienen algoritmos cuya operación no siempre resulta completamente visible para el lector.

La inteligencia artificial puede contribuir a estos procesos mediante automatización de documentación, análisis reproducibles y gestión de grandes repositorios. Sin embargo, también puede introducir nuevos obstáculos cuando se utilizan modelos propietarios cuyo funcionamiento, datos de entrenamiento o versiones no pueden examinarse.

Por ello, considero que las investigaciones mediadas por IA deberían incorporar, cuando resulte pertinente, información sobre:

**modelo utilizado → versión → finalidad → datos procesados →
procedimiento → validación humana**

La reproducibilidad futura no dependerá únicamente de conocer qué programa estadístico fue utilizado, sino también de documentar suficientemente la participación de sistemas inteligentes.

Gao y Wang (2024) muestran que la IA está extendiéndose rápidamente dentro de la ciencia. Este crecimiento permite anticipar un ecosistema donde la colaboración entre investigadores y sistemas computacionales será cada vez más frecuente. No obstante, el futuro científico debería medirse menos por el grado de automatización alcanzado y más por la capacidad de mantener calidad, apertura, equidad y confianza.




Figura 5. Escudo de integridad científica para el uso responsable de inteligencia artificial en investigación y escritura académica.

Como se observa en la Figura 5, la integridad científica en investigaciones mediadas por inteligencia artificial depende de la articulación de cinco dimensiones fundamentales: escritura responsable, autoría y transparencia, citación y evidencia, ética y protección de datos, y reproducibilidad y ciencia abierta. Estas dimensiones no actúan de manera aislada, sino como componentes complementarios que protegen la calidad y credibilidad del proceso científico.

La figura también destaca cinco acciones esenciales verificar, declarar, proteger, documentar y reproducir que deben acompañar el uso de herramientas de inteligencia artificial. Su incorporación permite establecer controles frente a riesgos como referencias inexistentes, pérdida de trazabilidad, exposición de información sensible, sesgos algorítmicos o atribuciones incorrectas de autoría.

Desde una perspectiva investigativa, el elemento más relevante del modelo es que sitúa la responsabilidad científica en el investigador. La inteligencia artificial puede contribuir a redactar, organizar, analizar o sintetizar información, pero corresponde al autor comprobar la evidencia, declarar de manera transparente su utilización y garantizar que cada decisión pueda ser metodológicamente justificada.

Reflexión final

La inteligencia artificial generativa está modificando la escritura, publicación y comunicación de la ciencia, pero no transforma los principios fundamentales que otorgan legitimidad al conocimiento. Una investigación continúa necesitando evidencia verificable, procedimientos transparentes, interpretación crítica y autores capaces de responder por sus conclusiones.

Salvagno et al. (2023) muestran las posibilidades de la IA como apoyo a la escritura; Thorp (2023) establece claramente sus límites respecto de la autoría; Heil et al. (2021) resaltan la importancia de la reproducibilidad; y Resnik y Hosseini (2025) sitúan la responsabilidad, los sesgos y la transparencia entre los principales desafíos éticos de esta nueva etapa.

Desde mi criterio, la discusión futura no debería dividir a los investigadores entre quienes usan y quienes no usan inteligencia artificial. La diferencia verdaderamente importante estará entre quienes la emplean con criterios científicos y quienes delegan en ella funciones que requieren responsabilidad intelectual.

La IA puede mejorar una frase, organizar información, detectar patrones y acelerar determinadas tareas. Pero no puede asumir la responsabilidad epistemológica y ética de aquello que una comunidad científica acepta como conocimiento.

Por ello, el principio que debería cerrar este libro es sencillo pero decisivo: cuanto mayor sea la capacidad de la inteligencia artificial para intervenir en la investigación, mayor deberá ser la capacidad del investigador para verificar, explicar y asumir responsabilidad por cada decisión científica.

CAPÍTULO 6

Innovación, automatización y nuevas fronteras de la investigación científica con inteligencia artificial



○ Autora: ○

Ivette Amalia Talavera Cortez

Capítulo 6.

Innovación, automatización y nuevas fronteras de la investigación científica con inteligencia artificial

La investigación científica está entrando en una etapa en la que la inteligencia artificial ya no funciona únicamente como herramienta de apoyo para tareas aisladas. Su integración comienza a extenderse hacia flujos de trabajo más complejos, procesos semiautónomos, simulaciones, experimentación digital y sistemas capaces de colaborar con investigadores en distintas fases del descubrimiento científico. Este cambio abre nuevas posibilidades, pero también exige revisar qué significa investigar cuando parte de las decisiones, análisis o acciones pueden ser ejecutadas por sistemas inteligentes.

Gao y Wang (2024) muestran que el uso de inteligencia artificial se ha extendido ampliamente por múltiples disciplinas científicas y que sus beneficios potenciales han crecido con rapidez desde 2015. Este fenómeno indica que la IA está dejando de ser un recurso especializado para convertirse progresivamente en una infraestructura transversal dentro de la ciencia contemporánea.

Más recientemente, Resnik, Hosseini y Hauswald (2026) señalan que la incorporación de inteligencia artificial en investigación está avanzando desde una fase dominada por herramientas bajo control humano directo hacia otra en la que agentes de IA pueden realizar determinadas tareas con autonomía parcial, aunque todavía bajo supervisión humana.

Este escenario modifica la relación tradicional entre investigador, método y tecnología. El científico deja de interactuar únicamente con programas que ejecutan instrucciones específicas y comienza a trabajar con sistemas capaces de proponer acciones, modificar procedimientos o coordinar múltiples tareas.

Desde mi perspectiva, este cambio representa una de las transformaciones más importantes de la metodología científica contemporánea. El desafío ya no consiste solamente en aprender a utilizar inteligencia artificial, sino en establecer qué grado de autonomía puede delegarse, qué decisiones deben permanecer bajo control humano y cómo garantizar que la automatización no debilite la transparencia, la reproducibilidad ni la responsabilidad científica.

6.1. Automatización inteligente de procesos y flujos de investigación

Un flujo de trabajo científico reúne las diferentes actividades necesarias para transformar una pregunta en resultados reproducibles. Puede incluir adquisición de datos, preparación, procesamiento, análisis, generación de gráficos, evaluación y almacenamiento de resultados.

Tradicionalmente, muchas de estas actividades requerían intervención manual. Actualmente, los sistemas computacionales permiten construir secuencias automatizadas capaces de ejecutar múltiples tareas siguiendo criterios previamente definidos.

La automatización puede representarse mediante la secuencia:

Entrada de datos → procesamiento → análisis → validación → resultados → documentación

Su principal ventaja consiste en reducir tareas repetitivas y disminuir errores operativos. Además, facilita que un procedimiento pueda repetirse bajo condiciones similares.

Sänger et al. (2024) destacan que los sistemas de flujos científicos permiten ejecutar procesos complejos de análisis sobre grandes conjuntos de datos y ofrecen ventajas relacionadas con reproducibilidad, confiabilidad y escalabilidad. Su estudio muestra que los modelos de lenguaje pueden interpretar con buena precisión flujos ya existentes, aunque presentan mayores limitaciones cuando deben modificar componentes o extenderlos de forma intencionada.

Este hallazgo resulta especialmente importante porque demuestra que la automatización no debería confundirse con autonomía completa.

Un sistema puede comprender una secuencia de pasos, pero modificar metodológicamente un procedimiento exige comprender qué consecuencias científicas produce ese cambio.

Puede distinguirse entre tres niveles:

- **Automatización básica:** ejecuta instrucciones previamente definidas.
- **Automatización inteligente:** selecciona entre alternativas utilizando reglas o modelos.
- **Automatización adaptativa:** modifica determinados pasos según resultados intermedios.

Cuanto mayor sea el nivel de autonomía, mayor deberá ser también la exigencia de supervisión.

Desde mi criterio, el principal beneficio de automatizar la investigación no debería medirse únicamente por el tiempo ahorrado. Su verdadero valor aparece cuando mejora la trazabilidad, consistencia y reproducibilidad del proceso.

Automatizar un error simplemente permite reproducir ese error con mayor rapidez.

6.2. Agentes de inteligencia artificial y asistentes autónomos para la investigación científica

Una de las tendencias más relevantes de los últimos años es la aparición de agentes de inteligencia artificial. A diferencia de un sistema generativo que responde a una instrucción puntual, un agente puede recibir una meta general y ejecutar varias acciones intermedias para intentar alcanzarla.

En investigación, un agente podría, por ejemplo:

buscar literatura → organizar documentos → identificar información → ejecutar análisis → generar un informe preliminar.

Esto introduce una diferencia importante entre herramienta y agente.

Una herramienta espera instrucciones específicas.

Un agente puede planificar parcialmente qué pasos realizar.

Resnik et al. (2026) describen precisamente esta transición al señalar que los agentes de IA comienzan a realizar tareas investigativas con autonomía parcial mientras permanecen bajo supervisión y control humanos.

Esta evolución abre oportunidades interesantes para investigaciones complejas. Diferentes agentes podrían especializarse en tareas distintas: uno localizar literatura, otro analizar datos y otro revisar consistencia metodológica.

Sin embargo, también aparecen nuevos riesgos.

Si un agente decide qué documentos priorizar, qué variables incluir o qué análisis ejecutar, parte de la metodología podría quedar implícita dentro del sistema.

Por ello, deberían establecerse límites claros sobre:

qué puede decidir el agente → qué necesita autorización → qué debe documentarse → qué requiere verificación humana.

Resnik y Hosseini (2025) sostienen que quienes utilizan inteligencia artificial en investigación son responsables de identificar, describir, reducir y controlar sesgos y errores relacionados con estos sistemas, además de explicar de forma transparente cómo fueron utilizados.

Esta responsabilidad se vuelve todavía más relevante con agentes parcialmente autónomos.

Desde mi perspectiva, la pregunta clave no debería ser “¿puede hacerlo la IA?”, sino:

“¿es científicamente conveniente permitir que lo haga sin intervención humana?”

La diferencia entre ambas preguntas es fundamental.

6.3. Laboratorios digitales, simulación científica y experimentación asistida por IA

La experimentación tradicional depende frecuentemente de recursos físicos, materiales, tiempo y condiciones controladas. Sin embargo, el crecimiento de la simulación computacional y de la inteligencia artificial está permitiendo explorar fenómenos mediante modelos digitales antes de realizar determinados experimentos físicos.

Los laboratorios digitales pueden incluir:

- simulaciones;
- modelos computacionales;
- gemelos digitales;
- optimización automática;
- experimentación virtual;
- análisis de escenarios.

Estas herramientas permiten probar un número elevado de posibilidades antes de seleccionar cuáles merecen experimentación real.

Wang et al. (2023) muestran que la inteligencia artificial está ampliando el descubrimiento científico en áreas como biología, química y ciencia de materiales, donde los modelos pueden explorar espacios de soluciones extraordinariamente grandes y ayudar a priorizar candidatos para su evaluación experimental.

Este proceso transforma parcialmente la lógica tradicional:

hipótesis → experimento físico → resultado

hacia modelos más iterativos:

**modelo → simulación → predicción → experimento →
retroalimentación → nuevo modelo**

La IA puede acelerar especialmente las fases de exploración y optimización.

Sin embargo, una simulación continúa siendo una representación de la realidad.

Su precisión depende de:

datos + supuestos + parámetros + modelo.

Por ello, un resultado computacional no debería confundirse automáticamente con evidencia empírica.

Desde mi criterio, la mejor función de los laboratorios digitales consiste en reducir el espacio de incertidumbre antes de realizar experimentos físicos, no en eliminar completamente la necesidad de contrastación.

Una simulación puede sugerir dónde mirar; la evidencia experimental determina si aquello que predijo ocurre realmente.

6.4. Investigación interdisciplinaria, colaboración humano-IA y generación de nuevo conocimiento

La inteligencia artificial también está favoreciendo nuevas formas de investigación interdisciplinaria. Muchos problemas científicos actuales — cambio climático, salud, educación, sostenibilidad, sistemas sociales complejos— requieren integrar conocimientos provenientes de múltiples disciplinas.

Los sistemas inteligentes pueden ayudar a relacionar información producida en campos diferentes, detectar conexiones conceptuales y trabajar simultáneamente con datos heterogéneos.

Feuerriegel et al. (2024) explican que la IA generativa puede producir y procesar múltiples tipos de contenido, lo que favorece aplicaciones que combinan lenguaje, datos y otras modalidades de información.

Esto puede facilitar la colaboración entre especialistas.

Por ejemplo, un mismo proyecto podría integrar:

**expertos disciplinares + científicos de datos + especialistas
metodológicos + sistemas de IA.**

Cada componente aporta capacidades distintas.

La colaboración humano-IA no debería concebirse como competencia, sino como complementariedad.

El investigador aporta:

contexto → criterio → creatividad → valores → interpretación

La inteligencia artificial aporta:

**velocidad → procesamiento → reconocimiento de patrones →
exploración de alternativas.**

Esta relación puede producir una forma de inteligencia científica ampliada.

Sin embargo, Gao y Wang (2024) advierten que los beneficios de la IA no se distribuyen uniformemente entre disciplinas ni entre diferentes grupos científicos. También identifican una brecha entre formación en IA y utilización efectiva dentro de la investigación.

Este hallazgo introduce un desafío institucional importante. Si únicamente determinados centros disponen de infraestructura, competencias y recursos avanzados, la IA podría aumentar las desigualdades existentes en la producción científica.

Desde mi punto de vista, el futuro de la investigación dependerá tanto del desarrollo tecnológico como de la capacidad para democratizar competencias, infraestructura y acceso.

Tabla 7. Nuevas fronteras de la investigación científica mediada por inteligencia artificial

Frontera emergente	Aporte de la IA	Oportunidad científica	Riesgo principal
Flujos automatizados	Ejecutar procesos secuenciales	Mayor eficiencia y reproducibilidad	Automatizar errores
Agentes de IA	Planificar y ejecutar tareas parciales	Ampliar capacidad investigativa	Pérdida de control metodológico
Simulación científica	Explorar escenarios y modelos	Reducir costos experimentales	Confundir simulación con evidencia
Laboratorios digitales	Integrar modelos y experimentación	Acelerar ciclos de descubrimiento	Dependencia tecnológica
Colaboración humano-IA	Complementar capacidades	Mejorar análisis y creatividad	Delegación excesiva
Investigación interdisciplinaria	Conectar grandes volúmenes de conocimiento	Generar nuevas relaciones científicas	Simplificación del contexto

Fuente: elaboración propia a partir de Wang et al. (2023), Sanger et al. (2024), Gao y Wang (2024), Resnik y Hosseini (2025) y Resnik et al. (2026).

Como se observa en la Tabla 7, las tecnologas emergentes no sustituyen necesariamente las etapas tradicionales de la investigaci3n; mas bien modifican su velocidad, escala y organizaci3n. Los beneficios potenciales son considerables, pero cada avance incorpora nuevos requisitos de documentaci3n y control.

Desde una perspectiva metodol3gica, la incorporaci3n de agentes, simulaciones o flujos automatizados debera responder siempre a una pregunta basica: esta tecnologa aumenta realmente la calidad del conocimiento generado o nicamente aumenta la cantidad de procesos ejecutados?

Esta distinci3n es fundamental porque la productividad y la calidad cientficas no son equivalentes.

6.5. Tendencias emergentes, desafíos futuros y competencias del investigador en la era de la inteligencia artificial

La transformación de la investigación científica probablemente continuará acelerándose. Sistemas generativos más avanzados, agentes autónomos, modelos multimodales y plataformas de experimentación automatizada ampliarán las posibilidades disponibles.

Resnik et al. (2026) consideran que la transición hacia sistemas más autónomos plantea cuestiones importantes respecto de valores humanos, control y normas científicas.

Por ello, el investigador del futuro necesitará competencias que combinen conocimientos tradicionales y capacidades emergentes.

Entre ellas pueden destacarse:

- **Competencia metodológica.** Comprender profundamente cómo diseñar y evaluar investigaciones.
- **Alfabetización en IA.** Conocer las posibilidades y límites básicos de los sistemas utilizados.
- **Pensamiento crítico.** Cuestionar resultados incluso cuando parecen técnicamente sofisticados.
- **Competencia en datos.** Comprender calidad, procedencia, sesgo y trazabilidad.
- **Ética científica.** Reconocer implicaciones sociales, privacidad y responsabilidad.
- **Capacidad interdisciplinaria.** Trabajar con especialistas provenientes de diferentes campos.
- **Reproducibilidad digital.** Documentar modelos, código, datos y procedimientos.

Gao y Wang (2024) identifican una brecha entre la disponibilidad de formación relacionada con inteligencia artificial y su aplicación científica, lo que señala la necesidad de fortalecer nuevas capacidades dentro de las comunidades investigadoras.

Desde mi criterio, esta brecha probablemente será uno de los principales retos de la próxima década. No será suficiente incorporar herramientas avanzadas a universidades y centros de investigación; será necesario formar investigadores capaces de comprenderlas críticamente.

El investigador del futuro no necesariamente necesitará desarrollar modelos de inteligencia artificial desde cero, pero sí deberá ser capaz de responder preguntas como:

¿qué hace este sistema?, ¿con qué datos trabaja?, ¿qué errores puede cometer?, ¿por qué debo confiar en el resultado?, ¿puede reproducirse?, ¿qué decisiones permanecen bajo mi responsabilidad?

Estas preguntas son metodológicas antes que tecnológicas.

Reflexión final del capítulo

La investigación científica está evolucionando desde un escenario donde la inteligencia artificial funcionaba principalmente como herramienta auxiliar hacia otro en el que comienzan a aparecer sistemas capaces de participar activamente en flujos de trabajo, análisis y decisiones parciales.

Sänger et al. (2024) muestran que los modelos de lenguaje ya pueden apoyar la comprensión de flujos científicos complejos, aunque todavía presentan limitaciones cuando deben modificarlos o ampliarlos. Gao y Wang (2024) evidencian que el uso de IA se extiende rápidamente por las ciencias, mientras que Resnik et al. (2026) advierten que los agentes parcialmente autónomos representan una nueva etapa en esta integración.

A mi juicio, la principal transformación no será tecnológica, sino epistemológica. A medida que los sistemas inteligentes participen más activamente en la investigación, será necesario redefinir con precisión dónde termina la asistencia automatizada y dónde comienza la decisión científica.

- ✓ La automatización puede ejecutar procedimientos.
- ✓ Los agentes pueden coordinar tareas.
- ✓ Los modelos pueden realizar predicciones.
- ✓ Las simulaciones pueden explorar escenarios.

Pero determinar qué problema merece estudiarse, qué evidencia resulta suficiente y qué significado científico posee un resultado continúa siendo una responsabilidad profundamente humana.

Por ello, el futuro de la investigación no debería orientarse hacia una ciencia completamente autónoma, sino hacia una ciencia aumentada, donde las capacidades computacionales amplíen el potencial investigador sin eliminar la supervisión, el pensamiento crítico y la responsabilidad.

Resnik y Hosseini (2025) recuerdan que los beneficios de la inteligencia artificial conviven con problemas éticos complejos y que los investigadores deben asumir responsabilidad por su uso, sus limitaciones y sus posibles sesgos.

Desde esta perspectiva, el reto fundamental de las próximas décadas no será construir sistemas capaces de hacer más ciencia, sino garantizar que esa ciencia siga siendo comprensible, reproducible, responsable y orientada al bienestar humano.

La inteligencia artificial puede ampliar las fronteras de aquello que somos capaces de descubrir. Sin embargo, la dirección que tome ese descubrimiento continuará dependiendo de las preguntas, valores y decisiones de quienes investigan.

Referencias Bibliográficas:

- Abbas, M., Jam, F. A., & Khan, T. I. (2024). Is it harmful or helpful? Examining the causes and consequences of generative AI usage among university students. *International Journal of Educational Technology in Higher Education*, 21, 10. DOI: 10.1186/s41239-024-00444-7.
- Bauchner, H., & Rivara, F. P. (2024). Use of artificial intelligence and the future of peer review. *Health Affairs Scholar*, 2(5), qxae058. DOI: 10.1093/haschl/qxae058.
- Bolaños, F., Salatino, A., Osborne, F., & Motta, E. (2024). Artificial intelligence for literature reviews: Opportunities and challenges. *Artificial Intelligence Review*, 57, 259. DOI: 10.1007/s10462-024-10902-3.
- Currie, G. M. (2023). Academic integrity and artificial intelligence: Is ChatGPT hype, hero or heresy? *Seminars in Nuclear Medicine*, 53(5), 719–730. DOI: 10.1053/j.semnuclmed.2023.04.008.
- de la Torre-López, J., Ramírez, A., & Romero, J. R. (2023). Artificial intelligence to automate the systematic review of scientific literature. *Computing*, 105, 2171–2194. DOI: 10.1007/s00607-023-01181-x.
- Elali, F. R., & Rachid, L. N. (2023). AI-generated research paper fabrication and plagiarism in the scientific community. *Patterns*, 4, 100706. DOI: 10.1016/j.patter.2023.100706.
- Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative AI. *Business & Information Systems Engineering*, 66, 111–126. DOI: 10.1007/s12599-023-00834-7.
- Gao, J., & Wang, D. (2024). Quantifying the use and potential benefits of artificial intelligence in scientific research. *Nature Human Behaviour*, 8, 2281–2292. DOI: 10.1038/s41562-024-02020-5.
- Hagendorff, T. (2024). Mapping the ethics of generative AI: A comprehensive scoping review. *Minds and Machines*, 34, 39. DOI: 10.1007/s11023-024-09694-w.

- He, S., Yang, F., Zuo, J.-P., & Lin, Z.-M. (2023). ChatGPT for scientific paper writing—Promises and perils. *The Innovation*, 4(6), 100524. DOI: 10.1016/j.xinn.2023.100524.
- Heil, B. J., Hoffman, M. M., Markowetz, F., Lee, S.-I., Greene, C. S., & Hicks, S. C. (2021). Reproducibility standards for machine learning in the life sciences. *Nature Methods*, 18, 1132–1135. DOI: 10.1038/s41592-021-01256-7.
- Islam, G., & Greenwood, M. (2024). Generative artificial intelligence as hypercommons: Ethics of authorship and ownership. *Journal of Business Ethics*, 192, 659–663. DOI: 10.1007/s10551-024-05741-9.
- Li, Z.-Q., Xu, H.-L., Cao, H.-J., Liu, Z.-L., Fei, Y.-T., & Liu, J.-P. (2024). Use of artificial intelligence in peer review among top 100 medical journals. *JAMA Network Open*, 7(12), e2448609. DOI: 10.1001/jamanetworkopen.2024.48609.
- Malik, M. A. A., Amjad, A. I., Aslam, S., & Fakhrou, A. (2024). Global insights: ChatGPT's influence on academic and research writing, creativity, and plagiarism policies. *Frontiers in Research Metrics and Analytics*, 9, 1486832. DOI: 10.3389/frma.2024.1486832.
- Ning, Y., Teixayavong, S., Shang, Y., Savulescu, J., Nagaraj, V., Miao, D., et al. (2024). Generative artificial intelligence and ethical considerations in health care: A scoping review and ethics checklist. *The Lancet Digital Health*, 6(11), e848–e856. DOI: 10.1016/S2589-7500(24)00143-2.
- Ofori-Boateng, R., Aceves-Martins, M., Wiratunga, N., & Moreno-Garcia, C. F. (2024). Towards the automation of systematic reviews using natural language processing, machine learning, and deep learning: A comprehensive review. *Artificial Intelligence Review*, 57, 200. DOI: 10.1007/s10462-024-10844-w.
- Oliveira-Santos, C., Takeshita, W. M., & Oliveira, M. L. (2023). ChatGPT: A tool for scientific writing or a threat to integrity? *British Journal of Radiology*, 96(1152), 20230430. DOI: 10.1259/bjr.20230430.
- Park, S. G. (2025). AI and systematic reviews: Can AI tools replace librarians in the systematic search process? *Science & Technology Libraries*. DOI: 10.1080/0194262X.2025.2521519.

- Resnik, D. B., & Hosseini, M. (2025). The ethics of using artificial intelligence in scientific research: New guidance needed for a new tool. *AI and Ethics*, 5, 1499–1521. DOI: 10.1007/s43681-024-00493-8.
- Sänger, M., De Mecquenem, N., Lewińska, K. E., Bountris, V., Lehmann, F., Leser, U., & Kosch, T. (2024). A qualitative assessment of using ChatGPT as large language model for scientific workflow development. *GigaScience*, 13, giae030. DOI: 10.1093/gigascience/giae030.
- Salvagno, M., Taccone, F. S., & Gerli, A. G. (2023). Can artificial intelligence help for scientific writing? *Critical Care*, 27, 75. DOI: 10.1186/s13054-023-04380-2.
- Sengar, S. S., Hasan, A. B., Kumar, S., & Carroll, F. (2025). Generative artificial intelligence: A systematic review and applications. *Multimedia Tools and Applications*, 84, 23661–23700. DOI: 10.1007/s11042-024-20016-1.
- Thorp, H. H. (2023). ChatGPT is fun, but not an author. *Science*, 379, 313. DOI: 10.1126/science.adg7879.
- Tomczyk, P. (2026). AI meets academia: Transforming systematic literature reviews. *EuroMed Journal of Business*, 21(1), 345–369. DOI: 10.1108/EMJB-03-2024-0055.
- Watermeyer, R., Phipps, L., Lanclos, D., & Knight, C. (2024). Generative AI and the automating of academia. *Postdigital Science and Education*, 6, 446–466. DOI: 10.1007/s42438-023-00440-6.

SEMBLANZA DE AUTORES





Ericka Torres Gaytan



CORREO ELECTRÓNICO
eritgaytan@gmail.com



ORCID
<https://orcid.org/0009-0007-8978-3599>

Biografía de la autora

Ericka Torres Gaytan es profesional del ámbito educativo con experiencia en docencia, capacitación para el empleo, gestión educativa y vinculación institucional. Posee formación en Ingeniería en Sistemas de Producción, una especialidad en Recursos Humanos, maestrías en Administración con énfasis en Relaciones Industriales y en Educación en el área de Docencia e Investigación, además de estudios doctorales en Ciencias de la Educación y Administración. Desde 2019 se desempeña como docente en la Universidad Autónoma de Tamaulipas, UAMRR, y desde 2012 participa en el Instituto Tamaulipeco de Capacitación para el Empleo, Plantel Reynosa, en actividades de vinculación. También ha ejercido la docencia en el Centro Universitario José Vasconcelos y en la Universidad del Atlántico. Su trayectoria incluye participación en organismos de vinculación educativa y comunitaria, consolidando un perfil orientado a la formación profesional, la colaboración interinstitucional, el liderazgo educativo y el fortalecimiento de las relaciones entre academia, sector productivo y sociedad.



Arturo Navarrete Sánchez



CORREO ELECTRÓNICO

arturo.navarretes@imss.gob.mx



ORCID

<https://orcid.org/0009-0004-3758-6268>

Biografía del autor

Arturo Navarrete Sánchez es médico cirujano y maestro en Salud Pública con área de Epidemiología, con una amplia trayectoria en el Instituto Mexicano del Seguro Social. Su experiencia profesional integra atención médica, epidemiología, prevención, gestión sanitaria, administración y liderazgo institucional. Actualmente se desempeña como Titular del Órgano de Operación Administrativa Desconcentrada del IMSS en Veracruz Sur. Previamente ocupó cargos como Supervisor Médico Delegacional de IMSS-BIENESTAR, Jefe de Servicios de Prestaciones Médicas, Coordinador de Prevención y Atención a la Salud, Coordinador Auxiliar de Gestión Médica y Gerente Delegacional de IMSS-PROSPERA. También cuenta con experiencia docente en la Universidad Autónoma de Tamaulipas y en el propio IMSS, además de participación como ponente, conferencista y sinodal. En el ámbito de la investigación ha colaborado en publicaciones relacionadas con hipertensión arterial y osteoporosis vertebral. Su trayectoria refleja una visión integral de la salud pública, la docencia, la investigación y la gestión institucional.



Moisés Malpica Córdova



CORREO ELECTRÓNICO

moimalpica10@gmail.com



ORCID

<https://orcid.org/0009-0007-81-9281>

Biografía del autor

Moisés Malpica Córdova es Licenciado en Derecho por la Universidad Autónoma de Tamaulipas y Maestro en Derecho Constitucional y Amparo por la Universidad del Desarrollo Profesional. Actualmente cursa estudios de Doctorado en Educación en la Universidad Chapultepec. Cuenta con más de tres décadas de experiencia profesional en el Instituto Mexicano del Seguro Social, donde desempeñó responsabilidades en servicios jurídicos, investigaciones laborales, auditoría, responsabilidades administrativas, desarrollo de personal y funciones directivas. Ocupó cargos como Abogado Procurador, Jefe de Investigaciones Laborales, Jefe del Departamento Contencioso y Jefe de Servicios de Desarrollo de Personal. Su trayectoria le ha permitido especializarse en derecho laboral, constitucional, administrativo y de seguridad social, así como en procedimientos contenciosos y gestión de recursos humanos. Actualmente se desempeña como asesor jurídico vinculado al Congreso del Estado de Tamaulipas y como abogado postulante, integrando experiencia institucional, práctica jurídica, formación académica y servicio público.



Rufino III Contreras De León



CORREO ELECTRÓNICO

rufinocontreras@yahoo.com.mx



ORCID

<https://orcid.org/0009-0007-7396-3229>

Biografía del autor

Rufino III Contreras De León es médico cirujano, especialista en Otorrinolaringología y Cirugía de Cabeza y Cuello, y maestro en Planeación y Gestión Educativa. Cuenta con una amplia trayectoria clínica en el Instituto Mexicano del Seguro Social, donde ha brindado atención especializada, consulta externa, urgencias y procedimientos quirúrgicos relacionados con oído, nariz y garganta. Su experiencia profesional también se extiende al ámbito privado, con práctica clínica y quirúrgica en instituciones de Matamoros, Tamaulipas. Paralelamente, ha desarrollado una destacada labor docente en la Universidad Autónoma de Tamaulipas y en el Instituto de Ciencias y Estudios Superiores de Tamaulipas, formando estudiantes de medicina en el área de otorrinolaringología. Posee certificación vigente del Consejo Mexicano de Otorrinolaringología y formación complementaria en rinología, senos paranasales, cirugía facial y cirugía nasal. Su trayectoria integra atención médica, docencia, actualización científica y compromiso con una práctica profesional ética, especializada y centrada en el bienestar del paciente.



Luis Alberto Limón Montelongo



CORREO ELECTRÓNICO

drlimon2106@outlook.com



ORCID

<https://orcid.org/0009-0002-8409-0324>

Biografía del autor

Luis Alberto Limón Montelongo es Doctor en Administración de la Salud, Maestro en Administración y Gerencia de Instituciones de Salud, especialista en Ortodoncia y Ortopedia Dentomaxilofacial, Cirujano Dentista y Contador Público. Su formación multidisciplinaria integra la práctica clínica, la administración sanitaria y la gestión institucional. Cuenta con más de catorce años de trayectoria en el Instituto Mexicano del Seguro Social, donde ha desempeñado funciones en Recursos Humanos, Dirección Médica y atención estomatológica. Desde 2022 ejerce como estomatólogo en Nuevo Laredo, Tamaulipas. Paralelamente, ha desarrollado liderazgo en programas de promoción y prevención de la salud bucal, participando en organizaciones odontológicas de alcance local, estatal, nacional e internacional. También ha asumido responsabilidades de coordinación y representación dentro del Sindicato Nacional de Trabajadores del Seguro Social. Su trayectoria se orienta a la calidad de la atención, la prevención, la mejora continua, el liderazgo institucional, la seguridad del paciente y el fortalecimiento de los servicios de salud.



Ivette Amalia Talavera Cortez



CORREO ELECTRÓNICO

ivettetctz@gmail.com



ORCID

<https://orcid.org/0009-0008-7846-4012>

Biografía de la autora

Ivette Amalia Talavera Cortez es profesional de la Contaduría Pública y Finanzas con trayectoria en los ámbitos administrativo, educativo y empresarial. Su formación académica integra una Licenciatura en Contaduría Pública y Finanzas, una Maestría en Administración de Relaciones Industriales, una Especialidad en Recursos Humanos y estudios de Doctorado en Educación. Ha desarrollado gran parte de su experiencia en el Instituto Tamaulipeco de Capacitación para el Empleo, donde participa desde 2011, complementando esta labor con docencia universitaria en instituciones privadas. Cuenta con amplia experiencia en el área económico-administrativa y en la formación de profesionales, así como en actividades de gestión, vinculación institucional y asesoramiento de tesis. De manera paralela, ejerce la Contaduría Pública en el ámbito privado, integrando conocimientos financieros, administrativos y organizacionales. Su trayectoria refleja un compromiso permanente con la educación, la administración y la investigación, entendidas como herramientas para innovar, fortalecer organizaciones y contribuir al desarrollo profesional y social.

Investigar es transformar la realidad con conocimiento y evidencia.



Publicado por
PUERTO MADERO
EDITORIAL
Buenos Aires, Argentina

ISBN 978-631-6960-02-3



9 786316 960023