





INTELIGENCIA ARTIFICIAL

para diseñar proyectos de

INVESTIGACIÓN


David Israel Báez Herrera, Galo Fernando Almeida Casanova,
Génesis Gissell Cabrera Salazar, Julio Alfredo Castillo Guillin &
Ángel Patricio Herrera Carrión




CIDPROS
EDITORIAL

Inteligencia artificial para diseñar proyectos de investigación

David Israel Báez Herrera, Galo Fernando Almeida
Casanova, Génesis Gissell Cabrera Salazar, Julio
Alfredo Castillo Guillin & Ángel Patricio Herrera
Carrión





Datos bibliográficos

ISBN	978-9907-9574-7-1
Título del libro	Inteligencia artificial para diseñar proyectos de investigación
Autores	David Israel Báez Herrera Galo Fernando Almeida Casanova Génesis Gissell Cabrera Salazar Julio Alfredo Castillo Guillín Ángel Patricio Herrera Carrión
Editorial	CIDPROS EDITORIAL
Materia	001.4 - Investigación
Público objetivo	Profesional / académico
Año	2026
Número de edición	1
Tamaño	2.57Mb
Soporte	Libro digital descargable
Formato	PDF (.pdf)
Idioma	Español
DOI	https://doi.org/10.67166/saw3wf10

Hecho en Ecuador / Made in Ecuador

MSc. David Israel Báez Herrera

Investigador Independiente
dbmasternet@gmail.com
<https://orcid.org/0009-0009-2487-7214>
Quito, Pichincha, Ecuador

Semblanza

David Israel Báez Herrera es un investigador y profesional ecuatoriano residente en Quito, especializado en tecnologías de la información, transformación digital, gestión de proyectos e innovación educativa. Cuenta con un Bachelor of Arts (BA) en Redes y Sistemas Operativos, una maestría en Telecomunicaciones y una maestría en Innovación Educativa.



Actualmente cursa un Doctorado en Dirección de Proyectos, en el que desarrolla una investigación orientada al fortalecimiento de los procesos de evaluación interna y acreditación de las instituciones de educación superior mediante un modelo apoyado en una plataforma digital para la gestión, validación y análisis de evidencias. Posee más de diez certificaciones internacionales y acreditaciones de formación especializada en tecnologías, metodologías y estándares promovidos por organizaciones reconocidas como Cisco, Amazon Web Services (AWS), Red Hat, WatchGuard, Microsoft y Hewlett Packard (HP), además de formación en gestión de proyectos bajo el enfoque PMP y en sistemas de gestión basados en normas ISO.

Su preparación comprende áreas como redes, ciberseguridad, telecomunicaciones, computación en la nube, desarrollo de software, bases de datos, infraestructura tecnológica, sistemas operativos y dirección de proyectos. También cuenta con formación y certificaciones relacionadas con los sistemas de gestión de la calidad ISO 9001 y de seguridad de la información ISO/IEC 27001, así como una certificación como Delegado de Protección de Datos, conocimientos que le han permitido intervenir en iniciativas de calidad, seguridad digital, privacidad, protección de datos personales y cumplimiento normativo. Su perfil académico se complementa con más de 150 cursos de formación continua, cuatro diplomados vinculados con programación, investigación científica e inteligencia artificial y la participación en seminarios internacionales relacionados con sus áreas de especialización.

A lo largo de más de quince años de trayectoria, ha asesorado y acompañado a organizaciones públicas y privadas de los sectores educativo, financiero, bancario, inmobiliario, de la construcción y del desarrollo tecnológico en proyectos de infraestructura, redes, telecomunicaciones, seguridad informática y transformación digital. En el ámbito de la

educación superior, ha liderado y participado en la implementación de soluciones de software a medida para la gestión académica, administrativa y contable, contribuyendo a la automatización de actividades, la integración de información, la generación de indicadores y el fortalecimiento de la toma de decisiones institucionales. Su experiencia también comprende el diseño instruccional de contenidos y entornos virtuales de aprendizaje, la administración de plataformas educativas, el desarrollo de sistemas de información, la mejora y optimización de procesos y la implementación, mantenimiento y evaluación de sistemas de gestión de la calidad. Su ejercicio profesional se caracteriza por integrar la tecnología, la educación, la investigación y la gestión organizacional desde una perspectiva interdisciplinaria orientada a la innovación, la mejora continua, la seguridad de la información y el cumplimiento normativo.

Mantiene un firme compromiso con la ética profesional, la actualización permanente y la generación de soluciones tecnológicas que contribuyan a elevar la calidad educativa, fortalecer la eficiencia de las organizaciones y producir un impacto positivo y sostenible en la sociedad.

MSc. Galo Fernando Almeida Casanova

Universidad Politécnica Estatal del Carchi
galo.almeida@upec.edu.ec
<https://orcid.org/0009-0000-3388-6264>
Tulcán, Carchi, Ecuador

Semblanza

Galo Almeida es ingeniero en finanzas por la Universidad Central del Ecuador y posee un magíster en administración de empresas con mención en innovación socioproductiva sostenible, otorgado por la Universidad Tecnológica Indoamérica (Ecuador). Actualmente avanza en su Doctorado en Administración de Empresas en la Universidad Central de Querétaro, México.



Además, cuenta con una formación complementaria orientada a la gestión y al desarrollo organizacional, entre la que destacan un Diplomado en Gerencia de Organizaciones Solidarias (Universidad Santo Tomás, Colombia), un Diplomado en Emprendimiento e Innovación (Fundación Perea, Colombia), un Diplomado en Gerencia de Microfinanzas y Gestión del Cambio (Universidad Metropolitana de Honduras) y una Certificación en Gestión Integral de Riesgos Financieros (Risk Management Consulting).

Con más de 15 años de experiencia en los sectores público y privado, su trayectoria ensemble se distingue por una clara orientación tanto académica como práctica. En el ámbito docente, ha impartido clases en la Universidad Politécnica Estatal del Carchi y en el Instituto Superior Tecnológico de Técnicas Empresariales y del Conocimiento, abarcando áreas contables y administrativas.

En su labor profesional, se ha desempeñado como consultor en la Administración Integral de Riesgos dentro del sector financiero de la Economía Popular y Solidaria. También fue Experto en Riesgo Financiero en el Instituto Ecuatoriano de Seguridad Social y Subgerente Administrativo Financiero en la Cooperativa de Ahorro y Crédito Pablo Muñoz Vega.

Su experiencia incluye funciones como Director Nacional de Investigación y Capacitación (en funciones) y Especialista de Investigación y Capacitación en la Superintendencia de Economía Popular y Solidaria. En el ámbito de la banca pública, ha trabajado como Analista de Riesgo de Crédito y Control Metodológico, así como Oficial de Crédito en el Banco Nacional de Fomento y BanEcuador. Además, formó parte del Banco del Pacífico, desempeñando roles como cajero, supervisor de cajas y asesor de atención al cliente.

Su perfil se caracteriza por una sólida formación académica y una amplia experiencia en gestión financiera, docencia, investigación, capacitación y administración integral de riesgos, con un énfasis especial en el fortalecimiento institucional y el desarrollo del sector financiero popular y solidario.

MSc. Génesis Gissell Cabrera Salazar

Investigador Independiente
gcabrerass@unemi.edu.ec
<https://orcid.org/0009-0004-7432-7396>
Balzar, Guayas, Ecuador

Semblanza

Génesis Gissell Cabrera Salazar, es profesional ecuatoriana, nació el 12 de abril de 1997, es profesional en Turismo e Idiomas y Máster en Pedagogía de los Idiomas por la Universidad Casa Grande, actualmente es docente de Inglés y Robótica e Inteligencia Artificial. Su trayectoria profesional ha pasado por diferentes áreas que han contribuido a definir su actual vocación por la educación. Su interés por aprender idiomas la llevó a continuar preparándose mediante estudios de **TESOL (Teaching English to Speakers of Other Languages)** y **TEFL (Teaching English as a Foreign Language)** en una institución educativa de Inglaterra e involucrarse en proyectos de investigaciones enfocados en la tecnología. Cuenta además con certificaciones de **inglés C1, francés B1 e italiano B2**. También ha realizado estudios relacionados con aeronáutica y tripulación de cabina en la Aviación Civil, experiencias que ampliaron su formación y le permitieron desarrollar habilidades de tecnología, comunicación y adaptación a diferentes entornos. Actualmente se encuentra próxima a culminar una **Maestría en Educación**, como parte de su propósito de continuar creciendo profesionalmente como docente.



En la actualidad se desempeña como **docente de inglés y robótica**. La educación se ha convertido en una parte muy importante de su desarrollo profesional, especialmente porque disfruta trabajar con niños y adolescentes, le gusta descubrir nuevas maneras de enseñarles. Le interesa particularmente la **tecnología aplicada a la educación**, pues considera que, utilizada de manera adecuada, puede despertar la curiosidad y hacer que los estudiantes participen más activamente en su aprendizaje. Por esta razón, procura mantenerse en constante preparación, aprender sobre nuevas herramientas y buscar estrategias que pueda aplicar en sus clases. Para ella, ser docente no significa únicamente enseñar lo que sabe, sino también continuar aprendiendo para ofrecer cada día mejores oportunidades a sus estudiantes.

A lo largo de su trayectoria también ha participado en **proyectos de investigación relacionados con la tecnología y el turismo**, ha colaborado con **organizaciones medioambientales** y ha formado parte de proyectos vinculados con **inteligencia artificial**. Estas experiencias despertaron aún más su interés por la investigación, la innovación y las posibilidades que ofrece la tecnología dentro de la educación. Su experiencia en distintas áreas le ha permitido comprender que cada etapa de formación puede aportar algo valioso a la

enseñanza. Por ello, su propósito es continuar preparándose y creciendo como educadora, combinando los **idiomas, la tecnología y la innovación** para acompañar a sus estudiantes en su aprendizaje. Para Génesis, enseñar también significa aprender junto a ellos, motivarlos a descubrir aquello que son capaces de hacer y brindarles herramientas que puedan ser útiles para su futuro.

MSc. Julio Alfredo Castillo Guillin

Investigador Independiente
jacg.edu.ec@gmail.com
<https://orcid.org/0009-0007-1564-5863>
Chaguarpamba, Loja, Ecuador

Semblanza

Julio Alfredo Castillo Guillin, es un docente ecuatoriano nacido el 23 de septiembre de 1987 en Macará-Loja; desde su infancia es un apasionado por la lectura, el dibujo y la poesía. Se ha destacado como un excelente estudiante tanto en la primaria como en la secundaria, obteniendo las máximas distinciones que se otorgan en las instituciones educativas.

Cuenta con una amplia y relevante formación académica: es Magíster en Educación Básica, Licenciado en Educación Física, Entrenador de Baloncesto, Formador de formadores y actualmente se encuentra cursando la Licenciatura en Comunicación. Esta preparación refleja su vocación por la educación, el deporte y la comunicación.



Los inicios de su trayectoria se remontan al año 2014 en la ciudad de Loja, en donde ha ejercido su profesión en instituciones educativas particulares y en escuelas de entrenamiento deportivo, para luego pasar a formar parte del Ministerio de Educación en el año 2020, en el cual se desempeña como maestro, impartiendo sus conocimientos y sabiduría a los futuros ciudadanos del Ecuador. Profesional dedicado a la excelencia académica con un gran compromiso social por la comunidad en donde reside; con su aporte en formación de valores morales a la niñez y juventud, busca entregar a la patria educandos con la capacidad de transformar la sociedad y que busquen el bienestar común, la igualdad y equidad.

Dr. h. Ángel Patricio Herrera Carrión

Docente, investigador y mediador pedagógico
redinvestigativa.aphc6.0@gmail.com
<https://orcid.org/0009-0001-5501-6988>
Ecuador

Semblanza

Ángel Patricio Herrera Carrión es docente, investigador y mediador pedagógico ecuatoriano, con más de veinticinco años de trayectoria vinculada a la educación, la inclusión social, la innovación pedagógica y el acompañamiento comunitario.

Es licenciado en Ciencias de la Educación, con mención en Administración Educativa, por la Universidad Tecnológica Equinoccial, y máster universitario en Psicopedagogía por la Universidad Internacional de La Rioja. Amplía su formación en Inteligencia Artificial para la Educación en la Universidad Bolivariana del Ecuador y cuenta con más de cinco mil horas en capacitaciones de neurodidáctica, liderazgo pedagógico, metodologías activas, inclusión educativa y competencias digitales.


Entre sus principales reconocimientos se encuentra la distinción de Doctor Honoris Causa, otorgada por la Universidad Anglo Hispana Mexicana en mérito a su labor social, comunitaria y educativa. También ha obtenido certificaciones profesionales y resultados sobresalientes en evaluaciones nacionales de razonamiento y ciudadanía.

Desde 2017 se desempeña como docente del Ministerio de Educación del Ecuador. Formó parte del Proyecto de Educación Básica para Jóvenes y Adultos Todos ABC y ha impartido Ciencias Sociales, Historia, Filosofía, Educación para la Ciudadanía e Investigación en instituciones educativas de Pastaza y Napo.

Su práctica combina aprendizaje basado en proyectos, aula invertida, trabajo cooperativo e inteligencia artificial aplicada a la educación desde una perspectiva ética, humanista e inclusiva. Su compromiso social se refleja en el acompañamiento a más de 1.500 adolescentes y jóvenes, así como a más de 400 niños y sus familias.

Es fundador de Asuntos Psicopedagógicos 6.0 y autor y coautor de libros, artículos científicos y trabajos académicos sobre educación, psicopedagogía, inclusión, innovación, inteligencia artificial y tecnología educativa. Su labor busca transformar la educación mediante la investigación, el compromiso social y el uso responsable de la inteligencia artificial.





El contenido y las ideas expuestas en esta obra se encuentran protegidos por la normativa vigente en materia de propiedad intelectual y constituyen derechos exclusivos de su(s) autor(es).

Todos los derechos reservados © 2026

Sinopsis

Este libro analiza el uso de la inteligencia artificial como herramienta de apoyo para diseñar proyectos de investigación de manera más estructurada, crítica y metodológicamente coherente. La obra examina cómo estas tecnologías pueden intervenir desde la identificación y delimitación de problemas científicos hasta la formulación de preguntas, la comparación de alternativas metodológicas, el diseño de instrumentos y la evaluación de riesgos asociados con el proceso investigativo.

A lo largo de cinco capítulos se estudian aplicaciones concretas de la inteligencia artificial para buscar y organizar antecedentes, detectar vacíos de conocimiento, analizar tendencias, generar y refinar preguntas científicas, simular decisiones sobre enfoque, diseño, población, muestra, técnicas de recolección y análisis de datos, así como revisar cuestionarios, escalas, entrevistas y protocolos de observación. También se abordan problemas relacionados con sesgos, errores, viabilidad, trazabilidad y confiabilidad de las decisiones asistidas.

La obra sostiene que la inteligencia artificial puede ampliar la capacidad de exploración, comparación y revisión del investigador, pero no sustituye el juicio científico, la validación metodológica ni la comprobación de las fuentes. Su uso exige supervisión humana, criterios explícitos y una evaluación constante de la calidad de la información empleada.

Palabras clave: inteligencia artificial; proyectos de investigación; metodología de la investigación; diseño de investigación; herramientas inteligentes.

Synopsis

This book examines the use of artificial intelligence as a support tool for designing research projects in a more structured, critical, and methodologically coherent manner. It explores how these technologies can contribute from the identification and delimitation of scientific problems to the formulation of research questions, the comparison of methodological alternatives, the design of research instruments, and the assessment of risks associated with the research process.

Across five chapters, the book addresses specific applications of artificial intelligence for searching and organizing previous research, detecting knowledge gaps, analyzing trends, generating and refining scientific questions, simulating decisions related to research approach, design, population, sample, data collection techniques, and data analysis, as well as reviewing questionnaires, scales, interviews, and observation protocols. It also examines issues related to bias, errors, feasibility, traceability, and the reliability of AI-assisted decisions.

The book argues that artificial intelligence can expand researchers' capacity for exploration, comparison, and review, but it does not replace scientific judgment, methodological validation, or source verification. Its use requires human oversight, explicit criteria, and continuous evaluation of the quality of the information employed.

Keywords: artificial intelligence; research projects; research methodology; research design; intelligent tools.

Índice de Contenido

Sinopsis	13
Synopsis	14
Introducción	17
Capítulo 1. Detección inteligente de problemas relevantes de investigación	21
1.1 Identificación de necesidades y problemáticas mediante inteligencia artificial	22
1.2 Búsqueda asistida de antecedentes científicos y académicos.....	25
1.3 Detección de vacíos de conocimiento en la literatura existente.....	29
1.4 Análisis de tendencias temáticas y líneas emergentes de investigación	33
1.5 Priorización de problemas según relevancia científica y social	35
1.6 Delimitación del problema de investigación con apoyo de herramientas inteligentes 38	
1.7 Validación preliminar de la pertinencia y originalidad del problema.....	43
Capítulo 2. Formulación de preguntas científicas con inteligencia artificial.....	47
2.1 Características de una pregunta científica bien formulada.....	48
2.2 Generación de preguntas de investigación mediante modelos de inteligencia artificial 51	
2.3 Transformación de problemas de investigación en preguntas científicas	55
2.4 Delimitación de población, variables, contexto y alcance en las preguntas	58
2.5 Formulación de preguntas según enfoques cuantitativos, cualitativos y mixtos.....	61
2.6 Evaluación de claridad, precisión y viabilidad de las preguntas mediante inteligencia artificial 65	
2.7 Refinamiento iterativo de preguntas científicas mediante herramientas inteligentes	68
Capítulo 3. Simulación de decisiones metodológicas antes del estudio	72
3.1 Selección asistida del enfoque de investigación	73
3.2 Comparación de diseños de investigación mediante escenarios simulados.....	76

3.3	Simulación de alternativas para definir población y muestra	80
3.4	Evaluación previa de técnicas de recolección de datos.....	83
3.5	Simulación de procedimientos para el desarrollo del estudio	86
3.6	Comparación de métodos de análisis de datos con apoyo de inteligencia artificial .	90
3.7	Construcción y evaluación de escenarios metodológicos antes de la ejecución del proyecto	93
Capítulo 4. Diseño de instrumentos con herramientas inteligentes		97
4.1	Selección del instrumento según objetivos, variables y tipo de estudio	98
4.2	Generación asistida de ítems para cuestionarios y escalas.....	100
4.3	Diseño de guías de entrevista mediante inteligencia artificial	103
4.4	Diseño de protocolos de observación y codificación asistida por inteligencia artificial	107
4.5	Revisión de claridad, pertinencia y coherencia de los ítems mediante herramientas inteligentes	111
4.6	Simulación de respuestas para detectar problemas en los instrumentos	114
4.7	Apoyo de la inteligencia artificial en la validación y mejora de instrumentos	117
Capítulo 5. Evaluación de riesgos, sesgos y viabilidad investigativa.....		121
5.1	Identificación temprana de riesgos metodológicos mediante inteligencia artificial	122
5.2	Detección de sesgos en la formulación y delimitación del estudio.....	124
5.3	Evaluación de sesgos asociados con la selección de participantes y muestras	128
5.4	Análisis de posibles sesgos en instrumentos y procedimientos de recolección de datos	131
5.5	Evaluación de riesgos éticos y de protección de datos en investigaciones asistidas por inteligencia artificial	134
5.6	Análisis de viabilidad técnica, temporal, económica y operativa del proyecto	137
5.7	Evaluación integral de la coherencia y factibilidad del diseño de investigación antes de su ejecución.....	140

Conclusión	144
Bibliografía	148

Introducción

El diseño de un proyecto de investigación exige tomar decisiones sucesivas que condicionan la calidad del estudio: identificar un problema relevante, reconocer qué se conoce sobre él, formular preguntas científicas, seleccionar un enfoque metodológico, definir procedimientos de recolección y análisis, construir instrumentos y anticipar los riesgos que pueden afectar la validez de los resultados. Estas tareas requieren conocimiento metodológico, capacidad crítica y revisión constante de la evidencia disponible. La incorporación de herramientas de inteligencia artificial introduce nuevas posibilidades para apoyar este proceso, especialmente en actividades que implican búsqueda, organización, comparación, generación de alternativas y análisis preliminar de grandes cantidades de información.

La inteligencia artificial puede intervenir desde las primeras etapas de una investigación. Su capacidad para procesar lenguaje, clasificar información, establecer semejanzas, generar alternativas y reorganizar contenidos permite explorar problemas, ampliar estrategias de búsqueda, comparar antecedentes y formular interrogantes preliminares. También puede utilizarse para examinar diferentes configuraciones metodológicas antes de ejecutar un estudio, revisar instrumentos, simular determinados escenarios y detectar inconsistencias entre los componentes de un proyecto. Estas posibilidades amplían los recursos disponibles para el investigador, pero no convierten a los sistemas inteligentes en sustitutos del razonamiento científico ni de la evaluación metodológica.

El principal problema no consiste, por tanto, en decidir si la inteligencia artificial debe utilizarse en investigación, sino en determinar para qué tareas resulta pertinente, bajo qué condiciones puede aportar información útil y qué decisiones deben permanecer necesariamente bajo responsabilidad humana. Las respuestas producidas por sistemas generativos pueden presentar información incorrecta, asociaciones insuficientemente justificadas, referencias inexistentes o formulaciones metodológicamente inadecuadas. Asimismo, su funcionamiento depende de los datos, instrucciones y contextos que reciben. La apariencia de coherencia de una respuesta no constituye evidencia de su validez científica, lo que obliga a mantener

procedimientos de verificación, trazabilidad y revisión crítica durante todo el proceso (Gao et al., 2023).

Desde esta perspectiva, el uso de inteligencia artificial adquiere mayor sentido cuando se integra a una dinámica de interacción entre tecnología y criterio investigador. Cedeño et al. (2024) permiten situar estas herramientas como recursos de apoyo dentro de distintas actividades investigativas, mientras que Krenn et al. (2022) muestran que su incorporación al trabajo científico puede contribuir a explorar espacios de posibilidades y apoyar procesos de razonamiento. Esto significa que su utilidad no reside únicamente en producir respuestas con rapidez, sino en facilitar comparaciones, identificar alternativas y someter decisiones preliminares a nuevas preguntas. El investigador conserva la responsabilidad de definir el problema, evaluar la evidencia, justificar las elecciones metodológicas e interpretar el significado de los resultados.

Esta obra tiene como propósito analizar de manera aplicada el uso de la inteligencia artificial durante el diseño de proyectos de investigación. El interés se concentra en las etapas anteriores a la ejecución definitiva del estudio, cuando todavía es posible explorar alternativas, detectar errores y modificar decisiones sin haber comprometido datos, participantes o recursos. La propuesta parte de una concepción de la inteligencia artificial como herramienta de asistencia metodológica. En consecuencia, cada aplicación se examina considerando simultáneamente aquello que puede facilitar la tecnología, las decisiones que corresponden al investigador y los riesgos que deben controlarse.

El primer capítulo aborda la detección inteligente de problemas relevantes de investigación. Se examinan la identificación de necesidades y problemáticas, la búsqueda asistida de antecedentes científicos, la detección de vacíos de conocimiento, el análisis de tendencias temáticas, la priorización de problemas, su delimitación y la evaluación preliminar de pertinencia y originalidad. Arias y Artigas (2022) destacan que un problema científico requiere reconocer una necesidad de conocimiento suficientemente sustentada y delimitada. Bajo este criterio, la inteligencia artificial puede contribuir a organizar y comparar información, pero la existencia de una brecha investigativa necesita comprobarse mediante antecedentes verificables.

El segundo capítulo estudia la formulación de preguntas científicas mediante inteligencia artificial. Se analizan las características de una pregunta bien construida, la generación de

alternativas mediante modelos inteligentes, la transformación del problema en interrogantes científicas, la delimitación de población, variables y contexto, y las diferencias entre preguntas cuantitativas, cualitativas y mixtas. También se examinan procedimientos para evaluar y refinar iterativamente las formulaciones. El énfasis se encuentra en conservar la correspondencia entre problema, pregunta, alcance y posibilidades metodológicas, evitando que una redacción aparentemente correcta introduzca relaciones o inferencias que el estudio no puede sostener.

El tercer capítulo desarrolla la simulación de decisiones metodológicas antes de la ejecución del proyecto. La inteligencia artificial se emplea como recurso para comparar enfoques, diseños, alternativas de población y muestra, técnicas de recolección, procedimientos y métodos de análisis. La simulación permite representar escenarios condicionales y anticipar las consecuencias de determinadas elecciones, aunque no constituye una predicción exacta de lo que sucederá durante el estudio. Su utilidad se encuentra en hacer explícitos los supuestos, las restricciones y las posibles incompatibilidades antes de adoptar decisiones difíciles de modificar posteriormente.

El cuarto capítulo se concentra en el diseño de instrumentos con herramientas inteligentes. Se examinan la selección del instrumento, la generación y revisión de ítems, el diseño de guías de entrevista, la elaboración de protocolos de observación y codificación, la simulación de respuestas y el apoyo de la inteligencia artificial en los procesos de mejora. Se mantiene una distinción fundamental entre asistencia automatizada y validación científica: un sistema puede detectar problemas, proponer formulaciones y organizar información, pero la validez de un instrumento requiere evaluación especializada y evidencia empírica obtenida con participantes reales.

Finalmente, el quinto capítulo aborda la evaluación de riesgos, sesgos y viabilidad investigativa. Esta perspectiva resulta necesaria porque la incorporación de inteligencia artificial puede aumentar la capacidad de procesamiento y análisis, pero también amplificar errores presentes en los datos, reproducir sesgos, generar resultados plausibles pero incorrectos o favorecer decisiones metodológicas insuficientemente examinadas. Por ello, diseñar proyectos de investigación con inteligencia artificial exige combinar aprovechamiento tecnológico, supervisión humana, verificación de fuentes y coherencia metodológica.


El recorrido propuesto sitúa a la inteligencia artificial dentro del proceso de diseño científico sin atribuirle funciones que corresponden al investigador. Su aporte se encuentra en ampliar

las posibilidades de exploración, comparación y revisión; la responsabilidad científica continúa dependiendo de decisiones fundamentadas, evidencia verificable y procedimientos metodológicos capaces de sostener las conclusiones del estudio.

Capítulo 1.

Detección inteligente de problemas relevantes de investigación

David Israel Báez Herrera



1.1 Identificación de necesidades y problemáticas mediante inteligencia artificial

La identificación de necesidades y problemáticas constituye una fase decisiva en la construcción de un proyecto de investigación, porque determina qué situación será examinada, bajo qué condiciones y con qué nivel de pertinencia. Arias y Artigas (2022) señalan que la formulación de problemas científicos exige reconocer brechas, inconsistencias o situaciones que justifiquen una indagación sistemática. En este proceso, la inteligencia artificial puede utilizarse como apoyo para organizar información dispersa, comparar descripciones de una misma situación y detectar patrones que ayuden a precisar posibles necesidades investigativas. Su utilidad depende, sin embargo, de la calidad de la información incorporada y del criterio del investigador.

Una necesidad de investigación no surge únicamente de la existencia de un problema práctico, sino de la posibilidad de convertir una situación observable en una cuestión susceptible de análisis científico. Barradas (2023) permite situar la inteligencia artificial como recurso de apoyo dentro de procesos académicos que requieren búsqueda, organización y tratamiento de información. Aplicada a esta fase, puede ayudar a distinguir entre percepciones generales y elementos concretos que merecen mayor examen. El investigador puede introducir descripciones preliminares, documentos, antecedentes o conjuntos de observaciones para obtener agrupaciones temáticas, relaciones posibles y preguntas iniciales, sin asumir que las respuestas generadas constituyen por sí mismas evidencia científica.

El aporte de las herramientas inteligentes resulta especialmente útil cuando el investigador enfrenta grandes volúmenes de información o múltiples manifestaciones de un mismo problema. Cedeño et al. (2024) abordan el uso de inteligencia artificial en actividades vinculadas con la investigación, lo que permite considerar su función como soporte para ordenar insumos y explorar relaciones entre elementos inicialmente dispersos. Mediante procesos de clasificación semántica, comparación textual o generación de categorías preliminares, estas herramientas pueden facilitar la identificación de recurrencias. No obstante, cualquier categoría producida debe ser revisada, porque una coincidencia lingüística o temática no equivale necesariamente a una relación causal, conceptual o metodológicamente relevante.

La identificación de problemáticas requiere diferenciar síntomas, causas probables, consecuencias y condiciones contextuales. Una herramienta de inteligencia artificial puede ayudar a separar estos componentes cuando recibe información suficientemente precisa, pero no puede establecer automáticamente cuál de ellos representa el verdadero núcleo del

problema. Díaz (2024) permite comprender la inteligencia artificial como un recurso que amplía determinadas tareas cognitivas relacionadas con el análisis y la organización de información. En investigación, esa capacidad puede aprovecharse para construir mapas preliminares de relaciones entre situaciones observadas. La decisión final sobre qué elemento debe investigarse exige contrastar esas relaciones con evidencia disponible, conocimiento disciplinar y condiciones reales del contexto estudiado.

Otro uso relevante consiste en comparar necesidades expresadas por diferentes actores o fuentes. Mata et al. (2024) muestran la presencia creciente de herramientas de inteligencia artificial en actividades académicas, contexto en el cual estas pueden emplearse para procesar información heterogénea y apoyar su interpretación inicial. Si un problema es descrito mediante entrevistas exploratorias, informes institucionales, registros o documentos científicos, la inteligencia artificial puede contribuir a reconocer coincidencias y discrepancias entre esas fuentes. Esta función facilita una primera aproximación a la problemática, pero no elimina la necesidad de valorar quién produce la información, con qué propósito, bajo qué condiciones y qué limitaciones presenta cada fuente utilizada.

La interacción con modelos de inteligencia artificial también puede favorecer un proceso de interrogación progresiva. En lugar de solicitar directamente una definición del problema, resulta más útil proporcionar información contextual y pedir que se identifiquen actores involucrados, situaciones recurrentes, posibles consecuencias, variables relacionadas o aspectos que requieren comprobación. Arias y Artigas (2022) sostienen que la relevancia de un problema científico depende de una adecuada identificación de aquello que todavía necesita explicación. Bajo esta lógica, la inteligencia artificial funciona mejor como instrumento de exploración que como mecanismo de decisión. Sus respuestas pueden ampliar el campo de preguntas, pero corresponde al investigador determinar cuáles poseen fundamento y cuáles derivan de asociaciones poco justificadas.

La calidad del resultado también depende de la formulación de las instrucciones proporcionadas al sistema. Barradas (2023) permite advertir la importancia de comprender las posibilidades y límites de estas tecnologías dentro del trabajo académico. Una instrucción demasiado amplia puede producir listados genéricos de problemas, mientras que una solicitud sustentada en información contextual favorece respuestas más delimitadas. Por ejemplo, indicar población, escenario, periodo, situación observada y antecedentes disponibles permite que el sistema organice mejor los elementos del problema. Esta precisión no garantiza validez

científica, pero reduce respuestas excesivamente abstractas y facilita que el investigador examine relaciones más próximas a la realidad que pretende estudiar.

El uso de inteligencia artificial para identificar necesidades también debe evitar la sustitución del contacto con el contexto. Cedeño et al. (2024) permiten ubicar estas herramientas como recursos complementarios dentro del proceso investigativo, no como fuentes autónomas capaces de representar por completo una realidad social, educativa, sanitaria, tecnológica o institucional. Una problemática puede presentar dimensiones que no aparecen en los documentos analizados o que dependen de experiencias y condiciones difíciles de traducir en datos textuales. Por ello, la información generada mediante inteligencia artificial necesita contrastarse con observación, antecedentes científicos, registros confiables y, cuando corresponda, con la perspectiva de los sujetos relacionados con el fenómeno.

La identificación asistida puede incorporar procedimientos de comparación entre situaciones similares para evitar que el investigador confunda una dificultad local con un problema científicamente relevante. Díaz (2024) aporta elementos para comprender el potencial de la inteligencia artificial en tareas de análisis que requieren examinar múltiples posibilidades. A partir de descripciones comparables, el sistema puede señalar semejanzas, diferencias o factores recurrentes que orienten una revisión más rigurosa. Esa función adquiere valor cuando se utiliza para formular hipótesis preliminares sobre dónde se encuentra la necesidad. Sin embargo, dichas hipótesis deben mantenerse como provisionales hasta que sean contrastadas mediante antecedentes, datos empíricos y criterios metodológicos apropiados.

También es necesario examinar cómo la inteligencia artificial puede reproducir sesgos presentes en los insumos utilizados para identificar una problemática. Mata et al. (2024) permiten considerar críticamente la incorporación de estas herramientas en actividades académicas y la necesidad de mantener supervisión humana. Si la información suministrada representa únicamente una parte del fenómeno, las respuestas obtenidas tenderán a organizar y ampliar esa misma perspectiva. En consecuencia, un análisis asistido puede invisibilizar necesidades poco documentadas o sobrerrepresentar problemas que aparecen con mayor frecuencia en los textos disponibles. La identificación inteligente debe acompañarse, por tanto, de una revisión consciente de la procedencia, diversidad y suficiencia de los insumos empleados.

La utilidad de la inteligencia artificial aumenta cuando el investigador la integra en un proceso iterativo. Una primera consulta puede producir categorías amplias; una segunda puede solicitar

diferencias entre ellas; posteriormente pueden examinarse causas posibles, consecuencias, actores afectados y evidencias necesarias para verificar cada planteamiento. Barradas (2023) y Cedeño et al. (2024) permiten comprender este uso como una interacción progresiva entre capacidades tecnológicas y juicio académico. El valor no reside en aceptar una respuesta inicial, sino en utilizarla para mejorar la definición del problema. Cada iteración debería conducir a una descripción más concreta, verificable y relacionada con información que pueda ser posteriormente sometida a procedimientos de investigación.

En términos metodológicos, la identificación de necesidades mediante inteligencia artificial debe entenderse como una etapa de apoyo al razonamiento científico y no como una transferencia de responsabilidad intelectual. Arias y Artigas (2022) sitúan la relevancia del problema en la capacidad de reconocer una necesidad de conocimiento que pueda investigarse con fundamento, mientras que Díaz (2024) y Mata et al. (2024) permiten considerar las herramientas inteligentes como recursos capaces de facilitar determinadas tareas analíticas. Su empleo resulta pertinente cuando contribuye a organizar evidencias, comparar perspectivas, formular interrogantes y delimitar situaciones. La problemática definitiva, sin embargo, debe responder a criterios científicos, contextuales y metodológicos establecidos por el investigador.

1.2 Búsqueda asistida de antecedentes científicos y académicos

La búsqueda de antecedentes científicos y académicos cumple una función decisiva en la delimitación de un problema de investigación, porque permite reconocer qué aspectos han sido estudiados, cuáles enfoques predominan y qué interrogantes continúan abiertas. La inteligencia artificial puede apoyar esta fase mediante procedimientos de exploración, organización y filtrado de información que reducen el tiempo dedicado a tareas repetitivas. Ávila (2024) examina el uso de herramientas inteligentes en actividades académicas vinculadas con la gestión de información. Su incorporación resulta especialmente útil cuando el investigador necesita estructurar una búsqueda inicial, aunque la pertinencia de cada antecedente debe comprobarse mediante revisión directa de la fuente.

Una búsqueda asistida puede comenzar con la identificación de términos que representen adecuadamente el problema estudiado. La inteligencia artificial puede proponer palabras clave, expresiones equivalentes, conceptos asociados y posibles relaciones entre categorías, lo que favorece una exploración más amplia de la literatura. Esta capacidad es útil cuando el tema presenta denominaciones diferentes entre disciplinas o cuando el investigador todavía está construyendo su vocabulario especializado. Sin embargo, los términos sugeridos deben

evaluarse según su precisión conceptual y su correspondencia con el objeto de estudio, pues una expansión excesiva de las palabras de búsqueda puede introducir documentos poco relacionados con la investigación (Polo y Casique, 2025).

La construcción de estrategias de búsqueda requiere algo más que introducir palabras aisladas en una plataforma. La inteligencia artificial puede ayudar a combinar conceptos, establecer relaciones entre variables y modificar progresivamente las consultas según los resultados obtenidos. Tang et al. (2023) permiten comprender la utilidad de estas tecnologías en procesos de recuperación y tratamiento de información científica. Una búsqueda puede comenzar con formulaciones amplias y después incorporar criterios relacionados con población, contexto, metodología o periodo. Esta secuencia favorece una exploración más estructurada, siempre que las decisiones sobre inclusión y exclusión respondan al propósito del estudio y no únicamente a las sugerencias generadas automáticamente.

La recuperación de numerosos documentos no garantiza que se hayan identificado antecedentes científicamente útiles. Un estudio puede coincidir con varios términos de búsqueda y, pese a ello, abordar un problema distinto, utilizar otra población o responder a objetivos incompatibles con el proyecto que se diseña. Por esta razón, la inteligencia artificial debe emplearse como mecanismo de preselección y no como criterio definitivo de pertinencia. La revisión necesita considerar el objeto estudiado, el enfoque teórico, el diseño metodológico y la proximidad entre los resultados del antecedente y la necesidad investigativa identificada. Esta valoración crítica resulta indispensable para evitar selecciones basadas únicamente en semejanzas superficiales (Gilbert et al., 2024).

Una vez recuperada la literatura, las herramientas inteligentes pueden facilitar su organización mediante categorías preliminares. Mata et al. (2024) permiten situar esta posibilidad dentro de los usos académicos de la inteligencia artificial relacionados con el procesamiento de información. Los trabajos pueden clasificarse según variables, enfoques, poblaciones, contextos, métodos o líneas temáticas, lo que ayuda a observar cómo se distribuye el conocimiento disponible. Esta organización resulta especialmente útil cuando el número de documentos comienza a dificultar una revisión individual desestructurada. Aun así, las categorías generadas deben mantenerse abiertas a revisión, porque una clasificación automática puede simplificar diferencias conceptuales o metodológicas relevantes entre investigaciones aparentemente semejantes.

Tabla 1

Funciones de la inteligencia artificial durante la búsqueda de antecedentes científicos y académicos

Fase del proceso	Apoyo posible de la inteligencia artificial	Decisión que conserva el investigador	Riesgo que debe controlarse
Exploración inicial	Proponer términos y relaciones conceptuales	Determinar su pertinencia para el problema	Ampliación temática innecesaria
Recuperación	Identificar documentos potencialmente relacionados	Establecer criterios de inclusión	Incorporación de literatura poco pertinente
Filtrado	Ordenar resultados según criterios definidos	Decidir qué documentos serán revisados	Exclusión de antecedentes relevantes
Organización	Agrupar estudios por características comunes	Revisar la consistencia de las categorías	Simplificación de diferencias importantes
Comparación	Estructurar semejanzas y diferencias entre estudios	Interpretar el significado de los contrastes	Lecturas descontextualizadas
Verificación	Facilitar la revisión de datos bibliográficos	Confirmar cada registro en la fuente original	Uso de información bibliográfica incorrecta

Nota. Elaboración propia. La organización distingue las funciones automatizables de aquellas decisiones que requieren valoración académica.

La tabla evidencia que la intervención de la inteligencia artificial puede variar a lo largo del proceso sin desplazar la responsabilidad del investigador. En las fases iniciales predominan funciones de expansión y organización, mientras que en las etapas posteriores adquieren mayor peso la evaluación, la interpretación y la verificación. Esta distinción es importante porque evita tratar la búsqueda como una actividad completamente automatizable. Ávila (2024) permite comprender que las herramientas inteligentes pueden apoyar tareas académicas concretas, pero su utilidad depende de la forma en que se integran al procedimiento. La eficiencia tecnológica necesita articularse con decisiones explícitas sobre pertinencia, calidad y relación con el problema investigado.

Otra aplicación relevante consiste en comparar antecedentes mediante estructuras homogéneas. Un sistema puede ayudar a extraer de cada documento información relacionada con objetivos, población, variables, métodos, técnicas o principales resultados, facilitando posteriormente su

contraste. Esta organización puede revelar coincidencias entre estudios y diferencias que no resultan evidentes durante una lectura fragmentada. No obstante, la síntesis debe confrontarse con el contenido original, porque reducir una investigación a pocas categorías puede eliminar condiciones necesarias para interpretar adecuadamente sus hallazgos. La inteligencia artificial funciona mejor como apoyo para ordenar la comparación que como sustituto de la lectura analítica de los trabajos seleccionados (Polo y Casique, 2025).

La búsqueda asistida también exige controlar la trazabilidad de la información recuperada. Tang et al. (2023) permiten advertir la importancia de vincular los procesos automatizados con mecanismos que permitan comprobar de dónde procede cada dato académico. Los nombres de autores, títulos, años de publicación y demás elementos bibliográficos deben verificarse en los registros originales o en las fuentes correspondientes antes de ser incorporados al proyecto. Esta precaución resulta necesaria porque una respuesta generada puede contener información incompleta o combinar datos de manera incorrecta. La rapidez de recuperación pierde utilidad cuando los documentos seleccionados no pueden identificarse, localizarse o comprobarse de manera independiente.

El modo en que se formulan las consultas también condiciona la calidad de los resultados. Solicitudes demasiado generales tienden a producir respuestas amplias, mientras que instrucciones que delimitan tema, población, contexto, periodo o tipo de estudio permiten orientar mejor la exploración. Mata et al. (2024) sitúan el uso de inteligencia artificial dentro de actividades académicas donde la interacción con la herramienta influye en el resultado obtenido. Por ello, conviene construir consultas progresivas y revisar sus efectos antes de ampliar o restringir la búsqueda. La herramienta puede proponer nuevas rutas de exploración, pero cualquier modificación de los criterios debe responder a una decisión metodológicamente justificada.

Un procedimiento consistente combina las capacidades de recuperación automatizada con la revisión crítica de la literatura. Gilbert et al. (2024) permiten comprender que las herramientas inteligentes pueden facilitar determinadas operaciones relacionadas con la localización y el procesamiento de información científica, pero la valoración académica requiere examinar directamente los estudios. En términos operativos, resulta conveniente diferenciar entre localizar documentos, determinar su pertinencia, organizarlos y analizar sus aportes. Estas tareas están relacionadas, aunque no poseen el mismo nivel de automatización posible.

Mantener esta distinción reduce el riesgo de convertir una lista de resultados en un conjunto de antecedentes sin comprobar su relación efectiva con la investigación.

La búsqueda asistida de antecedentes adquiere valor cuando permite transformar una exploración dispersa en un proceso organizado, verificable y orientado por criterios científicos. La inteligencia artificial puede ampliar términos, estructurar consultas, clasificar documentos y facilitar comparaciones preliminares; sin embargo, la selección final requiere interpretar la relación de cada estudio con el problema investigado. El empleo adecuado de estas herramientas depende de una interacción continua entre capacidad tecnológica y juicio académico. Polo y Casique (2025) permiten situar esta integración dentro de prácticas investigativas que aprovechan la automatización sin transferir a la herramienta decisiones que corresponden al investigador, especialmente aquellas vinculadas con pertinencia, calidad y significado de los antecedentes.

1.3 Detección de vacíos de conocimiento en la literatura existente

La detección de vacíos de conocimiento exige identificar aquello que la literatura disponible todavía no explica con suficiente precisión, profundidad o alcance. Arias y Artigas (2022) sitúan esta tarea como parte sustantiva del planteamiento de problemas científicos relevantes, pues una brecha no equivale simplemente a la ausencia de publicaciones sobre un tema. También puede expresarse en resultados contradictorios, poblaciones poco estudiadas, contextos insuficientemente examinados, limitaciones metodológicas persistentes o relaciones conceptuales todavía inciertas. La inteligencia artificial puede apoyar esta lectura comparativa al organizar grandes volúmenes de antecedentes y señalar patrones de concentración, omisión o divergencia que posteriormente requieren valoración académica.

Una primera utilidad de las herramientas inteligentes consiste en agrupar estudios según sus principales características y facilitar la comparación entre ellos. Al ordenar antecedentes por objetivos, variables, enfoques, población o contexto, resulta posible observar con mayor claridad qué áreas poseen abundante evidencia y cuáles muestran menor desarrollo. Polo y Casique (2025) permiten vincular esta capacidad con el uso de inteligencia artificial en procesos académicos de búsqueda y organización de información. La identificación de una zona poco representada puede orientar nuevas preguntas, aunque su sola escasez documental no demuestra automáticamente la existencia de un vacío científicamente relevante ni justifica por sí misma una investigación.

Los vacíos también pueden aparecer cuando diferentes estudios examinan un mismo fenómeno desde aproximaciones que no permiten responder determinadas preguntas. En tales casos, la inteligencia artificial puede ayudar a clasificar los diseños utilizados y mostrar qué perspectivas metodológicas predominan. Si la literatura se concentra, por ejemplo, en aproximaciones descriptivas, el investigador puede explorar si permanecen pendientes relaciones, procesos o explicaciones que requieran otros diseños. Ávila (2024) permite considerar el potencial de las herramientas inteligentes para organizar información académica y apoyar su examen. La interpretación de esa distribución metodológica, sin embargo, depende de conocer las exigencias del problema y las posibilidades reales de producir nueva evidencia.

Otra forma de detectar brechas consiste en identificar poblaciones o contextos escasamente representados en la literatura revisada. La inteligencia artificial puede extraer referencias a grupos participantes, escenarios institucionales, territorios o condiciones específicas y posteriormente compararlos. Este procedimiento permite advertir concentraciones excesivas en determinados contextos y ausencia relativa de evidencia en otros. Sin embargo, una diferencia contextual solo constituye una oportunidad investigativa cuando existen razones conceptuales o empíricas para considerar que el fenómeno podría comportarse de manera distinta. La tecnología facilita la localización de esas diferencias, pero no establece su relevancia científica de manera automática (Barradas, 2023).

Los resultados contradictorios representan otro punto de entrada para reconocer problemas aún no resueltos. Díaz (2024) permite comprender la inteligencia artificial como recurso para examinar relaciones y organizar información procedente de múltiples fuentes. Una herramienta puede ayudar a reunir estudios que analizan variables semejantes y presentar diferencias entre sus resultados, condiciones o procedimientos. A partir de ese contraste, el investigador puede preguntarse si las discrepancias responden a características de la muestra, variaciones conceptuales, instrumentos distintos o diferencias contextuales. El vacío no se encuentra entonces en la inexistencia de conocimiento, sino en la falta de una explicación suficientemente consistente acerca de por qué los hallazgos divergen.


También pueden reconocerse vacíos cuando un concepto aparece reiteradamente en la literatura, pero su definición o forma de medición varía entre investigaciones. En esta situación, las herramientas inteligentes pueden localizar términos recurrentes, comparar definiciones operativas y organizar los instrumentos utilizados. El propósito no consiste en decidir cuál formulación es correcta a partir de una respuesta automática, sino en hacer visibles diferencias

que requieren análisis conceptual. Arias y Artigas (2022) permiten relacionar esta revisión con la necesidad de formular problemas científicamente delimitados. Una brecha conceptual resulta relevante cuando esas diferencias dificultan la comparación entre estudios, generan ambigüedad o limitan la acumulación coherente de conocimiento.

La dimensión temporal ofrece otra vía para reconocer áreas insuficientemente estudiadas. Una revisión organizada cronológicamente puede mostrar si determinadas preguntas han perdido atención, si ciertos enfoques se concentran en periodos específicos o si cambios recientes todavía no cuentan con suficiente evidencia. Ávila (2024) permite situar la inteligencia artificial como apoyo para estructurar grandes conjuntos de información académica y detectar patrones dentro de ellos. Sin embargo, identificar pocos trabajos recientes no basta para afirmar que existe un vacío. El investigador debe valorar si el fenómeno ha experimentado transformaciones relevantes, si las condiciones actuales difieren de las previamente estudiadas y si una nueva investigación aportaría conocimiento adicional.

Figura 1

Detección de vacíos de conocimiento: Rol de la IA



Nota. La figura contrasta dos formas de identificar vacíos de conocimiento y muestra el paso hacia un análisis más estructurado mediante el apoyo de inteligencia artificial.

La inteligencia artificial puede contribuir, además, a diferenciar vacíos explícitos e implícitos. Los primeros aparecen cuando los propios estudios señalan preguntas pendientes, limitaciones o líneas de investigación futura. Los segundos requieren comparar diversos trabajos para detectar aspectos que no han sido planteados directamente. Polo y Casique (2025) permiten

comprender la utilidad de estas herramientas para relacionar información dispersa y facilitar una lectura transversal de la literatura. No obstante, las recomendaciones formuladas por autores previos no deben asumirse automáticamente como agendas obligatorias. Cada propuesta necesita evaluarse según su vigencia, pertinencia respecto del contexto y capacidad de producir un aporte científicamente justificable.

Un riesgo importante consiste en confundir la ausencia aparente de resultados con una ausencia real de conocimiento. Las herramientas de inteligencia artificial dependen del conjunto de documentos consultados y de la forma en que se formula la búsqueda. Barradas (2023) permite advertir que el empleo académico de estas tecnologías requiere reconocer sus límites y mantener supervisión crítica. Si la consulta utiliza términos demasiado restrictivos, excluye idiomas, omite bases relevantes o interpreta de manera estrecha un concepto, puede producir la impresión de que determinado tema no ha sido investigado. Por ello, todo vacío identificado debe contrastarse mediante búsquedas adicionales y variaciones razonadas de los términos empleados.

La utilidad de la inteligencia artificial aumenta cuando la detección de brechas se desarrolla de manera iterativa. Una primera revisión puede revelar concentraciones temáticas; una segunda puede explorar métodos, poblaciones y contextos; y consultas posteriores pueden examinar contradicciones o limitaciones recurrentes. Díaz (2024) permite relacionar esta dinámica con el uso de herramientas inteligentes como apoyo al análisis progresivo de información. Cada ciclo debería reducir la amplitud inicial del problema y mejorar la precisión de la posible brecha. La finalidad no es producir automáticamente una frase de “vacío de investigación”, sino construir una justificación basada en comparaciones verificables entre los antecedentes disponibles.

La detección de vacíos constituye, por tanto, una operación interpretativa sustentada en evidencia y no una simple búsqueda de temas poco mencionados. La inteligencia artificial puede facilitar la clasificación, comparación y reconocimiento de patrones dentro de la literatura, pero la relevancia de una brecha depende de su relación con un problema científico concreto. Arias y Artigas (2022) permiten vincular esta exigencia con la formulación de problemas relevantes, mientras que las herramientas inteligentes amplían la capacidad para examinar antecedentes de manera estructurada. Un vacío adquiere valor investigativo cuando puede justificarse conceptualmente, comprobarse en la literatura disponible y transformarse posteriormente en una pregunta susceptible de estudio.

1.4 Análisis de tendencias temáticas y líneas emergentes de investigación

El análisis de tendencias temáticas permite reconocer cómo se concentra, desplaza o diversifica la producción científica dentro de un campo determinado. Ávila (2024) permite situar la inteligencia artificial como apoyo para examinar grandes volúmenes de información académica y organizar patrones que serían difíciles de identificar mediante una revisión exclusivamente manual. A partir de conjuntos de publicaciones, estas herramientas pueden agrupar temas recurrentes, detectar cambios en la frecuencia de ciertos conceptos y mostrar relaciones entre áreas de interés. Su utilidad radica en facilitar una lectura estructurada de la evolución temática, aunque la interpretación de esos cambios sigue dependiendo del contexto disciplinar y del criterio investigador.

Una tendencia temática no debe confundirse con la simple repetición de palabras en los documentos revisados. La frecuencia puede indicar concentración de interés, pero no explica por sí sola la importancia científica de un tema ni su evolución conceptual. Polo y Casique (2025) permiten relacionar el uso de inteligencia artificial con procesos de organización y análisis de literatura académica. Mediante clasificación semántica, agrupamiento de contenidos o comparación de términos asociados, es posible identificar núcleos temáticos que comparten problemas, enfoques o aplicaciones. La interpretación requiere examinar después qué significado adquieren esas agrupaciones y si representan verdaderas líneas de investigación o coincidencias terminológicas circunstanciales.

El componente temporal resulta fundamental para diferenciar temas consolidados de líneas emergentes. Una herramienta inteligente puede ordenar publicaciones por periodos y detectar conceptos cuya presencia aumenta, disminuye o cambia de relación con otros temas. Hartung (2025) permite considerar la inteligencia artificial dentro de procesos de exploración científica capaces de apoyar la identificación de nuevas direcciones de investigación. Este tipo de análisis puede revelar desplazamientos en las preguntas formuladas o en los enfoques utilizados. Sin embargo, un incremento reciente de publicaciones no demuestra necesariamente la consolidación de una nueva línea, pues también puede responder a fenómenos coyunturales o intereses transitorios.

Las líneas emergentes suelen manifestarse mediante combinaciones conceptuales que todavía no presentan una producción extensa, pero comienzan a aparecer con mayor consistencia en distintos trabajos. Fushimi et al. (2025) aportan una perspectiva útil para comprender cómo los sistemas inteligentes pueden intervenir en procesos de exploración y generación de

conocimiento. Aplicada al análisis bibliográfico, esta capacidad permite reconocer asociaciones poco frecuentes entre conceptos, métodos o campos disciplinares. El investigador puede utilizar esas señales para examinar posibles áreas de desarrollo. No obstante, la novedad aparente debe contrastarse con antecedentes suficientes para evitar considerar emergente aquello que simplemente no fue recuperado adecuadamente durante la búsqueda inicial.

El análisis de tendencias también puede centrarse en la transformación de los métodos utilizados dentro de un área. Hua et al. (2023) permiten vincular la inteligencia artificial con procesos científicos en los que se exploran alternativas y relaciones complejas entre información disponible. Al clasificar estudios según métodos, diseños o técnicas, puede observarse si determinadas aproximaciones adquieren mayor presencia o comienzan a combinarse con otras. Esta evolución metodológica puede señalar cambios en la forma de investigar un problema, pero no implica necesariamente que los procedimientos más recientes sean superiores. Su importancia debe valorarse según la pregunta científica, la evidencia obtenida y las limitaciones de cada enfoque.

Otra dimensión relevante corresponde a la convergencia entre áreas anteriormente separadas. Cuando conceptos provenientes de distintos campos aparecen progresivamente relacionados, puede estar configurándose una línea interdisciplinaria. La inteligencia artificial puede facilitar la detección de estas conexiones mediante análisis de similitud temática y reconocimiento de asociaciones entre categorías. Polo y Casique (2025) permiten comprender este potencial dentro de la gestión de información científica. Aun así, la presencia conjunta de términos no basta para demostrar integración disciplinaria. Es necesario revisar cómo se articulan los conceptos, qué problemas intentan resolver y si existe una verdadera combinación de enfoques o únicamente referencias cruzadas entre áreas.

La identificación de tendencias exige también distinguir entre volumen de producción y relevancia científica. Un tema ampliamente publicado puede encontrarse en una fase de consolidación, mientras que otro con menor cantidad de estudios puede contener preguntas especialmente novedosas. Hartung (2025) permite situar la inteligencia artificial como herramienta para explorar posibilidades científicas más allá de patrones evidentes. Por ello, el análisis no debería limitarse a ordenar temas según su frecuencia. Conviene examinar simultáneamente crecimiento, diversidad metodológica, conexiones conceptuales y problemas pendientes. Esta combinación permite construir una interpretación más precisa sobre qué áreas están consolidadas y cuáles podrían representar direcciones de investigación en desarrollo.

Las herramientas inteligentes pueden apoyar la elaboración de mapas conceptuales preliminares que representen relaciones entre temas, subtemas y áreas emergentes. Fushimi et al. (2025) permiten considerar estas capacidades dentro de procesos donde la inteligencia artificial contribuye a explorar estructuras complejas de conocimiento. Al visualizar proximidades o conexiones, el investigador puede detectar grupos temáticos dominantes y zonas periféricas que merecen un análisis adicional. Estas representaciones deben utilizarse como instrumentos de orientación y no como conclusiones definitivas. La proximidad calculada entre dos conceptos depende de los datos analizados y de los criterios empleados para establecer similitudes entre documentos.

El reconocimiento de una línea emergente requiere una comprobación progresiva. Una señal detectada mediante inteligencia artificial puede servir para formular nuevas búsquedas, ampliar términos, revisar trabajos recientes y determinar si existen antecedentes suficientes para sostener su crecimiento. Hua et al. (2023) permiten relacionar este procedimiento con el uso de sistemas inteligentes para explorar espacios de posibilidades dentro de la actividad científica. El proceso es iterativo: una tendencia preliminar conduce a nuevas consultas y estas, a su vez, permiten confirmar, matizar o descartar la interpretación inicial. Esta dinámica reduce el riesgo de definir líneas de investigación a partir de patrones aislados o insuficientemente contextualizados.

El análisis de tendencias y líneas emergentes adquiere valor cuando contribuye a comprender la estructura dinámica de un campo y no únicamente a enumerar los temas más frecuentes. La inteligencia artificial facilita la identificación de recurrencias, desplazamientos temporales, convergencias y asociaciones que pueden orientar decisiones posteriores sobre el problema de investigación. Ávila (2024) permite situar estas funciones dentro del trabajo académico asistido por herramientas inteligentes. El resultado más útil es una representación razonada de cómo evoluciona el conocimiento disponible, capaz de distinguir entre áreas consolidadas, transformaciones recientes y posibles espacios emergentes que requieren una revisión científica más profunda antes de convertirse en problemas investigables.

1.5 Priorización de problemas según relevancia científica y social

La priorización de problemas de investigación exige valorar cuáles situaciones justifican con mayor fuerza la inversión de tiempo, recursos y esfuerzo científico. Arias y Artigas (2022) vinculan la relevancia de un problema con la identificación de brechas que posean interés académico y capacidad para orientar nuevas indagaciones. La inteligencia artificial puede

apoyar esta etapa mediante la organización comparativa de varios problemas candidatos y la identificación de atributos asociados con su pertinencia. Su función consiste en facilitar el análisis de criterios previamente definidos, no en decidir de manera autónoma qué problema merece investigarse, porque esa elección depende de argumentos científicos, sociales y contextuales que requieren juicio especializado.

La relevancia científica se relaciona con la capacidad de un problema para contribuir a la comprensión de un fenómeno, esclarecer inconsistencias o ampliar conocimiento disponible. Bunge (2017) permite situar el problema científico dentro de una estructura racional en la que las preguntas deben responder a cuestiones susceptibles de investigación sistemática. Desde esta perspectiva, la inteligencia artificial puede ayudar a comparar problemas según la claridad de su formulación, la existencia de antecedentes, la presencia de contradicciones y la posibilidad de producir conocimiento adicional. Sin embargo, una alta novedad aparente no garantiza relevancia científica si el problema carece de fundamento teórico o posibilidades reales de comprobación.

La dimensión social introduce criterios distintos, aunque relacionados con la importancia científica. Un problema puede adquirir prioridad cuando afecta a una población determinada, se vincula con necesidades persistentes o permite comprender condiciones que tienen consecuencias relevantes para un contexto específico. Callirgos et al. (2022) aportan elementos metodológicos útiles para valorar la pertinencia de los problemas dentro de procesos de investigación. La inteligencia artificial puede colaborar en la sistematización de documentos, registros y descripciones que permitan comparar la presencia de determinadas necesidades. Esta información debe interpretarse con cautela, porque la frecuencia con que una situación aparece documentada no equivale necesariamente a su gravedad o importancia social.

La priorización requiere evitar que los criterios científicos y sociales se examinen de forma aislada. Un problema puede ser conceptualmente novedoso, pero poseer escasa pertinencia para el contexto en el que se pretende investigar; otro puede mostrar fuerte importancia social, aunque todavía necesite una formulación científica más precisa. Castelo (2025) permite considerar la necesidad de relacionar la pertinencia investigativa con condiciones de viabilidad y utilidad académica. En este punto, la inteligencia artificial puede apoyar la comparación de alternativas mediante criterios múltiples, siempre que estos sean definidos antes del análisis y que su ponderación responda a razones explícitas, no a una clasificación automática generada por el sistema.

Tabla 2

Matriz analítica para priorizar problemas de investigación con apoyo de inteligencia artificial

Criterio	Pregunta orientadora	Apoyo posible de la inteligencia artificial	Decisión del investigador
Relevancia científica	¿El problema responde a una brecha, contradicción o necesidad de explicación?	Comparar antecedentes y patrones de conocimiento	Determinar el aporte científico esperado
Relevancia social	¿La situación tiene consecuencias identificables en una población o contexto?	Organizar registros y evidencias disponibles	Valorar la importancia contextual
Delimitación	¿El problema puede formularse con precisión?	Detectar elementos, actores y relaciones recurrentes	Establecer límites conceptuales y empíricos
Viabilidad	¿Puede estudiarse con recursos y condiciones disponibles?	Comparar escenarios y restricciones	Decidir si el estudio es realizable
Originalidad	¿La propuesta introduce una aproximación suficientemente diferenciada?	Contrastar similitudes con antecedentes	Justificar la novedad real
Coherencia	¿Existe correspondencia entre problema, propósito y posibilidades metodológicas?	Revisar consistencia entre componentes	Confirmar la lógica del proyecto

Nota. Elaboración propia. La matriz organiza criterios para comparar alternativas sin convertir la priorización en una decisión automática.

La matriz permite observar que priorizar no consiste en asignar una puntuación aislada a cada problema, sino en examinar la relación entre varias condiciones. Un problema socialmente relevante puede perder prioridad si no es posible delimitarlo o investigarlo con los recursos disponibles, mientras que uno científicamente novedoso puede resultar insuficiente si carece de una justificación contextual clara. Barradas (2023) permite situar la inteligencia artificial como apoyo para organizar información y comparar alternativas académicas. El valor de esta asistencia reside en hacer visibles diferencias entre problemas candidatos, facilitando una decisión argumentada que conserve bajo responsabilidad del investigador la interpretación final.

La ponderación de criterios constituye una fase especialmente sensible. No todos los proyectos deben conceder el mismo peso a relevancia social, novedad, viabilidad u originalidad, porque las prioridades dependen del campo disciplinar y del propósito de la investigación. Arias y Artigas (2022) permiten sostener que la identificación de un problema relevante exige considerar su aporte y su relación con una brecha comprobable. La inteligencia artificial puede

simular diferentes escenarios de ponderación y mostrar cómo cambia el orden de prioridad cuando se modifica un criterio. Esta posibilidad resulta útil para explorar decisiones, pero la asignación de pesos debe justificarse conceptualmente y no adoptarse por conveniencia algorítmica.

También es necesario controlar los sesgos derivados de la información utilizada para priorizar. Si la herramienta recibe antecedentes incompletos, registros concentrados en ciertos grupos o descripciones sesgadas del contexto, la comparación resultante reproducirá esas limitaciones. Barradas (2023) permite advertir que el uso académico de inteligencia artificial requiere supervisión crítica y comprensión de sus restricciones. Por esta razón, los criterios deben aplicarse sobre información suficientemente diversa y verificable. La prioridad de un problema no debería establecerse únicamente porque aparezca con mayor frecuencia en los datos disponibles, sino porque exista una justificación razonada sobre su importancia y sobre la necesidad de estudiarlo científicamente.

La priorización también puede beneficiarse de procesos iterativos. Una primera comparación permite descartar problemas poco delimitados; una segunda puede profundizar en relevancia, originalidad o viabilidad; posteriormente, los problemas mejor posicionados pueden someterse a una revisión más detallada. Castelo (2025) permite relacionar este procedimiento con la necesidad de valorar condiciones concretas antes de comprometer recursos en una investigación. La inteligencia artificial puede facilitar cada ronda mediante síntesis comparativas y reorganización de criterios. Este uso progresivo evita tratar la priorización como una decisión instantánea y permite ajustar el problema conforme aumenta la calidad de la información disponible.

Priorizar problemas según su relevancia científica y social implica construir una decisión justificable, no identificar automáticamente el tema con mayor cantidad de evidencia o mayor visibilidad. Bunge (2017) permite recordar que un problema científico debe integrarse dentro de una lógica de conocimiento susceptible de examen, mientras que Callirgos et al. (2022) refuerzan la importancia de mantener coherencia entre el problema y el proceso investigativo. La inteligencia artificial aporta valor cuando permite comparar alternativas, organizar criterios y explorar consecuencias de distintas elecciones. La prioridad final debe surgir de la convergencia entre pertinencia científica, importancia contextual, delimitación y posibilidad real de desarrollar el estudio.

1.6 Delimitación del problema de investigación con apoyo de herramientas inteligentes

La delimitación del problema de investigación consiste en reducir progresivamente una situación amplia hasta convertirla en un objeto susceptible de análisis sistemático. Arias y Artigas (2022) destacan que un problema científico requiere precisión respecto de aquello que se pretende conocer, así como una relación clara con una brecha identificable. Las herramientas de inteligencia artificial pueden apoyar esta tarea mediante la organización de información contextual, conceptual y empírica, ayudando a distinguir elementos centrales de aspectos secundarios. Su utilidad aumenta cuando el investigador parte de una problemática previamente fundamentada y utiliza la tecnología para examinar alternativas de delimitación, en lugar de solicitar formulaciones completamente desvinculadas de antecedentes verificables.

Delimitar implica establecer fronteras conceptuales que indiquen qué componentes forman parte del problema y cuáles quedan fuera. Bunge (2017) permite comprender esta necesidad desde la lógica de la investigación científica, donde una cuestión debe ser suficientemente definida para admitir tratamiento racional y contrastación. La inteligencia artificial puede colaborar identificando conceptos recurrentes, diferenciando categorías próximas y proponiendo relaciones entre variables o dimensiones. Sin embargo, estas sugerencias requieren revisión disciplinar, porque dos términos semánticamente relacionados no necesariamente poseen el mismo significado científico. La delimitación conceptual debe conservar coherencia con el marco teórico y con el modo en que el fenómeno será posteriormente observado o analizado.

La dimensión poblacional constituye otro componente relevante de la delimitación. Un problema amplio suele referirse inicialmente a grupos heterogéneos, por lo que resulta necesario determinar qué población presenta las características relacionadas con la situación investigada. Cedeño et al. (2024) permiten situar la inteligencia artificial como apoyo en actividades investigativas donde deben organizarse múltiples criterios de análisis. A partir de información disponible, una herramienta puede ayudar a comparar posibles grupos, identificar atributos diferenciadores y advertir niveles excesivos de amplitud. La selección definitiva debe responder a razones científicas y metodológicas, evitando restringir la población únicamente porque determinada opción resulte más sencilla de describir o procesar.

La delimitación espacial define el contexto en el cual el problema adquiere significado. Una misma situación puede manifestarse de manera diferente entre instituciones, territorios, organizaciones o entornos sociales, por lo que precisar el escenario evita generalizaciones que excedan la evidencia disponible. Díaz (2024) permite comprender el potencial de las

herramientas inteligentes para organizar información contextual y explorar relaciones entre distintos componentes de un problema. Estas capacidades pueden utilizarse para comparar escenarios posibles y reconocer cuáles concentran condiciones pertinentes para la investigación. No obstante, la elección del espacio debe justificarse mediante características concretas del fenómeno y no mediante una recomendación automatizada carente de conocimiento suficiente del contexto.

El componente temporal también contribuye a establecer los límites del objeto investigado. Un problema puede corresponder a una situación reciente, a un proceso acumulativo o a una condición que cambia según determinados periodos. Las herramientas inteligentes pueden organizar antecedentes cronológicamente y señalar variaciones en conceptos, resultados o condiciones, facilitando la identificación de un intervalo temporal razonable. Krenn et al. (2022) muestran el potencial de sistemas inteligentes para explorar espacios de posibilidades y generar alternativas dentro de procesos científicos. Esta capacidad puede apoyar la comparación entre diferentes delimitaciones temporales, aunque la selección debe responder a la dinámica real del fenómeno y a la información necesaria para estudiarlo.

La delimitación exige, además, precisar qué relación o aspecto del fenómeno constituye el núcleo del problema. Una problemática amplia puede contener múltiples causas, consecuencias, actores y variables que no pueden estudiarse simultáneamente con igual profundidad. Arias y Artigas (2022) señalan la importancia de identificar con claridad la brecha que da origen a la investigación. La inteligencia artificial puede contribuir mediante ejercicios de descomposición, separando elementos del problema y mostrando posibles conexiones entre ellos. Esta operación resulta útil para reducir complejidad, pero el investigador debe decidir cuáles relaciones poseen mayor sustento y cuáles constituyen únicamente hipótesis preliminares que todavía requieren evidencia.

La interacción con herramientas inteligentes puede desarrollarse mediante refinamientos sucesivos de una formulación inicial. En lugar de aceptar la primera versión producida, conviene solicitar análisis específicos sobre amplitud, ambigüedad, población, contexto o variables involucradas. Cedeño et al. (2024) permiten comprender la incorporación de estas tecnologías como apoyo dentro de procesos de construcción académica. Cada iteración puede revelar términos demasiado generales, límites poco claros o componentes que aún necesitan definición. Este procedimiento convierte la inteligencia artificial en una herramienta de

revisión progresiva, pero la calidad del resultado depende de que cada modificación sea evaluada según criterios metodológicos y no únicamente por su fluidez lingüística.

Una delimitación adecuada debe mantener correspondencia con los antecedentes disponibles. Si el problema se restringe excesivamente, puede resultar difícil encontrar evidencia suficiente que permita justificarlo; si permanece demasiado amplio, los antecedentes pueden abarcar fenómenos heterogéneos difíciles de integrar. Díaz (2024) permite situar la inteligencia artificial como recurso para comparar información y detectar relaciones dentro de conjuntos extensos de documentos. El investigador puede emplearla para comprobar si los límites propuestos coinciden con categorías presentes en la literatura o si requieren ajustes. Esta comparación no determina automáticamente la formulación correcta, pero permite identificar inconsistencias entre el problema planteado y el conocimiento científico que pretende fundamentarlo.


La delimitación también debe guardar coherencia con las posibilidades metodológicas del futuro estudio. Bunge (2017) permite sostener que una pregunta científica necesita formularse de manera que pueda ser examinada mediante procedimientos compatibles con el conocimiento científico. Un problema puede resultar conceptualmente interesante y, al mismo tiempo, ser demasiado amplio para investigarse con los recursos o métodos disponibles. Las herramientas inteligentes pueden ayudar a explorar consecuencias de distintas formulaciones, por ejemplo, mostrando cómo cambia el alcance cuando se incorpora o elimina una variable. Esta simulación permite evaluar alternativas antes de adoptar una versión definitiva, sin sustituir la decisión metodológica del investigador.

El apoyo de la inteligencia artificial resulta especialmente útil para detectar ambigüedades lingüísticas que afectan la precisión del problema. Términos como impacto, influencia, efecto, percepción o relación poseen implicaciones diferentes y no deberían utilizarse indistintamente. Krenn et al. (2022) permiten relacionar el empleo de sistemas inteligentes con procesos de exploración y generación de alternativas dentro de la actividad científica. Mediante comparaciones entre formulaciones, puede identificarse qué expresiones introducen supuestos causales, cuáles describen asociaciones y cuáles permanecen demasiado abiertas. La revisión conceptual posterior sigue siendo indispensable, porque una redacción lingüísticamente correcta puede mantener inconsistencias entre el término empleado y el diseño realmente posible.

Otro riesgo consiste en delegar a la herramienta la reducción automática del problema sin conservar trazabilidad sobre las decisiones realizadas. Una delimitación puede parecer precisa porque contiene población, lugar y periodo, aunque continúe sin expresar con claridad qué aspecto será investigado. Arias y Artigas (2022) permiten recordar que la relevancia científica depende de algo más que una formulación formalmente ordenada. Por ello, cada elemento añadido debe cumplir una función argumentativa y metodológica. La inteligencia artificial puede sugerir restricciones, pero el investigador necesita justificar por qué esas fronteras son pertinentes, qué evidencia las respalda y cómo contribuyen a convertir una preocupación inicial en un problema científicamente abordable.

Figura 2

Proceso de delimitación del problema de investigación



Nota. La figura representa la delimitación como un proceso progresivo que precisa el alcance del problema hasta establecer con claridad sus límites de estudio.

La delimitación asistida alcanza su mayor utilidad cuando articula precisión conceptual, contexto, población, temporalidad y posibilidades metodológicas dentro de una misma formulación coherente. Cedeño et al. (2024) permiten situar la inteligencia artificial como

recurso de apoyo en tareas investigativas complejas, mientras que su uso debe permanecer subordinado a criterios científicos explícitos. Delimitar no significa simplemente reducir el tamaño de un tema, sino establecer límites que hagan posible investigarlo sin perder el sentido del fenómeno original. Las herramientas inteligentes pueden facilitar comparaciones y refinamientos sucesivos, pero la formulación final requiere una decisión fundamentada que conserve correspondencia entre problema, antecedentes y condiciones reales del estudio.

1.7 Validación preliminar de la pertinencia y originalidad del problema

La validación preliminar de la pertinencia y originalidad del problema permite valorar si una propuesta investigativa posee suficiente fundamento antes de avanzar hacia etapas metodológicas más complejas. Arias y Artigas (2022) relacionan la relevancia del problema con la identificación de brechas que justifiquen nuevas indagaciones. La inteligencia artificial puede apoyar esta revisión mediante comparación de antecedentes, identificación de coincidencias temáticas y organización de evidencias vinculadas con el problema formulado. Su función no consiste en declarar automáticamente que una investigación es pertinente u original, sino en proporcionar elementos que permitan al investigador examinar si la propuesta responde a una necesidad científica claramente argumentada.

La pertinencia científica exige determinar si el problema se relaciona con una cuestión todavía insuficientemente explicada, discutida o resuelta en la literatura disponible. Una formulación puede ser clara y metodológicamente viable, pero resultar poco pertinente si reproduce preguntas ampliamente abordadas sin introducir una diferencia justificable. Castelo (2025) permite vincular esta valoración con la necesidad de examinar la utilidad y factibilidad de la propuesta dentro de un contexto investigativo concreto. Las herramientas inteligentes pueden facilitar la comparación entre el problema planteado y conjuntos de antecedentes, aunque el investigador debe interpretar si las similitudes encontradas representan repetición, continuidad necesaria o una oportunidad legítima de profundización.

La originalidad no debe reducirse a la búsqueda de un tema completamente nuevo. En investigación, también puede encontrarse en una población diferente, una relación poco estudiada, una perspectiva metodológica distinta o una combinación conceptual que permita examinar el fenómeno desde otra aproximación. Krenn et al. (2022) muestran cómo los sistemas de inteligencia artificial pueden intervenir en procesos científicos orientados a explorar posibilidades y generar alternativas. Esta capacidad puede utilizarse para contrastar distintas formulaciones del problema y detectar semejanzas con investigaciones previas. La

originalidad, sin embargo, requiere una interpretación razonada del aporte potencial y no una estimación basada únicamente en coincidencias textuales.

La revisión preliminar puede comenzar comparando los componentes centrales del problema con los antecedentes recuperados. Gilbert et al. (2024) permiten considerar la inteligencia artificial como apoyo para localizar, relacionar y procesar información científica. El investigador puede examinar coincidencias en variables, población, contexto, metodología o propósito para determinar hasta qué punto su propuesta reproduce configuraciones ya estudiadas. Una coincidencia parcial no invalida automáticamente el problema, puesto que puede existir una diferencia relevante en alguna de sus dimensiones. Lo decisivo es establecer con precisión qué elemento introduce una contribución distinta y por qué esa diferencia merece ser examinada mediante una nueva investigación.

Tabla 3

Matriz para la validación preliminar de pertinencia y originalidad del problema

Criterio de valoración	Pregunta de comprobación	Apoyo posible de la inteligencia artificial	Evidencia esperada
Pertinencia científica	¿Existe una cuestión insuficientemente resuelta?	Comparar antecedentes y detectar brechas	Diferencia justificable respecto del conocimiento disponible
Pertinencia contextual	¿El problema tiene sentido en la población o escenario elegido?	Organizar información del contexto	Correspondencia entre problema y condiciones estudiadas
Originalidad conceptual	¿Se propone una relación o enfoque poco desarrollado?	Identificar semejanzas y diferencias temáticas	Aporte conceptual claramente delimitado
Originalidad metodológica	¿El problema permite una aproximación distinta y fundamentada?	Comparar diseños y procedimientos previos	Diferencia metodológica pertinente
Consistencia	¿La propuesta mantiene coherencia entre problema, antecedentes y alcance?	Detectar contradicciones entre componentes	Formulación internamente articulada
Verificabilidad	¿La supuesta novedad puede comprobarse en la literatura?	Facilitar nuevas búsquedas de contraste	Antecedentes revisados y trazables

Nota. Elaboración propia. La matriz separa criterios de valoración que deben comprobarse antes de asumir la pertinencia u originalidad de una propuesta.

La matriz permite distinguir dos dimensiones que suelen confundirse. Un problema puede ser pertinente porque responde a una necesidad científica o contextual claramente identificada y,

aun así, presentar un grado limitado de originalidad. También puede ocurrir lo contrario: una propuesta aparentemente novedosa puede carecer de suficiente relevancia para justificar un estudio. Mata et al. (2024) permiten situar el uso de herramientas inteligentes dentro de procesos académicos donde la organización y revisión de información favorecen decisiones más fundamentadas. Examinar ambas dimensiones de forma separada evita que la novedad formal de una formulación sustituya la necesidad de demostrar su utilidad investigativa.

La validación preliminar requiere búsquedas de contraste dirigidas específicamente a poner a prueba la supuesta originalidad. No basta con que una primera consulta arroje pocos resultados, porque ello puede deberse a términos inadecuados, variaciones terminológicas o criterios de búsqueda demasiado restrictivos. Gilbert et al. (2024) permiten fundamentar el uso de inteligencia artificial para ampliar consultas, relacionar conceptos y localizar literatura potencialmente vinculada. Una estrategia sólida consiste en reformular términos, explorar sinónimos y modificar combinaciones conceptuales. Si después de estas comprobaciones persiste una diferencia claramente identificable respecto de los antecedentes, la afirmación de originalidad adquiere mayor sustento.

La pertinencia contextual necesita una comprobación diferente. El hecho de que un problema posea antecedentes internacionales o aparezca en numerosos estudios no demuestra automáticamente que sea relevante para cualquier población o escenario. Castelo (2025) permite considerar la pertinencia en relación con las condiciones concretas en que se desarrollará el proyecto. La inteligencia artificial puede ayudar a organizar información sobre el contexto y compararla con características descritas en otras investigaciones. Esta función permite detectar semejanzas y diferencias, pero corresponde al investigador establecer si esas condiciones justifican una nueva indagación y si el conocimiento esperado podrá responder efectivamente al problema identificado.

La validación también debe examinar posibles contradicciones internas entre la novedad declarada y la formulación del problema. Una propuesta puede afirmar que estudia una relación nueva, pero mantener objetivos, variables y contexto prácticamente idénticos a investigaciones precedentes. Krenn et al. (2022) permiten relacionar el uso de inteligencia artificial con procesos de exploración de alternativas científicas, lo que puede aprovecharse para comparar distintas versiones del planteamiento. Estas comparaciones ayudan a precisar dónde se encuentra realmente la diferencia. Si la originalidad depende únicamente de cambios

terminológicos, la propuesta necesita reformulación; si implica una variación sustantiva, esta debe expresarse de manera explícita y verificable.

Otro aspecto necesario consiste en mantener trazabilidad sobre la evidencia utilizada para validar el problema. Arias y Artigas (2022) permiten sostener que la identificación de una brecha requiere argumentos contruados a partir del conocimiento disponible. Por esta razón, las conclusiones generadas mediante inteligencia artificial deben poder relacionarse con antecedentes concretos y comprobables. Una afirmación como “el tema ha sido poco estudiado” carece de valor si no se demuestra qué búsquedas se realizaron, qué trabajos fueron encontrados y cuál es la diferencia entre ellos y la propuesta. La herramienta facilita la exploración, pero la justificación de pertinencia y originalidad debe permanecer documentada.

La validación preliminar funciona, finalmente, como un mecanismo de control antes de convertir una idea en un problema definitivo de investigación. Mata et al. (2024) permiten comprender la inteligencia artificial como apoyo para organizar información y revisar decisiones académicas, mientras que la responsabilidad interpretativa permanece en el investigador. El problema debería avanzar cuando exista evidencia suficiente de su pertinencia, una diferencia defendible respecto de los antecedentes y coherencia entre novedad, contexto y posibilidades de estudio. Esta revisión temprana reduce el riesgo de construir proyectos sobre supuestas brechas inexistentes y favorece una formulación cuya contribución pueda explicarse de manera clara y verificable.

Capítulo 2.

Formulación de preguntas científicas con inteligencia artificial

Galo Fernando Almeida Casanova



2.1 Características de una pregunta científica bien formulada

Una pregunta científica bien formulada traduce un problema de investigación en una interrogante susceptible de análisis sistemático. Bunge (2017) permite comprenderla como parte de una estructura lógica en la que el conocimiento avanza mediante problemas formulados con suficiente precisión para ser examinados racionalmente. Su calidad no depende únicamente de la corrección gramatical, sino de la claridad con que expresa aquello que se desea conocer y de la posibilidad de relacionarlo con procedimientos de investigación. Una pregunta ambigua, excesivamente amplia o sustentada en conceptos imprecisos dificulta la posterior definición de objetivos, variables, categorías, población y estrategias metodológicas.

La claridad constituye una condición básica porque la pregunta debe comunicar sin ambigüedad cuál es el fenómeno que será examinado. Arias y Artigas (2022) destacan la importancia de formular problemas científicos relevantes a partir de brechas identificables y adecuadamente delimitadas. Aplicado a la construcción de preguntas, esto implica evitar expresiones vagas, términos excesivamente generales o formulaciones que admitan interpretaciones incompatibles. La pregunta debe permitir reconocer su núcleo temático sin necesidad de explicaciones adicionales. Una redacción clara también facilita comprobar si existe correspondencia entre el problema detectado, los antecedentes revisados y el conocimiento que se espera producir mediante el estudio.

La precisión exige que los conceptos incluidos posean un significado suficientemente definido dentro del campo de estudio. Una pregunta puede ser comprensible y, al mismo tiempo, resultar imprecisa si emplea términos como influencia, impacto, calidad, percepción o desarrollo sin establecer qué representan en el contexto investigativo. Callirgos et al. (2022) permiten relacionar la formulación de preguntas con decisiones metodológicas que requieren coherencia entre los componentes del estudio. La selección de cada término debe anticipar el tipo de información que será necesaria para responder la interrogante, evitando introducir relaciones o supuestos que posteriormente no puedan sostenerse mediante el diseño elegido.

Otra característica fundamental corresponde a la delimitación. La pregunta debe establecer fronteras suficientes respecto de población, fenómeno, contexto y, cuando resulte pertinente, periodo de estudio. Falcón y Serpa (2021) permiten situar esta exigencia dentro de las decisiones que diferencian enfoques y diseños de investigación. Una interrogante excesivamente extensa puede incluir varios problemas simultáneos, mientras que una

delimitación demasiado estrecha puede reducir innecesariamente el alcance del análisis. El equilibrio consiste en formular una cuestión específica que conserve relevancia científica y que pueda abordarse dentro de las condiciones reales del proyecto sin fragmentar artificialmente el fenómeno investigado.

La viabilidad también determina la calidad de una pregunta científica. No basta con que una interrogante sea novedosa o conceptualmente interesante; debe ser posible obtener información suficiente para responderla mediante procedimientos compatibles con los recursos y condiciones disponibles. Bautista (2022) permite vincular la formulación de preguntas con la elección coherente del enfoque y de las técnicas de investigación. Antes de aceptar una pregunta, conviene valorar acceso a participantes o fuentes, posibilidades de medición u observación y correspondencia con el tiempo disponible. Una cuestión imposible de investigar empíricamente puede funcionar como reflexión teórica, pero no necesariamente como pregunta operativa para un proyecto concreto.

Tabla 4

Matriz analítica de características de una pregunta científica bien formulada

Característica	Criterio de comprobación	Señal de formulación adecuada	Problema frecuente
Claridad	¿Se comprende qué se desea conocer?	El núcleo de la interrogante es identificable	Ambigüedad conceptual
Precisión	¿Los términos tienen significado definido?	Los conceptos pueden vincularse con información observable o analizable	Uso de términos vagos
Delimitación	¿Se establecen límites suficientes?	El alcance resulta manejable	Amplitud excesiva
Relevancia	¿La pregunta responde a una necesidad de conocimiento?	Existe relación con una brecha justificable	Interrogante trivial o repetitiva
Viabilidad	¿Puede responderse con recursos y procedimientos disponibles?	Existe posibilidad real de obtener evidencia	Imposibilidad operativa
Coherencia	¿La pregunta corresponde al problema y al enfoque previsto?	Existe continuidad entre componentes del estudio	Desarticulación metodológica

Nota. Elaboración propia. La matriz permite revisar la consistencia de la pregunta antes de avanzar hacia su operacionalización metodológica.

La relevancia diferencia una pregunta científica de una interrogante meramente descriptiva o circunstancial. Una pregunta relevante debe responder a una necesidad de conocimiento

claramente identificada y aportar una razón suficiente para desarrollar el estudio. Arias y Artigas (2022) permiten vincular esta condición con la existencia de brechas, inconsistencias o problemas que requieren explicación. No todas las preguntas posibles poseen igual valor investigativo. Algunas pueden ser respondidas mediante información ya disponible, mientras que otras exigen nueva evidencia. La formulación adecuada debe mostrar que la respuesta esperada contribuirá efectivamente a comprender mejor el problema y no simplemente a producir información adicional sin propósito definido.

La coherencia interna requiere correspondencia entre la forma de preguntar y el tipo de respuesta que podrá producirse. Bautista (2022) permite considerar esta relación desde la articulación entre enfoque, problema y decisiones metodológicas. Una pregunta que utiliza términos causales exige condiciones diferentes de otra orientada a describir experiencias, interpretar significados o establecer asociaciones. Por ello, expresiones como “qué relación existe”, “cómo se manifiesta”, “qué significado atribuyen” o “en qué medida” no son intercambiables. Cada una anticipa una lógica investigativa específica. Elegir correctamente la forma interrogativa evita plantear expectativas de conocimiento que el diseño posterior no podrá satisfacer.

También debe evitarse la incorporación de supuestos no demostrados dentro de la propia pregunta. Bunge (2017) permite sostener que un problema científico necesita formularse de manera abierta a examen, sin convertir anticipadamente una explicación posible en una conclusión. Preguntar por las causas de un fenómeno presupone que dichas causas existen y que pueden establecerse, mientras que preguntar por relaciones o condiciones asociadas puede resultar más adecuado cuando todavía no existe evidencia suficiente. La formulación debe mantener apertura analítica y permitir que los resultados confirmen, modifiquen o contradigan las expectativas iniciales sin que la estructura de la pregunta fuerce una determinada respuesta.

La pregunta científica funciona además como eje articulador del proyecto. Falcón y Serpa (2021) permiten comprender que las decisiones posteriores sobre enfoque, diseño, participantes y técnicas dependen de la naturaleza de la interrogante planteada. Una pregunta bien formulada orienta la construcción de objetivos y ayuda a determinar qué información deberá obtenerse para responderla. Si cambia sustancialmente durante el desarrollo metodológico, debe revisarse también la coherencia de los demás componentes. Esta función articuladora explica por qué su redacción requiere más que corrección formal: debe expresar con precisión la relación entre el problema identificado y la estrategia de conocimiento prevista.

La formulación final debe resultar de un proceso de revisión y ajuste, no de una única redacción inicial. Callirgos et al. (2022) permiten vincular esta tarea con la necesidad de mantener consistencia entre los distintos componentes de una investigación. Una pregunta científicamente sólida combina claridad, precisión, delimitación, relevancia, viabilidad y coherencia metodológica sin convertir estos criterios en requisitos mecánicos. Su calidad se reconoce cuando permite comprender qué se investigará, por qué merece estudiarse y bajo qué lógica puede obtenerse una respuesta fundamentada. Esa consistencia proporciona una base estable para transformar el problema previamente delimitado en decisiones metodológicas posteriores.

2.2 Generación de preguntas de investigación mediante modelos de inteligencia artificial

La generación de preguntas de investigación mediante modelos de inteligencia artificial introduce una forma asistida de transformar temas, problemas y antecedentes en interrogantes susceptibles de análisis científico. Cedeño et al. (2024) permiten situar estas herramientas dentro de actividades académicas donde la inteligencia artificial apoya procesos de organización, producción y revisión de información. Su utilidad radica en proponer formulaciones iniciales a partir de instrucciones proporcionadas por el investigador. Sin embargo, la calidad de la pregunta generada depende de la precisión del problema de partida, de la información contextual suministrada y de la capacidad posterior para revisar críticamente la coherencia científica de la propuesta.

Los modelos de inteligencia artificial pueden producir varias preguntas a partir de una misma descripción, lo que facilita comparar enfoques posibles antes de seleccionar una formulación definitiva. Una problemática puede convertirse en interrogantes orientadas a describir, relacionar, comparar, explicar o comprender distintos componentes del fenómeno. Díaz (2024) permite considerar esta capacidad generativa como apoyo para ampliar alternativas dentro del trabajo académico. La diversidad obtenida resulta útil durante las primeras fases de diseño, siempre que no se confunda variedad con calidad. Una pregunta diferente no necesariamente representa una mejor opción si se aparta del problema, incorpora supuestos injustificados o introduce elementos que carecen de respaldo.

La calidad de las preguntas generadas se relaciona estrechamente con la información proporcionada al modelo. Barradas (2023) permite advertir que el uso académico de inteligencia artificial requiere instrucciones suficientemente contextualizadas para evitar

resultados genéricos. Una solicitud limitada a “generar preguntas sobre educación”, por ejemplo, ofrece pocos criterios para construir una interrogante científicamente delimitada. En cambio, aportar información sobre problema, población, contexto, variables o propósito favorece propuestas más específicas. Esto no significa que la herramienta comprenda necesariamente el fenómeno con profundidad disciplinar, sino que dispone de mejores condiciones lingüísticas y conceptuales para organizar una respuesta relacionada con los elementos introducidos.

La interacción puede estructurarse mediante instrucciones sucesivas en lugar de depender de una única consulta. Garzón et al. (2025) permiten considerar el refinamiento progresivo como parte del uso de herramientas inteligentes en procesos académicos. El investigador puede comenzar solicitando varias preguntas posibles y después pedir que se reduzca su amplitud, se eliminen términos ambiguos o se diferencien según el tipo de relación investigada. Cada interacción permite ajustar progresivamente la formulación. Este procedimiento resulta más consistente que aceptar automáticamente la primera pregunta producida, porque convierte la generación en un proceso de evaluación y modificación orientado por criterios definidos previamente.

Los modelos también pueden utilizarse para examinar cómo cambia una pregunta cuando se modifica alguno de sus componentes. Panfilova et al. (2026) permiten situar la inteligencia artificial como recurso para apoyar actividades investigativas que requieren interacción, revisión y adaptación de contenidos. Manteniendo constante el problema, el investigador puede explorar qué ocurre al modificar población, contexto, alcance o perspectiva analítica. Este ejercicio facilita comprender las consecuencias conceptuales de cada decisión. No obstante, las alternativas generadas deben conservar relación con el problema original, porque una variación aparentemente interesante puede desplazar gradualmente el objeto de estudio hacia una cuestión distinta que requeriría otros antecedentes y otra justificación.


Otra aplicación consiste en solicitar al modelo preguntas correspondientes a diferentes niveles de profundidad. Una primera formulación puede limitarse a identificar características de un fenómeno, mientras que otras pueden explorar asociaciones, diferencias o procesos más complejos. Cedeño et al. (2024) permiten relacionar esta función con el uso de inteligencia artificial como apoyo en distintas etapas de construcción investigativa. Comparar preguntas de diferente alcance ayuda a reconocer qué tipo de conocimiento pretende obtenerse. Sin embargo, no debe asumirse que una interrogante más compleja es necesariamente superior, pues su

conveniencia depende de los antecedentes disponibles, del enfoque seleccionado y de las posibilidades metodológicas reales del proyecto.

La generación automatizada también puede ayudar a detectar problemas de redacción presentes en una pregunta elaborada inicialmente por el investigador. Díaz (2024) permite considerar la inteligencia artificial como herramienta de apoyo para revisar y reorganizar contenidos académicos. Al solicitar varias reformulaciones, pueden hacerse visibles ambigüedades, repeticiones, relaciones poco claras o términos que admiten interpretaciones diferentes. Esta función resulta especialmente valiosa cuando la intención científica está definida, pero la formulación lingüística todavía es imprecisa. La revisión humana debe garantizar que las modificaciones no alteren el sentido original, introduzcan relaciones causales inexistentes o sustituyan conceptos técnicos por expresiones aparentemente más fluidas, pero menos exactas.

Figura 3

Generación de preguntas de investigación de baja calidad con IA



Nota. La figura muestra cómo una formulación insuficientemente definida puede generar preguntas poco pertinentes, inconsistentes o alejadas del propósito de la investigación cuando se utiliza inteligencia artificial.

La inteligencia artificial también puede producir preguntas plausibles que carecen de suficiente fundamento científico. Barradas (2023) permite advertir que las respuestas generadas deben

ser examinadas con criterio académico y no aceptadas por su apariencia de corrección. Una interrogante puede estar gramaticalmente bien construida y, aun así, combinar variables sin relación demostrada, introducir poblaciones arbitrarias o formular problemas cuya relevancia no ha sido comprobada. Por esta razón, cada propuesta debe contrastarse con los antecedentes y con la delimitación previamente realizada. La generación constituye una fase creativa de apoyo; la justificación científica de la pregunta corresponde a un proceso distinto de validación.

Los modelos pueden contribuir igualmente a revisar la correspondencia entre la pregunta principal y posibles preguntas específicas. Garzón et al. (2025) permiten situar estas herramientas dentro de procesos de refinamiento donde la coherencia entre componentes puede analizarse mediante iteraciones sucesivas. Una pregunta general puede descomponerse en interrogantes orientadas a dimensiones particulares, siempre que cada una contribuya realmente a responder el problema central. La inteligencia artificial puede sugerir esa desagregación, pero existe el riesgo de producir preguntas específicas redundantes o desconectadas. El investigador debe comprobar que cada interrogante tenga una función diferenciada y que el conjunto conserve una estructura lógica común.

La formulación mediante inteligencia artificial también puede aprovecharse para comparar distintas expresiones interrogativas. Preguntar “qué relación existe”, “cómo se caracteriza”, “qué diferencias se presentan” o “cómo se interpreta” conduce a expectativas de conocimiento diferentes. Panfilova et al. (2026) permiten comprender el potencial de los modelos para generar alternativas y apoyar procesos de revisión dentro de la investigación. Al contrastar estas formulaciones, el investigador puede identificar cuál corresponde mejor al propósito del estudio. Esta comparación debe realizarse antes de consolidar objetivos y metodología, porque pequeñas modificaciones lingüísticas pueden implicar cambios sustanciales en el tipo de evidencia necesaria para responder adecuadamente la pregunta.

La generación de preguntas adquiere mayor rigor cuando el investigador solicita al modelo justificar las diferencias entre las alternativas propuestas. En lugar de limitarse a recibir un listado, puede requerirse que identifique qué elemento cambia, qué alcance presupone cada formulación o qué información sería necesaria para responderla. Cedeño et al. (2024) permiten situar este tipo de interacción dentro del uso reflexivo de herramientas inteligentes para apoyar decisiones académicas. Las explicaciones ofrecidas tampoco deben asumirse como criterios definitivos, pero pueden ayudar a reconocer inconsistencias y estimular una revisión más

consciente. El valor reside en utilizar la respuesta como insumo para razonar, comparar y depurar.

La generación asistida de preguntas resulta útil cuando se integra dentro de un proceso controlado que comienza con un problema fundamentado y termina con una formulación revisada por el investigador. Garzón et al. (2025) permiten comprender la importancia del refinamiento iterativo, mientras que la inteligencia artificial aporta rapidez para producir alternativas y explorar variaciones. El objetivo no consiste en delegar la pregunta científica al modelo, sino en ampliar las posibilidades de formulación y someterlas después a criterios de claridad, pertinencia, delimitación y viabilidad. Una pregunta generada alcanza valor investigativo únicamente cuando mantiene coherencia con los antecedentes, el problema y las condiciones reales del estudio.

2.3 Transformación de problemas de investigación en preguntas científicas

Transformar un problema de investigación en una pregunta científica implica convertir una situación previamente delimitada en una interrogante capaz de orientar la producción sistemática de conocimiento. Arias y Artigas (2022) permiten comprender esta transición como un proceso que parte de la identificación de una brecha y avanza hacia una formulación susceptible de investigación. La pregunta no debe limitarse a reformular el problema en forma interrogativa, porque necesita expresar con claridad qué relación, condición, característica o proceso será examinado. Una transformación adecuada conserva el núcleo del problema, pero lo organiza de modo que pueda vincularse con objetivos, decisiones metodológicas y procedimientos de análisis posteriores.

El problema y la pregunta cumplen funciones relacionadas, aunque no equivalentes. El primero expone una situación que requiere explicación o conocimiento adicional; la segunda precisa qué aspecto de esa situación será interrogado científicamente. Bunge (2017) permite situar esta diferencia dentro de la lógica de la investigación, donde los problemas deben formularse de manera que puedan ser sometidos a examen racional. Por ello, una pregunta científica no surge de añadir signos de interrogación a una afirmación problemática. Requiere seleccionar los componentes relevantes, establecer relaciones posibles entre ellos y evitar formulaciones que anticipen respuestas o incorporen supuestos que todavía no han sido comprobados.

Una transformación rigurosa comienza identificando el núcleo cognoscitivo del problema. Si una situación contiene múltiples actores, causas posibles, consecuencias y condiciones

contextuales, resulta necesario determinar qué se desconoce exactamente y qué conocimiento sería necesario producir. Callirgos et al. (2022) permiten relacionar esta definición con la coherencia que debe existir entre problema, propósito y estructura metodológica. La pregunta científica debe concentrarse en aquello que puede investigarse de manera concreta, evitando incluir simultáneamente varios problemas distintos. Esta reducción no implica empobrecer el fenómeno, sino establecer un foco analítico que permita estudiar una parte relevante sin perder su vínculo con la situación original.

La inteligencia artificial puede apoyar esta transformación mediante la descomposición del problema en componentes y la generación de alternativas interrogativas. Cedeño et al. (2024) permiten situar estas herramientas como recursos complementarios dentro de tareas académicas vinculadas con la formulación investigativa. A partir de una descripción suficientemente detallada, un sistema puede identificar población, variables, contexto, relaciones y posibles focos de análisis. Esta función resulta útil para comparar opciones, pero las categorías generadas deben ser revisadas. Un modelo puede introducir elementos no previstos, sobredimensionar relaciones secundarias o proponer preguntas formalmente correctas que no correspondan con la brecha que dio origen al estudio.

La formulación depende también del tipo de conocimiento que se pretende obtener. Una misma problemática puede dar lugar a preguntas descriptivas, comparativas, relacionales, explicativas o interpretativas, y cada opción modifica las exigencias posteriores del proyecto. Arias y Artigas (2022) permiten vincular esta decisión con la necesidad de que el problema conserve relevancia y delimitación suficientes. Antes de elegir una estructura interrogativa, conviene determinar si se desea conocer cómo se presenta un fenómeno, qué diferencias existen entre grupos, qué relación aparece entre determinados elementos o cómo se comprende una experiencia. La pregunta debe expresar esa intención sin atribuir resultados antes de disponer de evidencia.

El cambio de una sola palabra puede modificar sustancialmente el alcance de una pregunta. Expresiones como asociación, efecto, influencia, diferencia o percepción no son equivalentes y pueden implicar expectativas metodológicas distintas. Bunge (2017) permite recordar que la precisión conceptual es indispensable cuando un problema se convierte en una cuestión científicamente examinable. La inteligencia artificial puede generar variantes lingüísticas y señalar diferencias entre formulaciones, pero la elección requiere conocimiento metodológico. Una pregunta que presupone causalidad, por ejemplo, no debería adoptarse cuando el diseño

previsto únicamente permite estudiar relaciones entre variables. La redacción debe reflejar fielmente lo que puede investigarse.

La transformación también exige preservar los límites establecidos durante la formulación del problema. Población, contexto y alcance no deberían desaparecer cuando la problemática se convierte en pregunta, salvo que exista una razón metodológica para modificarlos. Callirgos et al. (2022) permiten comprender que la consistencia entre componentes constituye una condición del diseño investigativo. Una pregunta demasiado general puede deshacer el trabajo previo de delimitación y ampliar nuevamente el objeto de estudio. Por el contrario, añadir restricciones innecesarias puede convertirla en una interrogante excesivamente específica. El criterio debe ser conservar únicamente aquellos límites que contribuyen a definir con precisión dónde y sobre qué se producirá conocimiento.

Las herramientas inteligentes pueden ser utilizadas para comparar varias formulaciones derivadas de un mismo problema y examinar sus implicaciones. Krenn et al. (2022) permiten relacionar el uso de sistemas inteligentes con la exploración de alternativas dentro de procesos científicos. El investigador puede solicitar versiones orientadas a distintos alcances y analizar cómo cambia el objeto cuando se modifica una variable, se incorpora un contexto o se altera el tipo de relación expresada. Este ejercicio resulta útil para anticipar consecuencias antes de seleccionar la pregunta definitiva. La comparación, sin embargo, debe mantenerse subordinada al problema original y a la evidencia que sustenta su relevancia.

Un criterio esencial consiste en verificar que la pregunta pueda responderse mediante información obtenible. La transformación fracasa cuando produce una interrogante conceptualmente interesante pero imposible de abordar con procedimientos disponibles. Cedeño et al. (2024) permiten considerar la inteligencia artificial como apoyo para revisar la correspondencia entre formulaciones y posibles estrategias de investigación. La herramienta puede señalar requerimientos generales asociados con distintas preguntas, aunque no determina por sí misma su viabilidad. El investigador debe comprobar acceso a fuentes o participantes, posibilidad de observar los fenómenos involucrados y congruencia entre el tipo de respuesta buscada y los métodos que posteriormente podrán emplearse.

También debe revisarse que la pregunta no amplíe o distorsione la brecha inicialmente identificada. Una formulación atractiva puede introducir conceptos nuevos que no estuvieron presentes en los antecedentes o desplazar el interés hacia relaciones diferentes de las que

justificaron el problema. Arias y Artigas (2022) permiten sostener que la pregunta debe conservar correspondencia con la necesidad de conocimiento previamente demostrada. Por esta razón, resulta conveniente volver a los antecedentes después de formularla y comprobar si continúa respondiendo al vacío reconocido. La inteligencia artificial puede facilitar esta comparación, pero la coherencia científica requiere una lectura crítica de las fuentes y del planteamiento construido.

La transformación del problema en pregunta científica se completa cuando existe continuidad entre la brecha identificada, el objeto delimitado y la interrogante formulada. Krenn et al. (2022) permiten situar la inteligencia artificial como recurso para explorar alternativas y apoyar decisiones dentro de procesos científicos, pero la selección final exige valoración humana. Una pregunta sólida concentra el problema sin deformarlo, explicita el tipo de conocimiento buscado y mantiene límites compatibles con las condiciones del estudio. Convertir un problema en pregunta supone, por tanto, una operación conceptual y metodológica que organiza la incertidumbre inicial en una forma susceptible de investigación sistemática.

2.4 Delimitación de población, variables, contexto y alcance en las preguntas

La delimitación de población, variables, contexto y alcance permite convertir una pregunta general en una formulación científicamente manejable. Arias y Artigas (2022) vinculan la construcción de problemas relevantes con la necesidad de establecer límites que permitan identificar con precisión qué se pretende conocer. En la pregunta de investigación, estos límites evitan que el objeto se expanda de forma indefinida y facilitan la posterior correspondencia con objetivos, diseño y técnicas de recolección. Una formulación adecuada debe incluir únicamente los componentes necesarios para definir el fenómeno, sin sobrecargar la interrogante con detalles que corresponden a otras secciones metodológicas.

La población delimita a quiénes, qué unidades o qué casos se refiere la pregunta. Bautista (2022) permite comprender esta decisión en relación con el enfoque y con la naturaleza del fenómeno estudiado. No toda pregunta requiere mencionar una población en términos estrictamente estadísticos; en estudios cualitativos, por ejemplo, puede referirse a participantes, grupos, experiencias o contextos específicos. Lo importante es evitar expresiones amplias como “los estudiantes”, “las empresas” o “la población” cuando el proyecto realmente examina un subconjunto definido. La precisión poblacional contribuye a determinar sobre quiénes podrá sostenerse posteriormente la respuesta obtenida.

Las variables adquieren especial importancia cuando la pregunta busca describir, comparar o relacionar atributos susceptibles de medición. Falcón y Serpa (2021) permiten distinguir cómo la estructura de la pregunta cambia según el enfoque investigativo y el tipo de conocimiento pretendido. En formulaciones cuantitativas, las variables deben aparecer con suficiente claridad para evitar confundir fenómenos diferentes o establecer relaciones imprecisas. Sin embargo, no resulta conveniente incorporar variables simplemente para otorgar apariencia técnica a la pregunta. Cada una debe derivarse del problema, contar con sustento conceptual y cumplir una función específica dentro de la relación que se pretende investigar.

El contexto precisa las condiciones institucionales, sociales, educativas, organizacionales o territoriales en las que la pregunta adquiere significado. Callirgos et al. (2022) permiten relacionar esta delimitación con la coherencia interna que debe mantener el diseño del estudio. Un mismo fenómeno puede presentar características distintas según el escenario en el que ocurre, por lo que omitir el contexto puede conducir a generalizaciones excesivas. Tampoco es necesario introducir todos los detalles del lugar dentro de la interrogante. La delimitación contextual debe aportar información suficiente para comprender dónde se sitúa el problema, evitando convertir la pregunta en una descripción extensa del escenario investigado.

El alcance define el tipo y profundidad de conocimiento que se espera producir. Una pregunta puede orientarse a describir características, comparar grupos, examinar relaciones, comprender experiencias o explorar procesos, entre otras posibilidades. Posso et al. (2025) permiten situar esta decisión dentro de la articulación entre formulación investigativa y procedimientos metodológicos. Expresiones como “qué características”, “qué relación”, “qué diferencias” o “cómo se manifiesta” orientan respuestas distintas y requieren estrategias compatibles. Delimitar el alcance no consiste únicamente en elegir un verbo o una fórmula interrogativa, sino en establecer qué nivel de análisis resulta coherente con el problema y con la evidencia disponible.

Tabla 5
Matriz analítica para delimitar componentes de una pregunta de investigación

Componente	Pregunta de control	Función en la formulación	Riesgo de una delimitación inadecuada
Población	¿Sobre quiénes o qué unidades se investigará?	Define los sujetos, casos o unidades de análisis	Generalización excesiva

Componente	Pregunta de control	Función en la formulación	Riesgo de una delimitación inadecuada
Variables o categorías	¿Qué fenómenos serán examinados?	Precisa los conceptos centrales del estudio	Ambigüedad conceptual
Contexto	¿En qué escenario adquiere sentido el problema?	Ubica las condiciones en que ocurre el fenómeno	Descontextualización
Alcance	¿Qué tipo de conocimiento se busca producir?	Orienta la profundidad y naturaleza de la respuesta	Incompatibilidad metodológica
Articulación	¿Los componentes mantienen coherencia entre sí?	Integra la estructura de la pregunta	Formulación fragmentada

Nota. Elaboración propia. La matriz funciona como criterio de revisión para comprobar que los límites de la pregunta sean suficientes y coherentes.

La delimitación adecuada no significa incorporar obligatoriamente todos estos elementos de forma explícita en cada pregunta. Arias y Artigas (2022) permiten sostener que la precisión debe responder a la naturaleza del problema y no a una estructura mecánica. En algunos estudios, población y contexto pueden quedar claramente establecidos por el planteamiento previo, mientras que en otros su presencia dentro de la interrogante evita ambigüedades importantes. El criterio consiste en determinar qué información necesita el lector para comprender con exactitud el objeto interrogado. Agregar componentes innecesarios puede volver la pregunta extensa, rígida y difícil de relacionar con el propósito central.

También debe examinarse la relación entre población y alcance. Una pregunta formulada sobre una población muy amplia puede exigir recursos incompatibles con las condiciones reales del estudio, especialmente cuando pretende establecer comparaciones o relaciones entre numerosos grupos. Bautista (2022) permite vincular esta decisión con la necesidad de mantener congruencia entre enfoque, participantes y posibilidades metodológicas. Reducir la población puede hacer viable el estudio, pero esa restricción debe justificarse y no responder únicamente a comodidad operativa. La delimitación adecuada busca equilibrio entre representatividad del problema, profundidad del análisis y posibilidad real de obtener información suficiente para responder la interrogante.

La coherencia entre variables y alcance merece una revisión específica. Una pregunta que incluye dos variables no implica necesariamente que pretenda determinar causalidad entre ellas. Falcón y Serpa (2021) permiten comprender que las relaciones planteadas deben corresponder con el enfoque y diseño que posteriormente se adoptarán. Expresiones como

“influencia” o “efecto” pueden introducir expectativas explicativas que exceden las posibilidades de determinados estudios, mientras que “relación” o “asociación” delimitan otro tipo de análisis. Por ello, la formulación debe evitar que la elección lingüística atribuya al proyecto una capacidad de inferencia que su estrategia metodológica no podrá sostener.

El contexto también puede funcionar como criterio de diferenciación científica. Callirgos et al. (2022) permiten considerar que la delimitación contextual contribuye a definir la pertinencia de la investigación y la interpretación de sus resultados. Estudiar un fenómeno en una institución, territorio o grupo específico puede ser relevante cuando existen condiciones que justifican examinarlo allí. Sin embargo, cambiar únicamente el lugar de una investigación previa no garantiza por sí mismo una contribución significativa. El contexto debe formar parte de la lógica del problema y no emplearse como recurso superficial para presentar como nueva una pregunta cuya estructura conceptual permanece prácticamente idéntica.

Una pregunta bien delimitada integra población, variables o categorías, contexto y alcance de manera coherente con el problema previamente construido. Posso et al. (2025) permiten relacionar esta articulación con decisiones metodológicas posteriores, porque cada componente condiciona qué información deberá obtenerse y cómo podrá analizarse. La delimitación no busca reducir artificialmente la complejidad del fenómeno, sino establecer fronteras que permitan investigarlo con precisión. Cuando estos elementos se encuentran claramente definidos y conectados, la pregunta adquiere una estructura capaz de orientar el proyecto sin anticipar respuestas, introducir supuestos injustificados ni exceder las posibilidades reales del estudio.

2.5 Formulación de preguntas según enfoques cuantitativos, cualitativos y mixtos

La formulación de preguntas científicas varía según el enfoque desde el cual se pretende estudiar el problema. Bautista (2022) permite distinguir que los enfoques cuantitativo, cualitativo y mixto responden a lógicas diferentes de producción de conocimiento, por lo que no resulta adecuado formular una misma interrogante y modificar únicamente la técnica de recolección. La pregunta debe anticipar qué tipo de evidencia será necesaria, qué relación se establecerá con el fenómeno y cuál será la profundidad esperada del análisis. Esta correspondencia inicial evita inconsistencias entre la formulación del problema, los objetivos, el diseño metodológico y los procedimientos utilizados posteriormente.

En el enfoque cuantitativo, las preguntas suelen orientarse hacia la medición, comparación, asociación o explicación de variables previamente definidas. Falcón y Serpa (2021) permiten comprender que esta lógica requiere una delimitación suficientemente precisa de los componentes que serán observados. Una pregunta cuantitativa debe indicar con claridad qué variables participan, sobre qué población se examinan y qué tipo de relación se pretende establecer. Expresiones como frecuencia, diferencia, relación o asociación pueden resultar pertinentes cuando corresponden con el diseño previsto. La formulación debe evitar términos causales si el estudio no posee condiciones metodológicas que permitan sostener ese nivel de inferencia.

Las preguntas cuantitativas también necesitan cuidar la correspondencia entre nivel de alcance y estructura interrogativa. Una pregunta descriptiva busca caracterizar la distribución o comportamiento de una variable, mientras que una pregunta correlacional examina relaciones entre dos o más componentes. Bautista (2022) permite situar estas diferencias dentro de las decisiones metodológicas que derivan del enfoque elegido. Formular “qué relación existe” implica una expectativa distinta de preguntar “cuál es el nivel” o “qué diferencias se presentan”. Cada construcción orienta procedimientos de análisis específicos, por lo que la elección de la forma interrogativa debe responder al conocimiento que efectivamente puede producir el estudio.

Las preguntas cualitativas siguen una lógica distinta porque buscan comprender significados, experiencias, procesos, interpretaciones o dinámicas situadas. Williams y Ingleby (2025) permiten relacionar este enfoque con formas de investigación donde la apertura analítica resulta necesaria para captar la complejidad del fenómeno. En estos casos, la pregunta no suele estructurarse alrededor de variables medibles, sino de experiencias, prácticas, percepciones o procesos que requieren interpretación contextual. Formulaciones como “cómo se comprende”, “cómo se experimenta” o “qué significado se atribuye” pueden orientar este tipo de indagación, siempre que no presupongan de antemano categorías que deberían emerger durante el análisis.

La apertura de una pregunta cualitativa no implica ausencia de delimitación. Zhang et al. (2025) permiten considerar la importancia de mantener suficiente precisión para orientar la recolección y análisis de información sin cerrar prematuramente las posibles interpretaciones. La población o los participantes, el fenómeno central y el contexto deben aparecer claramente definidos cuando sean necesarios para comprender el objeto de estudio. El equilibrio consiste en formular una pregunta suficientemente abierta para permitir que surjan matices y

significados no anticipados, pero lo bastante delimitada para evitar una exploración indefinida. Una pregunta cualitativa demasiado general puede dificultar la construcción de una estrategia analítica coherente.

La diferencia entre preguntas cuantitativas y cualitativas no se reduce al uso de determinados términos. Falcón y Serpa (2021) permiten sostener que ambas responden a supuestos distintos respecto de cómo se examina el fenómeno y qué tipo de conocimiento se espera obtener. Una pregunta cuantitativa suele buscar patrones observables entre variables, mientras que una cualitativa procura comprender cómo se configura o interpreta una experiencia dentro de determinadas condiciones. Esta diferencia debe conservarse desde la formulación inicial. Transformar una pregunta cuantitativa en cualitativa mediante un simple cambio verbal puede producir inconsistencias si permanece intacta la lógica de medición originalmente planteada.

El enfoque mixto introduce una exigencia adicional: articular componentes cuantitativos y cualitativos dentro de un mismo problema de investigación. Cedeño et al. (2024) permiten situar las herramientas de inteligencia artificial como apoyo en procesos investigativos que requieren organizar y revisar estructuras complejas. Una pregunta mixta debe justificar por qué ambos tipos de evidencia son necesarios y qué relación existirá entre ellos. No basta con formular una pregunta cuantitativa y añadir otra cualitativa de manera independiente. La integración debe responder a una necesidad analítica concreta, de modo que los resultados obtenidos mediante un enfoque contribuyan a complementar, explicar o ampliar los obtenidos mediante el otro.

Las preguntas mixtas pueden estructurarse mediante una interrogante integradora o mediante varias preguntas vinculadas entre sí. Bautista (2022) permite comprender que la elección depende del diseño y de la secuencia con que se combinarán los componentes metodológicos. En algunos estudios, la medición puede preceder a una exploración cualitativa destinada a comprender ciertos resultados; en otros, una fase inicial cualitativa puede contribuir a definir posteriormente variables o instrumentos. La pregunta debe reflejar esa lógica de integración sin convertirse en una formulación excesivamente extensa. La claridad exige que cada componente cumpla una función diferenciada dentro del propósito general.


La inteligencia artificial puede apoyar la comparación entre formulaciones correspondientes a distintos enfoques. Cedeño et al. (2024) permiten considerar estas herramientas como recursos para generar alternativas y revisar coherencia dentro del diseño de investigación. A partir de

un mismo problema, un modelo puede producir versiones cuantitativas, cualitativas y mixtas para que el investigador examine cómo cambia el objeto de conocimiento. Esta práctica facilita reconocer diferencias entre medir relaciones, comprender experiencias e integrar ambas aproximaciones. Sin embargo, la herramienta no debe decidir el enfoque únicamente por la forma lingüística de la pregunta, porque esa elección requiere considerar la naturaleza del problema y los antecedentes.

También resulta necesario evitar preguntas híbridas que mezclen lógicas incompatibles sin una integración metodológica explícita. Williams y Ingleby (2025) permiten comprender la importancia de mantener coherencia entre la intención investigativa y la forma en que se construye la pregunta. Una interrogante que pretende medir una variable y, simultáneamente, comprender significados profundos puede requerir un enfoque mixto, pero solo si ambos componentes se articulan de manera fundamentada. Cuando esa integración no está justificada, la pregunta puede terminar exigiendo procedimientos demasiado amplios. La formulación debe expresar una intención científica clara y compatible con los recursos, participantes y posibilidades analíticas del proyecto.

Figura 4

Explorando las dimensiones de las preguntas científicas



Nota. La figura representa la relación entre la formulación de preguntas científicas y la elección del enfoque metodológico más adecuado según la naturaleza del problema estudiado.

La revisión de preguntas según enfoque debe considerar también qué tipo de respuestas podrían producir. Zhang et al. (2025) permiten vincular la formulación con procesos de análisis donde el significado de la evidencia depende del modo en que fue obtenida. Una pregunta cuantitativa debería conducir a resultados susceptibles de medición y comparación; una cualitativa, a interpretaciones contextualizadas; y una mixta, a una integración razonada de ambos tipos de evidencia. Examinar anticipadamente la naturaleza de la respuesta ayuda a detectar

inconsistencias. Si la respuesta esperada no corresponde con la estructura de la interrogante, resulta necesario reformularla antes de consolidar el diseño metodológico.

La formulación según enfoques cuantitativos, cualitativos y mixtos requiere que la pregunta mantenga coherencia con el tipo de conocimiento buscado y con las condiciones reales del estudio. Falcón y Serpa (2021) permiten comprender esta correspondencia como parte esencial de la lógica metodológica. Las herramientas de inteligencia artificial pueden ampliar alternativas, señalar diferencias de formulación y apoyar procesos de revisión, pero la elección final depende de la naturaleza del problema y de la estrategia científica adoptada. Una pregunta bien formulada no solo identifica qué se desea conocer, sino que expresa de manera consistente cómo ese conocimiento puede construirse desde el enfoque seleccionado.

2.6 Evaluación de claridad, precisión y viabilidad de las preguntas mediante inteligencia artificial

La evaluación de claridad, precisión y viabilidad constituye una fase necesaria antes de adoptar una pregunta como eje definitivo del proyecto. Garzón et al. (2025) permiten situar la inteligencia artificial como apoyo para revisar formulaciones, detectar ambigüedades y proponer ajustes sucesivos. Una pregunta puede parecer adecuada por su estructura gramatical y, aun así, contener conceptos vagos, relaciones imprecisas o exigencias metodológicas difíciles de cumplir. El uso de herramientas inteligentes resulta útil cuando se orienta a identificar estos problemas y generar alternativas de reformulación. La decisión final debe conservarse bajo revisión académica, porque una redacción fluida no garantiza validez científica ni coherencia metodológica.

La claridad se refiere a la posibilidad de comprender con exactitud qué se desea conocer. Panfilova et al. (2026) permiten considerar el potencial de los modelos de inteligencia artificial para revisar textos académicos mediante procesos iterativos de reformulación. Una herramienta puede señalar términos ambiguos, estructuras demasiado extensas o construcciones que admiten varias interpretaciones. También puede comparar versiones de una misma pregunta y mostrar cuál presenta una organización más directa. Sin embargo, la evaluación no debe limitarse a simplificar el lenguaje. Una pregunta científicamente clara necesita conservar la terminología necesaria para representar con fidelidad el fenómeno, aunque algunos conceptos requieran posteriormente una definición especializada.

La precisión exige examinar si cada término expresa exactamente la relación que se pretende investigar. Posso et al. (2025) permiten vincular esta revisión con la necesidad de mantener coherencia entre pregunta, variables, categorías y procedimientos metodológicos. La inteligencia artificial puede ayudar a detectar palabras como impacto, influencia, efecto, relación o percepción y advertir que no son necesariamente intercambiables. Esta revisión resulta especialmente útil cuando una formulación introduce implícitamente causalidad o un nivel de análisis que el diseño no podrá sostener. El investigador debe comprobar después si la alternativa sugerida conserva el sentido conceptual y corresponde con la evidencia que realmente podrá producirse.

La viabilidad obliga a pasar de la corrección lingüística a las condiciones reales de ejecución. Castillo (2023) permite considerar que el uso de inteligencia artificial en investigación requiere evaluar críticamente las decisiones que estas herramientas apoyan. Una pregunta puede ser clara y precisa, pero resultar inviable si exige acceso a una población inaccesible, información inexistente, recursos técnicos no disponibles o un periodo incompatible con el proyecto. La herramienta puede utilizarse para identificar posibles exigencias derivadas de la pregunta y organizar restricciones conocidas. No obstante, la valoración final depende de información contextual que el modelo puede desconocer o interpretar de manera incompleta.

Tabla 6
Matriz de evaluación asistida de preguntas científicas

Criterio	Aspecto que debe revisarse	Apoyo posible de la inteligencia artificial	Señal de alerta
Claridad	Comprensión directa de la interrogante	Detectar ambigüedades y proponer reformulaciones	Interpretaciones múltiples
Precisión	Correspondencia entre términos y relaciones planteadas	Comparar vocabulario y estructuras alternativas	Conceptos vagos o relaciones mal definidas
Delimitación	Presencia de límites suficientes	Identificar amplitud excesiva o elementos faltantes	Pregunta demasiado general
Viabilidad	Posibilidad real de obtener evidencia	Organizar requisitos y restricciones del estudio	Recursos o acceso insuficientes
Coherencia	Relación con problema, objetivos y enfoque	Contrastar componentes del proyecto	Incompatibilidad metodológica
Revisión humana	Correspondencia científica de la formulación	Señalar puntos que requieren comprobación	Aceptación automática de la respuesta generada

Nota. Elaboración propia. La matriz permite separar criterios lingüísticos, metodológicos y operativos durante la revisión de una pregunta.

La tabla muestra que una pregunta puede superar un criterio y presentar deficiencias en otro. Una formulación clara puede seguir siendo metodológicamente incoherente, mientras que una pregunta conceptualmente precisa puede resultar imposible de ejecutar. Garzón et al. (2025) permiten comprender la evaluación como un proceso iterativo en el que distintas versiones pueden compararse antes de seleccionar una formulación final. La inteligencia artificial facilita esta comparación porque puede modificar un componente específico sin alterar necesariamente los demás. El investigador debe revisar cada cambio de manera independiente, evitando asumir que una mejora estilística resuelve simultáneamente problemas de delimitación, pertinencia o factibilidad.

Una estrategia útil consiste en solicitar al modelo que evalúe la pregunta mediante criterios separados. Panfilova et al. (2026) permiten situar este tipo de interacción dentro de procesos de revisión asistida donde las instrucciones orientan el análisis producido. En lugar de preguntar si una formulación “está bien”, resulta más productivo requerir que identifique términos ambiguos, supuestos implícitos, amplitud del alcance o información necesaria para responderla. Esta descomposición mejora la utilidad de la respuesta y facilita una revisión posterior. También reduce el riesgo de aceptar valoraciones globales poco transparentes, porque permite reconocer qué parte concreta de la pregunta necesita modificación.

La evaluación asistida debe incorporar comprobaciones de coherencia con el resto del proyecto. Posso et al. (2025) permiten relacionar la formulación de preguntas con decisiones posteriores sobre instrumentos, variables, participantes y procedimientos. Una pregunta puede parecer viable cuando se analiza de manera aislada, pero mostrar incompatibilidades al compararla con el objetivo general o con el enfoque seleccionado. La inteligencia artificial puede utilizarse para contrastar estos componentes y señalar discrepancias preliminares. Esta función resulta especialmente útil durante el diseño, aunque cualquier recomendación debe verificarse metodológicamente antes de modificar elementos ya sustentados por antecedentes o decisiones conceptuales previas.

La apariencia de plausibilidad constituye una limitación particularmente relevante. Gao et al. (2023) muestran que un texto científico generado por inteligencia artificial puede resultar convincente en su forma sin que ello garantice calidad científica. Esta advertencia se aplica directamente a la evaluación de preguntas: una reformulación puede sonar más técnica, precisa

o académica y, aun así, introducir errores conceptuales o supuestos injustificados. Por ello, no conviene valorar una propuesta únicamente por su fluidez. La pregunta debe revisarse frente al problema, los antecedentes y las condiciones metodológicas, distinguiendo entre corrección lingüística y solidez científica.

La viabilidad también puede examinarse mediante escenarios alternativos. Castillo (2023) permite considerar la inteligencia artificial como recurso de apoyo para explorar consecuencias antes de adoptar determinadas decisiones investigativas. El modelo puede comparar qué ocurre si se reduce la población, se modifica el contexto o se ajusta el alcance de la pregunta. Estas simulaciones ayudan a identificar versiones más manejables sin perder necesariamente el núcleo del problema. Sin embargo, reducir exigencias operativas no siempre mejora la investigación. Una pregunta demasiado simplificada puede dejar de responder a la brecha original, por lo que cada ajuste debe equilibrar factibilidad, relevancia y consistencia conceptual.

La evaluación mediante inteligencia artificial adquiere mayor rigor cuando funciona como mecanismo de contraste y no como certificación automática de calidad. Gao et al. (2023) permiten advertir que la plausibilidad formal de una respuesta generada no sustituye su revisión científica. Una pregunta puede considerarse suficientemente sólida cuando presenta claridad lingüística, precisión conceptual, delimitación apropiada, viabilidad operativa y coherencia con el problema y el enfoque elegido. Las herramientas inteligentes pueden detectar debilidades, producir alternativas y facilitar comparaciones, pero la validación definitiva requiere juicio metodológico. Su mayor aporte consiste en ampliar la capacidad de revisión antes de consolidar decisiones difíciles de modificar posteriormente.

2.7 Refinamiento iterativo de preguntas científicas mediante herramientas inteligentes

El refinamiento iterativo de preguntas científicas consiste en revisar y ajustar sucesivamente una formulación hasta alcanzar mayor claridad, precisión, coherencia y viabilidad. Garzón et al. (2025) permiten situar este proceso como una interacción progresiva en la que las herramientas inteligentes pueden proponer modificaciones sobre aspectos específicos de una pregunta. La ventaja no radica en producir numerosas versiones, sino en comparar sus efectos sobre el sentido investigativo. Cada ajuste debe responder a una debilidad identificada previamente, evitando cambios puramente estilísticos que no mejoren la correspondencia entre la interrogante, el problema de investigación y las condiciones metodológicas previstas.

Una primera iteración puede centrarse en la claridad lingüística. Panfilova et al. (2026) permiten considerar el uso de inteligencia artificial para revisar estructuras complejas y generar alternativas de redacción. El investigador puede solicitar que se identifiquen ambigüedades, términos demasiado amplios o construcciones que admitan varias interpretaciones. A partir de esta revisión, la pregunta puede simplificarse sin perder contenido científico. El criterio no debe ser reducir palabras de manera automática, sino eliminar aquello que dificulta comprender el núcleo de la interrogante. Una versión más breve resulta útil únicamente cuando conserva los conceptos, relaciones y límites necesarios para orientar adecuadamente el estudio.

Una segunda fase puede orientarse hacia la precisión conceptual. Williams y Ingleby (2025) permiten relacionar la formulación de preguntas con la necesidad de conservar coherencia entre el tipo de fenómeno estudiado y la forma en que se pretende comprenderlo. Las herramientas inteligentes pueden comparar términos alternativos y mostrar cómo cambia el sentido cuando se sustituyen expresiones como efecto, relación, experiencia o percepción. Este contraste ayuda a detectar formulaciones que introducen supuestos no previstos. La revisión humana sigue siendo indispensable, porque una palabra lingüísticamente adecuada puede alterar la lógica epistemológica o metodológica de la pregunta si se emplea fuera del enfoque correspondiente.

El refinamiento también debe revisar el nivel de delimitación alcanzado. Zhang et al. (2025) permiten considerar la importancia de ajustar progresivamente población, contexto, fenómeno y alcance hasta obtener una interrogante suficientemente específica. Una pregunta inicial puede ser demasiado amplia y requerir varias rondas de reducción; otra puede estar excesivamente restringida y perder relevancia analítica. La inteligencia artificial puede generar versiones con distintos niveles de delimitación para facilitar su comparación. Esta estrategia permite observar qué información se conserva o elimina en cada variante. La decisión adecuada será aquella que mantenga el núcleo del problema sin incorporar límites arbitrarios o innecesarios.

Otra iteración debe centrarse en la viabilidad de la pregunta. Castillo (2023) permite situar el uso crítico de inteligencia artificial como apoyo para anticipar restricciones antes de consolidar decisiones investigativas. La herramienta puede ayudar a identificar qué datos, participantes, recursos o procedimientos serían necesarios para responder una formulación determinada. Si las exigencias resultan incompatibles con las condiciones del proyecto, pueden explorarse ajustes en alcance, población o contexto. El refinamiento no debe convertir la viabilidad en el único criterio dominante, porque simplificar excesivamente una pregunta puede hacerla

operativamente manejable, pero científicamente menos relevante o insuficiente frente al problema originalmente planteado.

La iteración adquiere mayor valor cuando cada nueva versión se compara explícitamente con la anterior. Garzón et al. (2025) permiten comprender que la revisión asistida puede organizarse como un proceso de mejora incremental en lugar de una sucesión desordenada de reformulaciones. El investigador puede solicitar al sistema que explique qué cambió, qué ambigüedad se redujo o qué implicación metodológica aparece con la modificación. Esta comparación favorece decisiones más transparentes y evita aceptar una nueva versión únicamente porque suena más académica. El refinamiento debe conservar trazabilidad sobre las razones que justifican cada cambio introducido en la pregunta científica.

También resulta útil someter una misma pregunta a distintos tipos de revisión. Panfilova et al. (2026) permiten situar las herramientas inteligentes como recursos capaces de responder a instrucciones específicas dentro del proceso de investigación. Una consulta puede evaluar claridad; otra, coherencia con el enfoque; una tercera, amplitud; y otra, viabilidad. Separar estos criterios reduce el riesgo de obtener valoraciones globales poco informativas. Además, permite detectar tensiones entre dimensiones: una modificación puede mejorar precisión, pero reducir claridad; otra puede aumentar viabilidad, aunque debilitar el alcance. La versión final debe equilibrar estos criterios sin asumir que todos pueden maximizarse simultáneamente.

El refinamiento iterativo también puede incluir la evaluación de alternativas construidas desde enfoques diferentes. Williams y Ingleby (2025) permiten comprender que la forma de preguntar debe corresponder al tipo de conocimiento que se pretende producir. Una herramienta inteligente puede reformular una interrogante desde una lógica descriptiva, relacional, interpretativa o integrada, facilitando la comparación de sus implicaciones. Este ejercicio no busca cambiar arbitrariamente el enfoque del estudio, sino comprobar si la formulación seleccionada representa realmente la intención investigativa. Cuando una versión alternativa parece más coherente, debe revisarse también su compatibilidad con los antecedentes, objetivos y recursos disponibles.

El refinamiento iterativo se completa cuando nuevas modificaciones dejan de aportar mejoras sustantivas y la pregunta mantiene estabilidad conceptual y metodológica. Zhang et al. (2025) permiten vincular esta revisión progresiva con la necesidad de conservar coherencia entre formulación y proceso de investigación. Las herramientas inteligentes pueden acelerar la

producción de alternativas, detectar problemas y facilitar contrastes, pero no establecen por sí mismas el punto de cierre. Una pregunta suficientemente refinada expresa con claridad qué se investigará, mantiene límites justificables y puede responderse mediante procedimientos compatibles con el proyecto. La iteración funciona, así como mecanismo de control antes de avanzar hacia decisiones metodológicas más específicas.

Capítulo 3.

Simulación de decisiones metodológicas antes del estudio

Génesis Gissell Cabrera Salazar



3.1 Selección asistida del enfoque de investigación

La selección del enfoque de investigación constituye una decisión metodológica central, porque determina la lógica con la que se abordará el problema, el tipo de evidencia que se buscará y la forma de interpretar los resultados. Falcón y Serpa (2021) permiten distinguir entre enfoques cuantitativos, cualitativos y mixtos a partir de sus propósitos y procedimientos. La inteligencia artificial puede apoyar esta elección mediante la comparación de alternativas metodológicas derivadas del problema y de la pregunta científica. Su utilidad reside en hacer visibles las implicaciones de cada opción, sin sustituir el juicio del investigador ni convertir el enfoque en una recomendación automática.

El enfoque cuantitativo resulta pertinente cuando el problema requiere medir variables, estimar frecuencias, comparar grupos o examinar relaciones mediante datos estructurados. Bautista (2022) permite vincular esta elección con una lógica orientada a la medición y al análisis sistemático de información susceptible de cuantificación. Una herramienta inteligente puede revisar la formulación de la pregunta y señalar si contiene elementos compatibles con este enfoque, como variables claramente definidas, relaciones comparables o poblaciones delimitadas. Sin embargo, la presencia de términos numéricos o estadísticos no basta para justificar la elección si el problema demanda una comprensión más profunda de significados, procesos o experiencias.

El enfoque cualitativo responde a problemas donde interesa comprender experiencias, interpretaciones, prácticas, significados o procesos situados. Falcón y Serpa (2021) permiten reconocer que esta lógica no se organiza principalmente alrededor de variables medibles, sino de categorías y fenómenos que requieren análisis contextual. La inteligencia artificial puede ayudar a identificar si la pregunta presenta una orientación interpretativa y comparar posibles estrategias de abordaje. Esta asistencia resulta útil para detectar incoherencias, por ejemplo, cuando una pregunta pretende comprender experiencias, pero se acompaña de una propuesta exclusivamente basada en medición. La selección debe conservar correspondencia entre naturaleza del problema y tipo de conocimiento esperado.

El enfoque mixto adquiere pertinencia cuando el problema exige integrar evidencia cuantitativa y cualitativa para alcanzar una comprensión más amplia. Callirgos et al. (2022) permiten considerar la necesidad de mantener coherencia entre los distintos componentes del diseño metodológico. Una herramienta inteligente puede simular cómo cambiaría el estudio si se

combinaran mediciones con información interpretativa y qué función cumpliría cada componente. Esta exploración permite valorar si la integración aporta realmente al problema o si únicamente aumenta la complejidad del proyecto. Elegir un enfoque mixto requiere justificar qué información adicional se obtiene mediante la combinación y cómo se relacionarán los resultados producidos.

La selección asistida puede comenzar con un análisis estructurado de la pregunta de investigación. Cedeño et al. (2024) permiten situar la inteligencia artificial como apoyo dentro de tareas investigativas que exigen organización y revisión de decisiones. El sistema puede identificar verbos, conceptos, relaciones y unidades de análisis presentes en la pregunta y asociarlos con posibles lógicas metodológicas. Esta lectura inicial sirve como orientación, pero no debe asumirse como clasificación definitiva. Una misma palabra puede adquirir sentidos distintos según el contexto científico, por lo que el enfoque debe decidirse considerando también antecedentes, objetivos y naturaleza de la evidencia necesaria.

Otro procedimiento consiste en solicitar a la herramienta que genere escenarios metodológicos alternativos para un mismo problema. Díaz (2024) permite considerar la inteligencia artificial como recurso para explorar posibilidades dentro del proceso académico. El investigador puede comparar qué información produciría un diseño cuantitativo, qué aportaría uno cualitativo y qué condiciones requeriría una integración mixta. Esta simulación ayuda a visualizar consecuencias antes de comprometer recursos. El propósito no consiste en elegir la alternativa más extensa o sofisticada, sino aquella que responda con mayor coherencia a la pregunta y permita obtener evidencia suficiente dentro de las condiciones reales del proyecto.

La selección del enfoque también debe considerar los antecedentes revisados. Bautista (2022) permite relacionar las decisiones metodológicas con el conocimiento previamente acumulado sobre el fenómeno. Si la literatura muestra una amplia tradición de medición, puede ser pertinente explorar relaciones todavía no examinadas o introducir una aproximación interpretativa cuando existan preguntas abiertas sobre experiencias y procesos. La inteligencia artificial puede organizar los enfoques predominantes en los antecedentes y mostrar concentraciones o ausencias metodológicas. Este análisis no obliga a elegir el enfoque menos utilizado, pero permite valorar si una perspectiva diferente aportaría conocimiento relevante o si carecería de justificación suficiente.

Las posibilidades de acceso a datos constituyen otro criterio de selección. Callirgos et al. (2022) permiten comprender que la coherencia metodológica también depende de condiciones operativas capaces de sostener el diseño propuesto. Una pregunta puede sugerir inicialmente un enfoque determinado, pero resultar difícil de ejecutar si no existen participantes accesibles, registros suficientes o posibilidades reales de obtener la información requerida. La inteligencia artificial puede ayudar a comparar necesidades de datos entre alternativas y a identificar posibles restricciones. Esta función permite anticipar dificultades, aunque la viabilidad debe confirmarse mediante información concreta sobre el contexto y los recursos disponibles.

Figura 5

¿Qué enfoque de investigación debería seleccionarse?

Enfoque Cuantitativo


Adecuado para medir variables, estimar frecuencias y examinar relaciones con datos estructurados.

Enfoque Cualitativo

Ideal para comprender experiencias, interpretaciones y procesos situados.

Enfoque Mixto

Beneficioso para integrar evidencia cuantitativa y cualitativa para una comprensión más amplia.



Nota. La figura sintetiza la selección del enfoque metodológico según el tipo de evidencia requerida y la finalidad analítica de la investigación.

La herramienta también puede utilizarse para detectar contradicciones entre enfoque, objetivos y técnicas previstas. Cedeño et al. (2024) permiten situar esta revisión como parte del apoyo que la inteligencia artificial puede brindar en la construcción metodológica. Si una propuesta declara un enfoque cualitativo, pero formula objetivos centrados exclusivamente en medir relaciones, existe una inconsistencia que debe revisarse. Lo mismo ocurre cuando un enfoque cuantitativo se acompaña de preguntas esencialmente interpretativas. El sistema puede señalar

estas tensiones y sugerir ajustes, pero corresponde al investigador decidir si debe modificarse el enfoque, reformularse la pregunta o reorganizarse el diseño.

La selección asistida requiere evitar decisiones basadas únicamente en patrones lingüísticos. Díaz (2024) permite advertir que las herramientas inteligentes funcionan mejor cuando reciben suficiente contexto y cuando sus respuestas son sometidas a revisión. Una pregunta que contiene la expresión “qué relación existe” suele sugerir una orientación cuantitativa, pero su interpretación definitiva depende de cómo se conceptualicen los fenómenos y de qué tipo de evidencia se pretenda producir. Por ello, la inteligencia artificial debe emplearse para contrastar opciones y hacer explícitas sus consecuencias, no para clasificar automáticamente proyectos mediante palabras clave aisladas de su fundamento teórico y metodológico.

La elección del enfoque se consolida cuando existe correspondencia entre problema, pregunta, objetivos, antecedentes, evidencia requerida y condiciones de ejecución. Falcón y Serpa (2021) permiten comprender que cada enfoque responde a una lógica distinta y que su selección debe justificarse desde el propósito científico del estudio. La inteligencia artificial aporta valor cuando facilita comparaciones, simula escenarios y detecta inconsistencias antes de avanzar hacia el diseño definitivo. Su intervención debe entenderse como apoyo a una decisión metodológica argumentada. El enfoque adecuado será aquel que permita responder la pregunta con procedimientos coherentes, viables y compatibles con la naturaleza del fenómeno investigado.

3.2 Comparación de diseños de investigación mediante escenarios simulados

La comparación de diseños de investigación mediante escenarios simulados permite anticipar cómo distintas decisiones metodológicas podrían modificar la producción y la interpretación de evidencia antes de ejecutar el estudio. Krenn et al. (2022) permiten sostener que el valor de la inteligencia artificial en ciencia no depende únicamente de su capacidad predictiva, sino también de su contribución a la comprensión de mecanismos y estructuras conceptuales. Aplicada al diseño metodológico, esta perspectiva implica comparar alternativas no solo por eficiencia, sino por su capacidad para responder la pregunta científica, producir resultados interpretables y mantener coherencia entre problema, evidencia y explicación.

Un escenario simulado puede representar de manera anticipada las consecuencias de optar por un diseño descriptivo, correlacional, experimental, longitudinal u otra alternativa compatible con el problema. La utilidad de este ejercicio consiste en identificar qué tipo de información

produciría cada diseño, qué relaciones permitiría examinar y cuáles inferencias resultarían justificables. Hua et al. (2023) destacan que los sistemas inteligentes aplicados a problemas científicos complejos requieren considerar estabilidad, calidad de los datos, coherencia teórica y aplicabilidad. Por ello, la simulación metodológica debe evaluar múltiples criterios y no reducir la comparación a cuál diseño parece producir resultados más precisos o técnicamente sofisticados.

La inteligencia artificial puede facilitar esta comparación al modificar sistemáticamente determinados componentes del proyecto mientras mantiene constantes otros. Por ejemplo, puede explorarse cómo cambia la capacidad de respuesta de un estudio al variar temporalidad, control de condiciones, tipo de observación o secuencia de recolección. Hartung (2025) permite comprender que la integración de inteligencia artificial y automatización amplía las posibilidades para explorar cursos alternativos dentro del trabajo científico. Este enfoque favorece una evaluación previa de consecuencias, pero exige límites claros para evitar que la generación automática de escenarios sustituya el análisis metodológico que determina cuáles alternativas son realmente compatibles con el problema investigado.

Tabla 7
Comparación analítica de diseños mediante escenarios simulados

Dimensión de comparación	Pregunta de simulación	Aspecto que debe examinarse	Riesgo de una elección inadecuada
Capacidad de respuesta	¿Qué evidencia produciría cada diseño?	Correspondencia con la pregunta científica	Obtener datos insuficientes para responderla
Temporalidad	¿Qué cambia si la observación ocurre una vez o en varios momentos?	Posibilidad de analizar variaciones en el tiempo	Inferir cambios sin evidencia temporal
Control	¿Qué nivel de control requiere cada alternativa?	Capacidad para sostener determinadas inferencias	Atribuir causalidad sin condiciones adecuadas
Interpretabilidad	¿Qué explicación permite construir cada diseño?	Relación entre resultados y comprensión del fenómeno	Priorizar desempeño sin explicación
Operatividad	¿Qué recursos y procesos demanda cada diseño?	Condiciones reales de ejecución	Diseñar un estudio difícil de implementar

Dimensión de comparación	Pregunta de simulación	Aspecto que debe examinarse	Riesgo de una elección inadecuada
Validación	¿Cómo se comprobarían los resultados obtenidos?	Coherencia, estabilidad y contrastación	Aceptar resultados sin mecanismos de verificación

Nota. Elaboración propia. La matriz orienta la comparación previa de alternativas metodológicas según sus consecuencias para el estudio.

La simulación resulta particularmente útil para examinar diferencias entre diseños que inicialmente parecen igualmente adecuados. Dos alternativas pueden responder a una misma temática, pero producir niveles de evidencia muy diferentes. Fushimi et al. (2025) muestran que los sistemas científicos automatizados pueden modificar condiciones, registrar decisiones y desarrollar ciclos experimentales de manera estructurada bajo mecanismos de supervisión. Esta lógica puede trasladarse al análisis previo de diseños: cada alternativa se representa como una secuencia de decisiones y consecuencias que puede ser contrastada con otras. La comparación permite identificar qué condiciones deberían mantenerse controladas y cuáles podrían introducir variaciones difíciles de interpretar posteriormente.

Los escenarios también pueden utilizarse para anticipar problemas derivados de la secuencia metodológica. En estudios con varias fases, el orden en que se recolecta, procesa y analiza la información puede modificar las decisiones posteriores. Tobias y Wahab (2025) permiten observar esta lógica en laboratorios autónomos, donde planificación, ejecución, análisis y ajuste forman ciclos conectados. En el diseño de proyectos, simular esas secuencias ayuda a prever qué ocurriría si una fase produce información insuficiente o contradictoria. Este ejercicio permite identificar dependencias entre etapas y evita diseñar procedimientos donde una decisión temprana comprometa de forma irreversible la interpretación final del estudio.

Otra dimensión importante corresponde a la interpretabilidad. Un diseño puede generar grandes cantidades de información y, aun así, ofrecer escasa capacidad para explicar el fenómeno que originó la investigación. Krenn et al. (2022) advierten que la precisión predictiva no equivale necesariamente a comprensión científica. Esta distinción resulta útil al comparar escenarios metodológicos, porque obliga a preguntar no solo qué resultados pueden obtenerse, sino qué significan y qué tipo de inferencias permiten construir. La inteligencia artificial puede mostrar diferencias entre alternativas, pero el investigador debe valorar cuál diseño produce evidencia compatible con la explicación o comprensión buscada y no únicamente con el procesamiento disponible.

La simulación metodológica debe incorporar también escenarios adversos. Hartung (2025) destaca la necesidad de establecer límites operativos, mecanismos de seguridad y posibilidades de interrupción cuando los sistemas automatizados producen resultados inesperados. Trasladado al diseño de investigación, esto implica preguntar qué ocurriría si disminuye la participación, falla una fuente de datos, aparecen resultados inconsistentes o determinadas condiciones no pueden mantenerse. La inteligencia artificial puede contribuir a representar estas contingencias y comparar respuestas posibles. El objetivo no es predecir exactamente lo que sucederá, sino identificar vulnerabilidades del diseño antes de que comprometan la ejecución o reduzcan la calidad de la evidencia.

La comparación también debe considerar la trazabilidad de las decisiones. Fushimi et al. (2025) muestran que los entornos experimentales automatizados requieren registros, controles y validaciones independientes para mantener confiabilidad durante ciclos sucesivos. En una simulación metodológica, cada modificación del diseño debería quedar asociada con la razón que la justifica y con las consecuencias previstas. Este registro permite saber por qué una alternativa fue descartada y otra conservada. La inteligencia artificial puede facilitar la organización de estos contrastes, pero la documentación final debe permitir reconstruir el razonamiento metodológico sin depender exclusivamente de las recomendaciones producidas por la herramienta.

Un riesgo específico aparece cuando la automatización amplifica errores iniciales. Tobias y Wahab (2025) señalan que los sistemas autónomos pueden acelerar la exploración científica, aunque también pueden propagar errores a través de ciclos conectados de decisión. En la comparación de diseños, una premisa incorrecta sobre población, variables o causalidad podría mantenerse y reproducirse en todos los escenarios generados. Por ello, antes de simular alternativas debe revisarse la calidad de los supuestos de entrada. La inteligencia artificial puede comparar diseños de manera consistente, pero esa consistencia pierde valor si todos parten de una interpretación metodológica equivocada o de información insuficientemente comprobada.

La comparación mediante escenarios simulados aporta mayor valor cuando permite anticipar consecuencias, restricciones y posibilidades interpretativas antes de seleccionar un diseño definitivo. Hua et al. (2023) permiten sostener que la evaluación de sistemas científicos complejos requiere considerar dimensiones que exceden la precisión, entre ellas coherencia, estabilidad y aplicabilidad. En consecuencia, el diseño metodológico más adecuado no es

necesariamente el más complejo ni el que incorpora mayor automatización. Debe ser aquel que responda con mayor consistencia a la pregunta científica, permita producir evidencia verificable y mantenga una relación razonable entre capacidad explicativa, condiciones operativas y mecanismos de validación.

3.3 Simulación de alternativas para definir población y muestra

La definición de población y muestra condiciona el alcance de los resultados, la posibilidad de generalización y la coherencia entre la pregunta de investigación y la evidencia obtenida. Falcón y Serpa (2021) permiten situar esta decisión dentro de la lógica metodológica que articula enfoque, diseño y unidades de análisis. La inteligencia artificial puede apoyar esta etapa mediante la simulación de escenarios alternativos en los que varían población objetivo, criterios de inclusión, tamaño muestral o modalidad de selección. Su función consiste en anticipar consecuencias metodológicas de distintas opciones, sin sustituir los procedimientos estadísticos o técnicos necesarios para determinar una muestra.

Una primera simulación puede centrarse en la delimitación de la población objetivo. Cedeño et al. (2024) permiten considerar la inteligencia artificial como apoyo para organizar información y comparar alternativas dentro del diseño de investigación. A partir de una descripción del problema, la herramienta puede ayudar a distinguir entre población general, población accesible y posibles subgrupos relevantes. Este ejercicio permite detectar formulaciones excesivamente amplias o poco compatibles con el contexto real del estudio. No obstante, la delimitación final debe responder al problema científico y no a la conveniencia operativa de trabajar con el grupo más fácil de localizar.

La simulación también puede utilizarse para examinar cómo cambian las características del estudio cuando se modifican los criterios de inclusión y exclusión. Posso et al. (2025) permiten relacionar estas decisiones con la necesidad de mantener coherencia entre participantes, objetivos e instrumentos. Un criterio demasiado restrictivo puede reducir la diversidad de la muestra y limitar el alcance de los resultados, mientras que uno excesivamente amplio puede introducir heterogeneidad difícil de interpretar. La inteligencia artificial puede comparar estos escenarios y mostrar posibles efectos sobre la composición de la muestra, pero corresponde al investigador justificar cada criterio en función del fenómeno y del diseño seleccionado.

Otra posibilidad consiste en comparar modalidades de muestreo antes de elegir una estrategia definitiva. En estudios cuantitativos, pueden evaluarse escenarios con procedimientos

probabilísticos o no probabilísticos; en diseños cualitativos, la selección puede responder a criterios de pertinencia, experiencia o saturación. Falcón y Serpa (2021) permiten comprender que estas decisiones dependen del enfoque y del propósito investigativo. La inteligencia artificial puede organizar ventajas, limitaciones y requerimientos de cada alternativa, facilitando una primera comparación. Sin embargo, no debe recomendar un tipo de muestreo ignorando las condiciones reales de acceso, marco muestral, recursos disponibles o naturaleza de la pregunta científica.

La estimación del tamaño muestral requiere especial cautela. Semmelrock et al. (2025) permiten advertir que las herramientas automatizadas pueden apoyar decisiones metodológicas, pero sus resultados dependen de los supuestos y datos utilizados. La inteligencia artificial puede simular escenarios con diferentes tamaños de muestra y mostrar cómo varían aspectos como precisión esperada, cobertura o carga operativa. No obstante, estas simulaciones no reemplazan los cálculos estadísticos requeridos en estudios cuantitativos ni los criterios metodológicos propios de diseños cualitativos. La determinación final debe realizarse con procedimientos técnicamente adecuados y con parámetros explícitos, no mediante una cifra sugerida de forma automática.

La representación de subgrupos constituye otra dimensión que puede explorarse mediante escenarios simulados. Kapoor y Narayanan (2023) permiten considerar los riesgos de obtener conclusiones poco confiables cuando las decisiones analíticas no contemplan adecuadamente la estructura de los datos. Si una población incluye grupos con características distintas, puede ser necesario valorar si la muestra permitirá analizarlos de manera suficiente. La inteligencia artificial puede ayudar a visualizar distribuciones hipotéticas y detectar posibles desequilibrios. Esta función es útil para anticipar problemas de representación, aunque la decisión sobre estratificación, cuotas u otros procedimientos debe responder a objetivos previamente definidos y no a patrones generados sin sustento metodológico.

Los escenarios también pueden incorporar pérdidas de participantes o datos incompletos. Posso et al. (2025) permiten relacionar la planificación de la muestra con las condiciones reales de aplicación de instrumentos y recolección de información. Una simulación puede mostrar qué ocurriría si parte de la muestra inicialmente prevista no participa, abandona el estudio o entrega registros inutilizables. Esta anticipación ayuda a reconocer vulnerabilidades y a planificar márgenes razonables dentro del diseño. Sin embargo, cualquier ajuste debe evitar inflar

arbitrariamente el tamaño muestral o modificar criterios después de observar resultados, porque ello puede comprometer la consistencia del procedimiento.

La calidad de los datos utilizados para construir escenarios es otro aspecto decisivo. Kapoor y Narayanan (2023) advierten sobre problemas metodológicos que pueden surgir cuando los análisis se sustentan en datos o particiones inadecuadas. Aplicado a la simulación de población y muestra, esto implica que una herramienta no puede producir recomendaciones confiables si recibe estimaciones erróneas sobre tamaño poblacional, distribución de características o tasas de participación. Los escenarios deben construirse con información verificable y supuestos explícitos. La inteligencia artificial puede facilitar cálculos comparativos o representar alternativas, pero no corrige automáticamente errores presentes en los datos de entrada.

La simulación resulta especialmente útil cuando se comparan consecuencias operativas de varias alternativas. Cedeño et al. (2024) permiten situar la inteligencia artificial como recurso para estructurar decisiones dentro del proyecto. Una muestra más amplia puede aumentar exigencias de tiempo, acceso y procesamiento, mientras que una más pequeña puede reducir capacidad analítica o representatividad. La herramienta puede organizar estas tensiones y mostrar cómo cambia el diseño bajo distintos supuestos. El propósito no consiste en buscar la opción menos costosa, sino en identificar una configuración que mantenga correspondencia entre calidad de la evidencia, posibilidades de ejecución y objetivos científicos.

En estudios que emplean procedimientos automatizados o modelos predictivos, la composición de la muestra puede generar efectos adicionales. Semmelrock et al. (2025) permiten considerar la importancia de evaluar el comportamiento de sistemas automatizados bajo condiciones diversas y no asumir que su desempeño será estable en todos los grupos. Una simulación puede explorar cómo ciertas distribuciones poblacionales afectan el análisis o la interpretación posterior. Esto resulta relevante cuando existen grupos minoritarios o categorías poco representadas. La herramienta puede señalar escenarios problemáticos, pero la solución requiere decisiones metodológicas conscientes sobre inclusión, balance y alcance de las conclusiones.

El uso de inteligencia artificial para simular alternativas también debe evitar una falsa sensación de exactitud. Una representación numérica o gráfica puede parecer precisa, aunque dependa de supuestos inciertos. Kapoor y Narayanan (2023) permiten advertir que la robustez metodológica exige revisar cómo se construyen y validan los procesos analíticos. Por ello, los

escenarios deben interpretarse como ejercicios condicionales: muestran qué podría ocurrir si se cumplen determinadas condiciones, no predicen con certeza el comportamiento real de la población. Esta distinción resulta fundamental para evitar que una simulación termine convirtiéndose en una justificación automática de decisiones todavía no verificadas.

La simulación de alternativas para definir población y muestra adquiere valor cuando permite anticipar restricciones, comparar opciones y hacer explícitos los supuestos antes de recolectar datos. Falcón y Serpa (2021) permiten mantener la decisión vinculada al enfoque y al diseño, mientras que las herramientas inteligentes pueden apoyar la exploración de escenarios posibles. El resultado esperado no es una muestra determinada automáticamente, sino una decisión metodológica mejor informada. La inteligencia artificial puede mostrar consecuencias de distintos criterios, tamaños o estrategias de selección, pero la definición definitiva debe sustentarse en procedimientos estadísticos o metodológicos apropiados y en condiciones reales del estudio.

3.4 Evaluación previa de técnicas de recolección de datos

La evaluación previa de las técnicas de recolección de datos permite determinar si los procedimientos previstos producirán información suficiente, pertinente y coherente con la pregunta de investigación. Bautista (2022) permite relacionar esta decisión con el enfoque metodológico, el tipo de fenómeno estudiado y la naturaleza de la evidencia requerida. La inteligencia artificial puede apoyar esta valoración mediante la comparación anticipada de técnicas como cuestionarios, entrevistas, observación o revisión documental. Su utilidad consiste en identificar ventajas, restricciones y posibles incompatibilidades antes de iniciar el trabajo de campo, evitando seleccionar instrumentos únicamente por familiaridad, facilidad de aplicación o disponibilidad tecnológica.

Una técnica adecuada debe guardar correspondencia directa con el tipo de información que se necesita obtener. Posso et al. (2025) permiten vincular esta elección con la articulación entre objetivos, variables o categorías e instrumentos de investigación. Si el propósito consiste en medir percepciones mediante respuestas estructuradas, un cuestionario puede resultar pertinente; si se busca comprender experiencias, una entrevista puede ofrecer información más profunda. La inteligencia artificial puede ayudar a contrastar estas alternativas y señalar qué tipo de datos produciría cada una. Sin embargo, la decisión final debe sustentarse en la lógica del estudio y no en una recomendación generada de forma automática.

La evaluación previa también debe considerar la capacidad de cada técnica para representar adecuadamente el fenómeno. Williams e Ingleby (2025) permiten comprender que, especialmente en investigaciones cualitativas, la selección del procedimiento de recolección condiciona la profundidad y riqueza de la información obtenida. Una entrevista estructurada, semiestructurada o abierta puede producir distintos niveles de detalle y flexibilidad. Mediante escenarios simulados, la inteligencia artificial puede mostrar cómo cambiaría la información esperada según el grado de apertura de las preguntas. Esta comparación permite anticipar restricciones, aunque la pertinencia de cada modalidad depende del propósito analítico y de las características de los participantes.

Las herramientas inteligentes pueden utilizarse para simular el funcionamiento de una técnica antes de aplicarla. Panfilova et al. (2026) permiten situar esta posibilidad dentro de procesos investigativos donde la inteligencia artificial interviene como apoyo para revisar y perfeccionar procedimientos. El investigador puede proporcionar preguntas, instrucciones o secuencias de aplicación y solicitar que se identifiquen ambigüedades, redundancias o puntos que podrían generar respuestas insuficientes. Este ejercicio no sustituye una prueba piloto con participantes reales, pero permite detectar problemas evidentes antes de esa etapa. La simulación funciona, así como un filtro preliminar que contribuye a mejorar la preparación del trabajo de campo.

La observación requiere una evaluación diferente porque depende de la capacidad para registrar conductas, eventos o condiciones de forma sistemática. Keadle et al. (2024) permiten considerar el uso de procedimientos tecnológicos y automatizados para apoyar la captura y clasificación de determinados comportamientos. La inteligencia artificial puede contribuir a anticipar categorías observacionales, revisar criterios de codificación o explorar situaciones en las que un protocolo produciría registros ambiguos. Sin embargo, la automatización no elimina problemas relacionados con contexto, interpretación o calidad del registro. Toda técnica observacional necesita criterios claros que permitan distinguir qué será observado, cómo se registrará y bajo qué condiciones.

Tabla 8*Matriz de evaluación previa de técnicas de recolección de datos*

Técnica	Tipo de información esperada	Aspecto que puede evaluarse con inteligencia artificial	Riesgo que debe controlarse
Cuestionario	Respuestas estructuradas y comparables	Claridad, redundancia y correspondencia de ítems	Preguntas ambiguas o poco pertinentes
Entrevista	Experiencias, significados y explicaciones	Secuencia, apertura y profundidad de preguntas	Respuestas superficiales o inducidas
Observación	Conductas, eventos y condiciones registrables	Categorías y criterios preliminares de codificación	Registros inconsistentes
Revisión documental	Información contenida en registros y textos	Clasificación y extracción preliminar	Selección incompleta o descontextualizada
Técnicas combinadas	Evidencia procedente de fuentes diferentes	Compatibilidad y complementariedad entre procedimientos	Duplicación o integración deficiente

Nota. Elaboración propia. La matriz orienta la revisión anticipada de la correspondencia entre técnica, información esperada y posibles limitaciones.

La tabla muestra que la evaluación previa debe centrarse en la función de cada técnica y no únicamente en sus características operativas. Posso et al. (2025) permiten sostener que la elección de procedimientos necesita conservar coherencia con aquello que se pretende medir, describir o comprender. Dos técnicas pueden parecer igualmente viables y, sin embargo, producir evidencia muy distinta. La inteligencia artificial puede facilitar esa comparación al representar posibles respuestas, registros o dificultades de aplicación. El criterio decisivo consiste en establecer cuál procedimiento permite obtener información más adecuada para responder la pregunta sin introducir exigencias innecesarias o incompatibles con el diseño.

La factibilidad operativa constituye otra dimensión que debe examinarse antes de seleccionar una técnica. Bautista (2022) permite relacionar esta valoración con condiciones de acceso, tiempo, recursos y características de los participantes. Una entrevista puede ofrecer mayor profundidad, pero requerir condiciones logísticas difíciles de sostener; un cuestionario puede ampliar cobertura, aunque limitar la riqueza de ciertas respuestas. La inteligencia artificial puede organizar estas diferencias y ayudar a construir escenarios comparativos. No obstante, la factibilidad no debe imponerse sobre la calidad metodológica, porque elegir únicamente la

técnica más sencilla puede reducir la capacidad del estudio para responder de manera adecuada al problema planteado.

También resulta necesario anticipar posibles fuentes de sesgo derivadas de la técnica elegida. Panfilova et al. (2026) permiten considerar la revisión asistida como un mecanismo para detectar formulaciones o secuencias que podrían orientar indebidamente las respuestas. En cuestionarios y entrevistas, determinadas expresiones pueden inducir posiciones o favorecer respuestas socialmente esperadas. En observación, categorías mal definidas pueden producir registros inconsistentes. La inteligencia artificial puede señalar estos riesgos mediante simulaciones o análisis de contenido, pero la evaluación debe complementarse con revisión metodológica y pruebas empíricas. Una técnica aparentemente clara puede comportarse de forma distinta cuando se utiliza con participantes reales.

La combinación de técnicas requiere comprobar que cada una aporte información diferenciada. Williams e Ingleby (2025) permiten comprender que la integración de distintas fuentes tiene valor cuando responde a una lógica analítica y no cuando se acumulan procedimientos sin una función definida. La inteligencia artificial puede ayudar a comparar qué información produciría cada técnica y detectar posibles redundancias. Si dos procedimientos recogen prácticamente el mismo tipo de evidencia, su combinación puede incrementar trabajo sin mejorar la comprensión del fenómeno. Por el contrario, técnicas complementarias pueden ampliar el análisis cuando cada una responde a una dimensión distinta de la pregunta y existe un criterio claro para relacionar sus resultados.

La evaluación previa de técnicas de recolección alcanza su mayor utilidad cuando permite detectar incompatibilidades antes de comenzar la obtención de datos. Keadle et al. (2024) permiten situar las herramientas tecnológicas como apoyo para estructurar y revisar procedimientos de captura y clasificación de información. La inteligencia artificial puede simular aplicaciones, comparar alternativas y señalar posibles problemas de claridad, cobertura o consistencia. Estas funciones ayudan a fortalecer la planificación, pero no sustituyen la prueba piloto, la validación de instrumentos ni la revisión del comportamiento real de la técnica. La elección definitiva debe responder a la pregunta científica, al enfoque y a las condiciones concretas del estudio.

3.5 Simulación de procedimientos para el desarrollo del estudio

La simulación de procedimientos permite representar anticipadamente cómo se desarrollarán las distintas etapas de un estudio antes de iniciar su ejecución real. Hartung (2025) permite comprender esta posibilidad dentro de entornos científicos apoyados por automatización e inteligencia artificial, donde la planificación de secuencias, decisiones y controles adquiere especial importancia. En investigación, esta práctica puede utilizarse para revisar el orden de actividades, identificar dependencias entre fases y anticipar puntos críticos. Su valor no consiste en reproducir exactamente lo que ocurrirá, sino en examinar si el procedimiento previsto mantiene coherencia con el diseño, los recursos disponibles y los objetivos científicos establecidos.

Una primera simulación puede centrarse en la secuencia completa del estudio, desde el acceso al campo hasta el procesamiento final de la información. Fushimi et al. (2025) muestran que los sistemas científicos automatizados pueden estructurar ciclos de planificación, ejecución, registro y ajuste bajo condiciones controladas. Esta lógica resulta útil para representar procedimientos de investigación como cadenas de actividades conectadas. El investigador puede examinar qué tareas dependen de otras, dónde podrían producirse retrasos y cuáles decisiones deben tomarse antes de continuar. La simulación permite detectar secuencias poco realistas y reorganizarlas antes de comprometer participantes, recursos o datos.

También pueden simularse puntos de decisión dentro del procedimiento. Tobias y Wahab (2025) permiten observar que los entornos autónomos de investigación funcionan mediante ciclos donde los resultados de una etapa influyen en las acciones siguientes. Aplicado a un proyecto, esto permite anticipar qué hacer cuando una fase produce información insuficiente, aparecen datos inesperados o determinada condición metodológica no puede mantenerse. La inteligencia artificial puede generar escenarios alternativos y mostrar posibles rutas de respuesta. Sin embargo, estas rutas deben definirse de acuerdo con criterios previamente establecidos, evitando modificaciones improvisadas que alteren el diseño después de conocer resultados preliminares.

La simulación previa también facilita examinar la interacción entre participantes, instrumentos y procedimientos. Hua et al. (2023) permiten considerar que el desempeño de sistemas científicos complejos depende de múltiples dimensiones, entre ellas estabilidad, calidad de la información y coherencia con el contexto de aplicación. Un procedimiento aparentemente sencillo puede producir dificultades cuando se considera el tiempo requerido, la secuencia de instrucciones o la carga impuesta a los participantes. Mediante escenarios hipotéticos pueden

identificarse momentos donde aumente el riesgo de abandono, errores de aplicación o registros incompletos. Estas previsiones permiten ajustar el procedimiento antes de someterlo a una prueba real.

Otra aplicación consiste en representar el flujo de datos desde su generación hasta su análisis. Krenn et al. (2022) permiten destacar que la utilidad científica de sistemas inteligentes no debe evaluarse únicamente por resultados finales, sino también por su capacidad para contribuir a procesos comprensibles e interpretables. La simulación puede mostrar dónde se originan los datos, cómo serán registrados, qué transformaciones experimentarán y qué controles se aplicarán antes del análisis. Esta trazabilidad ayuda a detectar etapas donde podrían introducirse errores, pérdidas o modificaciones no documentadas. Un procedimiento robusto necesita conservar continuidad entre la evidencia original y los resultados posteriormente interpretados.

Los escenarios simulados pueden incorporar errores previsibles para comprobar la capacidad de respuesta del procedimiento. Hartung (2025) destaca la relevancia de establecer límites operativos y mecanismos de control ante comportamientos inesperados en sistemas automatizados. En un estudio, pueden representarse situaciones como fallas tecnológicas, pérdida de registros, baja participación o interrupciones durante la recolección. El objetivo no es anticipar todas las contingencias posibles, sino identificar aquellas capaces de comprometer aspectos centrales del diseño. La inteligencia artificial puede ayudar a explorar respuestas alternativas, siempre que las medidas previstas mantengan la integridad metodológica y no introduzcan cambios incompatibles con el protocolo original.

La simulación resulta igualmente pertinente para revisar procesos repetitivos. Fushimi et al. (2025) permiten comprender que los ciclos automatizados requieren protocolos consistentes para garantizar que cada iteración conserve condiciones comparables. En investigación, procedimientos como aplicación de instrumentos, observación, codificación o preparación de datos pueden repetirse muchas veces. Representarlos previamente permite comprobar si las instrucciones son suficientemente claras y si cada ejecución seguirá criterios equivalentes. Cuando existen diferencias injustificadas entre aplicaciones, la calidad de la evidencia puede verse afectada. La inteligencia artificial puede señalar inconsistencias en la secuencia, aunque la estandarización definitiva debe responder a las exigencias del diseño.

La coordinación temporal constituye otro componente susceptible de simulación. Tobias y Wahab (2025) permiten relacionar la planificación científica automatizada con la organización encadenada de tareas y decisiones. Un proyecto puede depender de autorizaciones, disponibilidad de participantes, aplicación de instrumentos, procesamiento y análisis en momentos específicos. La inteligencia artificial puede organizar estas dependencias y representar qué efectos tendría el retraso de una etapa sobre las siguientes. Esta función ayuda a identificar actividades críticas y márgenes de ajuste. No obstante, la simulación temporal debe basarse en condiciones reales y no en estimaciones excesivamente optimistas que oculten restricciones operativas previsibles.

La evaluación de procedimientos debe incluir también su capacidad para mantener condiciones comparables y producir registros consistentes. Hua et al. (2023) permiten advertir que la estabilidad constituye una dimensión relevante en sistemas científicos apoyados por inteligencia artificial. Si una misma actividad cambia sustancialmente entre participantes, momentos o responsables de aplicación, los datos obtenidos pueden reflejar diferencias del procedimiento y no únicamente del fenómeno estudiado. La simulación puede ayudar a identificar instrucciones ambiguas, decisiones discrecionales o etapas poco estandarizadas. Estas observaciones permiten fortalecer el protocolo antes de la ejecución, especialmente cuando participan varias personas o herramientas tecnológicas.

La inteligencia artificial puede utilizarse además para comparar versiones alternativas del mismo procedimiento. Krenn et al. (2022) permiten situar este análisis dentro de una lógica científica donde comprender las consecuencias de distintas configuraciones resulta tan importante como obtener resultados. El investigador puede modificar el orden de actividades, el número de controles, la frecuencia de observación o la forma de registrar información y examinar cómo cambia el funcionamiento general del estudio. Esta comparación facilita elegir una secuencia más coherente, pero no debería orientarse únicamente hacia la rapidez. Un procedimiento más eficiente puede ser metodológicamente inferior si reduce control, trazabilidad o calidad de los datos.

La simulación de procedimientos adquiere utilidad cuando convierte un protocolo abstracto en una secuencia que puede ser examinada antes de su implementación. Hartung (2025) permite comprender que los entornos científicos automatizados requieren planificación, límites y mecanismos de supervisión para funcionar de manera confiable. Del mismo modo, un proyecto puede beneficiarse de representar anticipadamente sus pasos, dependencias, contingencias y

controles. La inteligencia artificial facilita esta exploración mediante escenarios y comparaciones, pero la versión definitiva debe conservar correspondencia con el diseño y con las condiciones reales del estudio. Simular permite detectar debilidades tempranas y ajustar el procedimiento antes de que afecten la evidencia.

3.6 Comparación de métodos de análisis de datos con apoyo de inteligencia artificial

La comparación de métodos de análisis de datos permite anticipar qué procedimientos ofrecen mayor correspondencia con la pregunta de investigación, el tipo de información disponible y el alcance previsto del estudio. Christou (2024) permite situar la inteligencia artificial como apoyo para examinar alternativas analíticas y organizar decisiones relacionadas con el tratamiento de datos. Su utilidad radica en contrastar métodos antes de aplicarlos, identificando requisitos, supuestos y posibles limitaciones. La selección no debe depender de la sofisticación del procedimiento, sino de su capacidad para producir resultados interpretables y coherentes con la naturaleza de los datos y con los objetivos planteados.

En investigaciones cuantitativas, la comparación puede incluir procedimientos descriptivos, pruebas de asociación, análisis de diferencias o modelos de mayor complejidad, según las características del estudio. Jalali y Akhavan (2024) permiten considerar el empleo de inteligencia artificial como apoyo para analizar información y valorar alternativas metodológicas. Una herramienta puede revisar el tipo de variables, la estructura de los datos y el propósito analítico para proponer procedimientos potencialmente compatibles. Estas sugerencias requieren verificación estadística, porque un método aparentemente adecuado puede exigir supuestos que los datos no cumplen. La decisión final debe basarse en criterios técnicos y en la interpretación científica esperada.

El análisis cualitativo presenta exigencias diferentes, debido a que busca interpretar significados, patrones, categorías o relaciones presentes en información textual y contextual. Lee et al. (2024) permiten considerar el uso de inteligencia artificial para apoyar tareas vinculadas con el procesamiento y análisis de datos cualitativos. Estas herramientas pueden facilitar una primera organización del material, identificar recurrencias o proponer agrupaciones preliminares. Sin embargo, la comparación entre métodos debe considerar qué nivel de interpretación exige cada procedimiento y cuánto depende del contexto. Automatizar la clasificación no equivale a comprender el significado de los datos ni sustituye la construcción analítica realizada por el investigador.

La comparación metodológica puede realizarse mediante escenarios en los que un mismo conjunto de datos hipotético es examinado desde distintas estrategias. Paoli (2024) permite situar la inteligencia artificial como recurso útil para explorar procedimientos analíticos y organizar información compleja. El investigador puede contrastar qué tipo de resultados produciría cada método, qué supuestos necesitaría satisfacer y qué interpretación permitiría sostener. Este ejercicio ayuda a detectar procedimientos innecesariamente complejos o insuficientes para la pregunta planteada. La simulación debe utilizarse como mecanismo de evaluación previa, sin convertir el resultado generado por la herramienta en una decisión metodológica definitiva.

Tabla 9

Matriz comparativa para seleccionar métodos de análisis de datos con apoyo de inteligencia artificial

Dimensión de comparación	Pregunta de evaluación	Apoyo posible de la inteligencia artificial	Riesgo que debe controlarse
Tipo de datos	¿El método corresponde con la estructura de la información?	Identificar alternativas compatibles	Seleccionar técnicas inadecuadas
Propósito analítico	¿El procedimiento responde al objetivo del estudio?	Comparar resultados esperados	Analizar aspectos no vinculados con la pregunta
Supuestos	¿Se cumplen las condiciones requeridas?	Señalar requisitos técnicos	Aplicar métodos sin comprobar supuestos
Interpretabilidad	¿Los resultados pueden explicarse con claridad?	Mostrar diferencias entre procedimientos	Priorizar complejidad sobre comprensión
Robustez	¿El método mantiene resultados consistentes ante variaciones razonables?	Simular escenarios alternativos	Obtener conclusiones inestables
Trazabilidad	¿Puede reconstruirse el proceso analítico?	Organizar pasos y decisiones	Dependencia de procesos opacos

Nota. Elaboración propia. La matriz facilita la revisión conjunta de compatibilidad, exigencias técnicas e interpretabilidad antes de seleccionar un procedimiento analítico.

La comparación no debe centrarse únicamente en cuál método produce mejores indicadores de ajuste o resultados más llamativos. Goyanes et al. (2025) permiten considerar críticamente el uso de inteligencia artificial en procesos de análisis donde la selección metodológica puede verse influida por automatización y facilidad de procesamiento. Un procedimiento puede ofrecer resultados técnicamente correctos y, aun así, aportar poco a la comprensión del

problema. Por ello, conviene examinar simultáneamente pertinencia, interpretabilidad y capacidad de respuesta. El método más apropiado será aquel que permita analizar la evidencia con un nivel de complejidad proporcional a la pregunta y al diseño.

La inteligencia artificial también puede contribuir a comprobar la sensibilidad de las decisiones analíticas. Christou (2024) permite relacionar esta capacidad con el uso de herramientas inteligentes para explorar alternativas dentro del análisis de datos. El investigador puede simular cómo cambian los resultados cuando se modifican criterios de clasificación, tratamiento de valores perdidos, selección de variables o procedimientos de estimación. Si pequeñas modificaciones producen conclusiones considerablemente diferentes, debe revisarse la estabilidad del análisis. Esta evaluación previa ayuda a detectar decisiones que podrían condicionar excesivamente los resultados y favorece la selección de procedimientos cuya interpretación dependa menos de elecciones arbitrarias.

En datos cualitativos, una comparación semejante puede examinar distintas formas de codificación, categorización o síntesis. Lee et al. (2024) permiten considerar que las herramientas inteligentes pueden apoyar determinadas tareas analíticas sin eliminar la necesidad de revisión humana. Un modelo puede agrupar segmentos textuales de diferentes maneras y facilitar la observación de patrones, pero esas agrupaciones deben contrastarse con el contexto y con los criterios conceptuales del estudio. Comparar alternativas permite identificar si ciertas categorías son demasiado amplias, redundantes o poco consistentes. El criterio de selección debe responder a la capacidad del método para conservar significado y producir interpretaciones fundamentadas.

La transparencia del procedimiento constituye otro criterio central. Jalali y Akhavan (2024) permiten situar la inteligencia artificial como apoyo en procesos analíticos que requieren organización y revisión de información. Cuando se utilizan métodos automatizados, debe ser posible comprender qué datos ingresaron, qué transformaciones fueron realizadas y cómo se obtuvieron los resultados. Una alternativa analítica difícil de reconstruir puede reducir la capacidad de verificar decisiones y detectar errores. Por ello, la comparación debe incorporar la trazabilidad como criterio explícito. La eficiencia computacional no compensa la pérdida de claridad sobre el proceso mediante el cual se construyeron las conclusiones del estudio.

La comparación de métodos alcanza mayor rigor cuando combina criterios técnicos, conceptuales y operativos antes de seleccionar una estrategia definitiva. Paoli (2024) permite

comprender el valor de utilizar inteligencia artificial para explorar alternativas y estructurar procesos analíticos, mientras que Goyanes et al. (2025) permiten mantener una lectura crítica sobre sus implicaciones. Las herramientas inteligentes pueden proponer métodos, simular consecuencias y organizar diferencias entre procedimientos, pero no sustituyen el conocimiento estadístico o cualitativo necesario para validar cada elección. La decisión final debe conservar coherencia con la pregunta, la naturaleza de los datos, los supuestos metodológicos y el nivel de interpretación que el estudio pretende alcanzar.

3.7 Construcción y evaluación de escenarios metodológicos antes de la ejecución del proyecto

La construcción de escenarios metodológicos permite representar anticipadamente distintas configuraciones posibles del estudio antes de iniciar su ejecución. Christou (2024) permite situar la inteligencia artificial como apoyo para explorar alternativas analíticas y metodológicas de forma estructurada. Un escenario puede modificar elementos como diseño, técnica de recolección, estrategia de análisis o secuencia operativa, manteniendo constante el problema de investigación. Esta comparación ayuda a identificar consecuencias previsibles de cada decisión y a reconocer incompatibilidades antes del trabajo de campo. Su finalidad no es predecir con exactitud el desarrollo del proyecto, sino mejorar la calidad de las decisiones previas.

Un escenario metodológico debe construirse a partir de supuestos explícitos y verificables. Jalali y Akhavan (2024) permiten considerar la utilidad de la inteligencia artificial para organizar información y apoyar procesos de evaluación de alternativas. Si los supuestos iniciales son imprecisos, incompletos o contradictorios, la simulación puede producir resultados formalmente coherentes, pero metodológicamente poco útiles. Por ello, conviene definir previamente población, tipo de datos, recursos, restricciones y propósito analítico. La inteligencia artificial puede ayudar a representar distintas combinaciones, aunque cada una debe revisarse en función de las condiciones reales bajo las cuales se desarrollará la investigación.

La evaluación de escenarios también debe considerar la coherencia interna entre los componentes del diseño. Lee et al. (2024) permiten comprender que el uso de herramientas inteligentes en investigación puede apoyar la organización y análisis de información compleja. Un escenario puede resultar inviable cuando combina una pregunta cualitativa con

procedimientos exclusivamente cuantitativos, o cuando propone un tipo de análisis incompatible con los datos previstos. La inteligencia artificial puede señalar estas inconsistencias y sugerir configuraciones alternativas. Sin embargo, la coherencia metodológica no debe determinarse únicamente mediante coincidencias formales, sino mediante la relación sustantiva entre problema, pregunta, evidencia y estrategia de interpretación.

Otra dimensión relevante corresponde a la viabilidad operativa. Paoli (2024) permite situar la inteligencia artificial como recurso para explorar procedimientos y organizar decisiones metodológicas antes de la ejecución. Un escenario puede ser conceptualmente sólido y, aun así, exigir acceso difícil a participantes, infraestructura no disponible o una carga de procesamiento incompatible con los recursos del proyecto. Simular estas condiciones permite comparar alternativas y reconocer puntos críticos. La evaluación debe distinguir entre aquello que sería metodológicamente deseable y aquello que puede ejecutarse realmente sin comprometer la calidad del estudio ni alterar de manera injustificada sus objetivos.

Los escenarios metodológicos también pueden incorporar variaciones en la forma de analizar los datos. Goyanes et al. (2025) permiten mantener una mirada crítica sobre el empleo de inteligencia artificial en procesos de análisis y toma de decisiones investigativas. Una misma base de información puede producir resultados diferentes según los criterios de clasificación, los procedimientos estadísticos o las estrategias interpretativas elegidas. Comparar estas alternativas antes de la ejecución ayuda a identificar qué decisiones tienen mayor capacidad para modificar las conclusiones. Esta revisión resulta especialmente importante cuando determinadas opciones dependen de elecciones discrecionales que podrían introducir sesgos o reducir la estabilidad del análisis.

Figura 6

Guía integral para la construcción de escenarios metodológicos



Nota. La figura integra criterios fundamentales para construir escenarios metodológicos consistentes, factibles y útiles para comparar alternativas dentro del diseño de investigación.

La construcción de escenarios adversos añade una dimensión preventiva al diseño. Christou (2024) permite relacionar el uso de herramientas inteligentes con la exploración anticipada de problemas que pueden afectar el tratamiento de los datos. El investigador puede representar situaciones como pérdida de participantes, información incompleta, baja variabilidad o dificultades en la aplicación de instrumentos. La inteligencia artificial puede organizar las consecuencias de cada contingencia y facilitar la comparación de respuestas posibles. Este ejercicio no elimina la incertidumbre propia de la investigación, pero ayuda a establecer criterios de actuación antes de que aparezcan problemas que obliguen a modificar improvisadamente el procedimiento.

La evaluación de escenarios debe incorporar también criterios de transparencia y trazabilidad. Jalali y Akhavan (2024) permiten considerar que el uso de inteligencia artificial en procesos analíticos requiere mantener claridad sobre las decisiones adoptadas y sobre las transformaciones aplicadas a la información. Cada escenario debería registrar qué componente fue modificado, por qué se introdujo el cambio y cuáles consecuencias se esperan. Esta documentación facilita comparar alternativas sin perder el razonamiento que las originó. Además, permite identificar decisiones que podrían haber sido adoptadas únicamente porque una herramienta las sugirió, sin contar con una justificación metodológica suficiente.


El valor de la simulación aumenta cuando los escenarios se comparan mediante criterios comunes. Paoli (2024) permite comprender que la exploración asistida puede facilitar la revisión sistemática de alternativas antes de comprometer recursos. En lugar de evaluar cada configuración de manera aislada, conviene examinar su capacidad de responder la pregunta, producir evidencia interpretable, mantener coherencia metodológica y ajustarse a las condiciones operativas. Esta comparación reduce la influencia de preferencias intuitivas y permite justificar por qué una opción resulta más adecuada que otra. La inteligencia artificial puede organizar el contraste, pero la jerarquización final requiere una decisión fundamentada por el investigador.

La construcción y evaluación de escenarios metodológicos funciona como un mecanismo de anticipación que fortalece el diseño antes de la ejecución. Goyanes et al. (2025) permiten situar críticamente el uso de inteligencia artificial dentro de procesos donde la automatización puede ampliar capacidades, pero también condicionar decisiones si no existe supervisión. Los escenarios son útiles cuando hacen visibles restricciones, dependencias y consecuencias que podrían pasar inadvertidas durante una planificación lineal. Su aporte principal consiste en permitir comparar configuraciones posibles antes de implementarlas, conservando la posibilidad de ajustar el proyecto sin comprometer datos, participantes o recursos ya utilizados.

Capítulo 4.

Diseño de instrumentos con herramientas inteligentes

Julio Alfredo Castillo Guillin



4.1 Selección del instrumento según objetivos, variables y tipo de estudio

La selección del instrumento de investigación debe responder de manera directa a los objetivos, a la naturaleza de las variables o categorías y al tipo de estudio planteado. Posso et al. (2025) permiten vincular esta decisión con la necesidad de mantener coherencia entre los componentes metodológicos del proyecto. Un instrumento no debe elegirse únicamente por disponibilidad, facilidad de aplicación o uso frecuente en estudios previos. Su pertinencia depende de que permita obtener la información necesaria para responder la pregunta científica. La inteligencia artificial puede apoyar esta comparación mediante la organización de alternativas, requisitos y limitaciones antes de adoptar una decisión definitiva.

Los objetivos orientan el tipo de información que debe producir el instrumento. Bautista (2022) permite comprender que describir, comparar, relacionar o interpretar fenómenos exige procedimientos de recolección distintos. Si el propósito consiste en medir una variable, puede resultar pertinente una escala o cuestionario estructurado; si busca comprender experiencias, podría requerirse una entrevista u otra técnica cualitativa. La inteligencia artificial puede ayudar a revisar la correspondencia entre los verbos utilizados en los objetivos y las características de los instrumentos posibles. Esta revisión facilita detectar inconsistencias, aunque la elección debe sustentarse en criterios metodológicos y no únicamente en asociaciones terminológicas automáticas.

La naturaleza de las variables constituye otro criterio fundamental. Falcón y Serpa (2021) permiten situar esta decisión dentro de la lógica del enfoque cuantitativo, donde las variables requieren formas de observación y medición coherentes con su definición conceptual. Un instrumento debe representar adecuadamente las dimensiones o indicadores que componen cada variable y evitar incluir reactivos ajenos a su estructura. La inteligencia artificial puede colaborar en la revisión preliminar de esta correspondencia, por ejemplo, agrupando ítems según dimensiones o identificando posibles redundancias. Sin embargo, estas tareas no sustituyen la definición teórica ni los procedimientos posteriores de validación y análisis psicométrico.

En los estudios cualitativos, la selección del instrumento depende de la profundidad y del tipo de significado que se pretende recuperar. Williams y Ingleby (2025) permiten comprender que las preguntas abiertas, las guías de entrevista y otros recursos flexibles pueden favorecer una exploración más contextualizada de experiencias y percepciones. La inteligencia artificial

puede ayudar a comparar distintos niveles de estructuración, anticipar posibles rutas de indagación y detectar preguntas que limiten excesivamente la respuesta. Su intervención debe conservar la apertura necesaria para que emerjan categorías no previstas, evitando convertir la guía cualitativa en un cuestionario rígido que condicione el discurso de los participantes.

El tipo de estudio también condiciona la elección. Cedeño et al. (2024) permiten situar la inteligencia artificial como apoyo en procesos de diseño investigativo donde deben articularse objetivos, métodos e instrumentos. Un estudio descriptivo puede requerir instrumentos distintos de uno correlacional, experimental o interpretativo, aun cuando compartan una temática semejante. La herramienta puede facilitar la comparación entre opciones y señalar requerimientos de cada diseño. Esta función resulta útil para descartar alternativas incompatibles, pero la decisión final debe considerar cómo se obtendrán los datos, qué nivel de control exige el estudio y qué inferencias se pretende sostener.

Tabla 10
Matriz para seleccionar instrumentos según componentes del estudio

Componente del proyecto	Pregunta de evaluación	Instrumento potencial	Criterio principal de selección
Objetivo descriptivo	¿Qué características deben identificarse?	Cuestionario, ficha de registro, escala	Capacidad para describir de forma consistente
Objetivo relacional	¿Qué variables serán comparadas o asociadas?	Escalas o cuestionarios estructurados	Medición diferenciada de cada variable
Variables y dimensiones	¿Qué indicadores representan cada constructo?	Escala, inventario o cuestionario	Correspondencia conceptual
Experiencias o significados	¿Qué información necesita ser comprendida en profundidad?	Guía de entrevista	Apertura y profundidad de las respuestas
Procesos o conductas observables	¿Qué acontecimientos deben registrarse?	Protocolo o ficha de observación	Claridad de categorías y criterios de registro
Diseño mixto	¿Qué tipos de evidencia deben integrarse?	Combinación de instrumentos	Complementariedad entre datos

Nota. Elaboración propia. La matriz relaciona decisiones del diseño con criterios que orientan la elección del instrumento.

La tabla evidencia que la selección del instrumento no puede separarse del propósito de la investigación. Posso et al. (2025) permiten sostener que la coherencia metodológica exige correspondencia entre lo que se pretende conocer y la forma en que se obtendrá la evidencia.

Un mismo instrumento puede ser adecuado para un objetivo y resultar insuficiente para otro. Por ello, la inteligencia artificial puede utilizarse para comparar alternativas bajo criterios comunes, pero no debería recomendar instrumentos de forma genérica. La valoración debe considerar simultáneamente contenido, estructura, tipo de datos esperados y compatibilidad con el análisis posterior.

También es necesario distinguir entre seleccionar un instrumento existente y diseñar uno nuevo. Bautista (2022) permite relacionar esta decisión con la disponibilidad de recursos metodológicos adecuados para estudiar el fenómeno. Si existe un instrumento pertinente y suficientemente sustentado, su adaptación puede ser más razonable que construir otro desde cero. La inteligencia artificial puede facilitar búsquedas, organización de características y comparación de opciones, pero no debe asumir que un instrumento es válido para cualquier contexto. La equivalencia conceptual, las condiciones de aplicación y la población objetivo deben revisarse antes de adoptarlo o modificarlo.

La selección asistida requiere además examinar la carga operativa del instrumento. Falcón y Serpa (2021) permiten comprender que las decisiones metodológicas deben ser compatibles con las condiciones reales del estudio. Un instrumento excesivamente extenso puede aumentar fatiga y respuestas incompletas; uno demasiado breve puede dejar dimensiones relevantes sin cobertura. La inteligencia artificial puede ayudar a comparar extensión, estructura y requerimientos de aplicación, anticipando posibles dificultades. Esta revisión debe equilibrar eficiencia y suficiencia informativa. Reducir reactivos o preguntas únicamente para agilizar la aplicación puede afectar la capacidad del instrumento para representar de manera adecuada el fenómeno estudiado.

La selección final debe resultar de una articulación entre objetivos, variables o categorías, enfoque, diseño y condiciones de aplicación. Cedeño et al. (2024) permiten situar las herramientas inteligentes como apoyo para revisar esa coherencia antes de iniciar la construcción o adaptación del instrumento. Su mayor utilidad consiste en hacer visibles incompatibilidades, comparar alternativas y organizar criterios de decisión. El instrumento adecuado no es necesariamente el más complejo ni el más automatizado, sino aquel que permite obtener información pertinente y suficiente para responder la pregunta científica. Esa elección constituye la base para las etapas posteriores de diseño, revisión y validación.

4.2 Generación asistida de ítems para cuestionarios y escalas

La generación asistida de ítems mediante inteligencia artificial puede apoyar las primeras etapas de construcción de cuestionarios y escalas al producir formulaciones preliminares a partir de constructos, dimensiones e indicadores previamente definidos. Attali et al. (2022) permiten situar esta posibilidad dentro del desarrollo automatizado de reactivos, donde los sistemas pueden ampliar con rapidez el conjunto inicial de opciones. La utilidad principal consiste en reducir tareas repetitivas y favorecer la exploración de distintas formas de expresar un mismo contenido. Sin embargo, los ítems generados deben considerarse borradores que requieren revisión conceptual, lingüística y metodológica antes de incorporarse a un instrumento.

La calidad de un ítem depende, en primer lugar, de su correspondencia con el constructo que pretende representar. Hommel et al. (2022) permiten comprender que la generación automatizada puede utilizarse para producir conjuntos de reactivos relacionados con dominios específicos, siempre que exista una definición previa suficientemente clara. Si la dimensión está formulada de manera ambigua, el modelo puede generar contenidos semánticamente cercanos, pero conceptualmente imprecisos. Por ello, la inteligencia artificial debe recibir instrucciones que incluyan definición del constructo, población objetivo, propósito de medición y características esperadas de los reactivos. La precisión de entrada condiciona la pertinencia del contenido generado.

La generación asistida también permite producir múltiples versiones de un mismo indicador. Hernandez y Nie (2023) muestran el potencial de los modelos de lenguaje para apoyar tareas relacionadas con la elaboración de ítems, lo que facilita comparar formulaciones antes de seleccionar una versión definitiva. Esta variedad puede utilizarse para revisar extensión, claridad, complejidad sintáctica y adecuación al nivel de comprensión de los participantes. Sin embargo, generar más alternativas no garantiza mayor calidad. Varias formulaciones pueden expresar prácticamente la misma idea o introducir matices que alteren el contenido que se pretende medir, por lo que cada propuesta requiere evaluación individual.

La correspondencia entre ítem y dimensión constituye otro punto crítico. Götz et al. (2024) permiten considerar que los modelos generativos pueden apoyar la construcción de reactivos, pero su utilidad debe evaluarse en relación con la estructura conceptual del instrumento. Un ítem lingüísticamente correcto puede ubicarse de manera errónea dentro de una dimensión o representar más de un componente simultáneamente. La inteligencia artificial puede ayudar a clasificar reactivos y detectar semejanzas entre ellos, aunque esta función no sustituye el juicio

de contenido. La asignación definitiva debe preservar la diferenciación conceptual entre dimensiones y evitar solapamientos que dificulten la interpretación posterior.

También es posible utilizar modelos inteligentes para generar bancos amplios de reactivos antes de realizar una selección más exigente. Salah et al. (2025) permiten situar esta estrategia dentro de procesos donde la inteligencia artificial incrementa la eficiencia de la producción inicial de contenido. Un banco extenso facilita descartar formulaciones repetitivas, ambiguas o poco representativas sin reducir prematuramente la cobertura del constructo. Sin embargo, la cantidad debe mantenerse subordinada a la calidad. Un gran número de reactivos deficientes aumenta el trabajo de revisión y puede generar una falsa impresión de exhaustividad si muchas preguntas expresan el mismo indicador mediante cambios superficiales de redacción.

La revisión de redundancia adquiere especial importancia cuando se generan ítems automáticamente. Terry et al. (2025) permiten considerar el uso de inteligencia artificial tanto para producir como para evaluar reactivos dentro de procesos iterativos. Los modelos pueden identificar similitudes semánticas y señalar formulaciones excesivamente próximas, lo que ayuda a reducir repeticiones. No obstante, dos ítems parecidos no siempre son redundantes si representan matices conceptuales distintos. La decisión de conservarlos debe basarse en su función dentro de la escala y no únicamente en la semejanza textual. El propósito es asegurar cobertura suficiente del constructo sin saturar el instrumento con preguntas equivalentes.

Otra dimensión corresponde a la claridad del lenguaje. Attali et al. (2022) permiten comprender que la generación automatizada necesita acompañarse de controles sobre la forma de los reactivos. La inteligencia artificial puede ayudar a identificar frases extensas, dobles negaciones, términos técnicos innecesarios o estructuras que incluyan más de una idea. También puede producir alternativas adaptadas a diferentes niveles de lectura. Estas funciones facilitan el refinamiento lingüístico, pero no garantizan que todos los participantes interpreten el ítem del mismo modo. La claridad debe evaluarse posteriormente mediante revisión experta y pruebas con personas semejantes a la población objetivo.

La formulación de opciones de respuesta también debe guardar coherencia con el contenido del ítem. Hommel et al. (2022) permiten considerar la generación automatizada como un proceso que puede extenderse más allá del enunciado y apoyar la construcción de componentes complementarios del reactivo. En escalas tipo Likert, por ejemplo, las categorías deben corresponder con aquello que se pregunta y mantener una estructura comprensible. La

inteligencia artificial puede detectar inconsistencias entre el enunciado y la escala de respuesta, pero la decisión final exige revisar si las categorías representan adecuadamente intensidad, frecuencia, acuerdo u otra dimensión seleccionada para la medición.

Los ítems generados deben además evitar contenidos que induzcan respuestas o presupongan experiencias que no necesariamente corresponden a todos los participantes. Hernandez y Nie (2023) permiten situar los modelos de lenguaje como herramientas útiles para producir alternativas, pero sus respuestas pueden reproducir patrones presentes en los datos con los que fueron desarrollados. Esto obliga a revisar posibles sesgos en formulaciones, ejemplos o supuestos implícitos. Un reactivo aparentemente neutral puede resultar inadecuado para determinados grupos o contextos. La revisión debe considerar pertinencia cultural, comprensibilidad y correspondencia con las condiciones reales en que será aplicado el instrumento.

La generación asistida puede organizarse como un ciclo de producción, evaluación y reformulación. Terry et al. (2025) permiten comprender esta lógica iterativa como una vía para mejorar progresivamente los reactivos antes de su aplicación. El investigador puede solicitar alternativas, comparar versiones, eliminar redundancias y revisar correspondencia con dimensiones hasta obtener un conjunto preliminar más consistente. Este proceso es útil para depurar contenido, pero no debe confundirse con validación del instrumento. La calidad conceptual de los ítems necesita revisión humana y sus propiedades métricas requieren comprobación empírica mediante procedimientos apropiados una vez que el instrumento sea aplicado.

La inteligencia artificial aporta mayor valor cuando amplía las posibilidades de construcción sin asumir funciones que corresponden a la validación científica. Salah et al. (2025) permiten situar estas herramientas como apoyo para generar y revisar contenido, mientras que la decisión sobre qué ítems conservar debe sustentarse en criterios conceptuales y metodológicos. Un proceso riguroso parte de constructos definidos, produce varias alternativas, revisa claridad y pertinencia, elimina redundancias y somete después el conjunto a evaluación especializada y comprobación empírica. La generación asistida facilita el trabajo inicial, pero la calidad del cuestionario depende de una secuencia de controles que excede la capacidad generativa del modelo.

4.3 Diseño de guías de entrevista mediante inteligencia artificial

El diseño de guías de entrevista mediante inteligencia artificial puede apoyar la construcción inicial de preguntas orientadas a explorar experiencias, significados, percepciones y procesos relacionados con el objeto de estudio. Panfilova et al. (2026) permiten situar estas herramientas como recursos capaces de asistir tareas investigativas que requieren formulación, revisión y ajuste progresivo de contenidos. Su utilidad radica en generar alternativas, organizar secuencias temáticas y detectar preguntas ambiguas o redundantes. No obstante, una guía de entrevista no debe construirse únicamente mediante generación automática, porque su calidad depende de la relación entre objetivos, categorías analíticas, características de los participantes y contexto de aplicación.

Una guía adecuada debe partir de los objetivos de investigación y de las categorías que orientan la comprensión del fenómeno. Williams y Ingleby (2025) permiten relacionar la formulación de preguntas cualitativas con la necesidad de preservar apertura suficiente para captar significados y experiencias no previstas. La inteligencia artificial puede transformar categorías generales en preguntas exploratorias, pero estas deben evitar respuestas cerradas o excesivamente dirigidas. El propósito no consiste en confirmar anticipadamente una interpretación, sino en facilitar relatos y explicaciones que permitan comprender cómo los participantes experimentan o interpretan la situación estudiada. Cada pregunta debe cumplir una función analítica claramente identificable.

La inteligencia artificial también puede ayudar a establecer una secuencia lógica entre preguntas generales y específicas. Zhang et al. (2025) permiten considerar la importancia de organizar la indagación de manera que el entrevistado pueda avanzar desde descripciones amplias hacia aspectos más concretos. Una guía puede comenzar con preguntas de apertura, continuar con interrogantes orientadas a experiencias particulares y finalizar con cuestiones de profundización o reflexión. Los modelos pueden proponer distintos ordenamientos y detectar saltos temáticos abruptos. Sin embargo, la secuencia final debe considerar la sensibilidad del tema, la progresión natural de la conversación y las características de quienes participarán.

Una función especialmente útil consiste en generar distintas versiones de una misma pregunta para comparar su nivel de apertura. Paoli (2024) permite situar la inteligencia artificial como apoyo en procesos de organización y análisis dentro de la investigación cualitativa. Una formulación como “¿está satisfecho con...?” puede orientar una respuesta breve, mientras que “¿cómo describiría su experiencia con...?” ofrece mayores posibilidades de desarrollo. La herramienta puede mostrar estas diferencias y proponer alternativas. La selección definitiva

debe favorecer preguntas comprensibles, neutrales y suficientemente abiertas, evitando formulaciones que contengan juicios, respuestas implícitas o supuestos que condicionen el discurso del participante.

El diseño de preguntas de profundización constituye otra posibilidad de uso. Jalali y Akhavan (2024) permiten considerar la inteligencia artificial como recurso para apoyar el tratamiento estructurado de información cualitativa y la preparación de procesos analíticos. A partir de una pregunta principal, el modelo puede sugerir sondeos orientados a solicitar ejemplos, aclaraciones, motivos, consecuencias o descripciones detalladas. Estas preguntas secundarias resultan útiles cuando la respuesta inicial es breve o necesita mayor especificidad. No deberían utilizarse como un listado rígido, sino como recursos flexibles que el entrevistador activa según el desarrollo de la conversación y la información proporcionada por cada participante.

La revisión de sesgos en las preguntas constituye una fase indispensable. Panfilova et al. (2026) permiten situar la inteligencia artificial como apoyo para examinar formulaciones y detectar posibles problemas antes de la aplicación. Un modelo puede señalar preguntas que presuponen experiencias, utilizan categorías valorativas o favorecen determinadas respuestas. Esta revisión es útil, aunque no garantiza neutralidad completa, porque la propia herramienta puede reproducir sesgos presentes en sus patrones de generación. Por ello, cada pregunta debe analizarse desde el contexto social y cultural del estudio, valorando si su lenguaje puede influir indebidamente en la forma en que los participantes interpretan y responden.


La adecuación lingüística también requiere atención. Williams y Ingleby (2025) permiten comprender que la entrevista cualitativa depende de una comunicación capaz de facilitar narraciones y significados sin imponer un lenguaje ajeno a los participantes. La inteligencia artificial puede simplificar preguntas, adaptar vocabulario o producir versiones con distintos niveles de formalidad. Esta función resulta útil cuando la guía se dirige a poblaciones con características educativas o comunicativas específicas. Sin embargo, simplificar no significa eliminar conceptos indispensables. La redacción debe conservar el sentido investigativo y utilizar expresiones comprensibles que permitan respuestas espontáneas sin reducir artificialmente la complejidad del fenómeno estudiado.

Otro aspecto corresponde a la extensión de la guía. Zhang et al. (2025) permiten considerar la necesidad de equilibrar profundidad y viabilidad dentro de procesos cualitativos de recolección. La inteligencia artificial puede identificar preguntas repetitivas, agrupar temas

semejantes y sugerir una estructura más compacta. Una guía excesivamente extensa puede provocar fatiga, limitar la profundidad de las últimas respuestas o dificultar una conversación natural. En cambio, una guía demasiado breve puede dejar categorías relevantes sin explorar. La selección debe priorizar preguntas centrales y conservar sondeos opcionales, de modo que el tiempo disponible se utilice para profundizar en contenidos realmente vinculados con los objetivos.

Figura 7

Ciclo de diseño de guías de entrevista con IA



Nota. La figura representa un proceso iterativo de elaboración y ajuste de guías de entrevista con apoyo de inteligencia artificial, orientado a mejorar su claridad, pertinencia y coherencia.

La simulación de entrevistas constituye otra estrategia de revisión previa. Paoli (2024) permite relacionar el uso de inteligencia artificial con procedimientos de exploración que ayudan a anticipar dificultades analíticas. El investigador puede introducir la guía y solicitar respuestas hipotéticas para observar si las preguntas generan información suficientemente diferenciada o si varias conducen a contenidos similares. Esta simulación puede revelar ambigüedades o redundancias, pero no representa el comportamiento real de los participantes. Las respuestas artificiales proceden de patrones generados por el modelo y no sustituyen una prueba piloto, cuya función es observar cómo las personas comprenden y responden efectivamente a la guía.

El diseño asistido también puede apoyar la correspondencia entre preguntas y categorías analíticas. Jalali y Akhavan (2024) permiten situar la inteligencia artificial como recurso para organizar información cualitativa de manera estructurada. Cada interrogante puede asociarse preliminarmente con una categoría o dimensión para comprobar que la guía cubra los aspectos necesarios sin concentrarse excesivamente en uno de ellos. Esta organización facilita detectar vacíos temáticos y preguntas sin función clara. No obstante, en investigación cualitativa debe conservarse flexibilidad para que aparezcan contenidos no anticipados. La guía orienta la entrevista, pero no debería impedir que el participante introduzca experiencias relevantes fuera de las categorías iniciales.

La intervención de la inteligencia artificial debe mantenerse subordinada a decisiones éticas y metodológicas. Panfilova et al. (2026) permiten considerar que las herramientas inteligentes pueden apoyar diferentes etapas de la investigación, pero su uso exige control sobre la información introducida y sobre las decisiones derivadas de sus respuestas. Al diseñar guías relacionadas con experiencias sensibles, no resulta apropiado incorporar datos personales innecesarios en plataformas externas. Además, las preguntas deben revisar posibles efectos sobre los participantes, evitar formulaciones invasivas sin justificación y mantener correspondencia con el consentimiento previsto. La eficiencia de generación no debe desplazar criterios de respeto, pertinencia y protección de la información.

El diseño de guías de entrevista mediante inteligencia artificial alcanza mayor valor cuando forma parte de un proceso iterativo de generación, revisión, simulación y ajuste. Williams y Ingleby (2025) permiten mantener como criterio central la capacidad de las preguntas para facilitar una comprensión contextualizada de experiencias y significados. Las herramientas inteligentes pueden ampliar alternativas, mejorar secuencias, detectar redundancias y proponer sondeos, pero la guía definitiva requiere revisión humana y prueba con participantes adecuados. Una estructura sólida combina preguntas abiertas, lenguaje comprensible, progresión temática y flexibilidad, manteniendo siempre correspondencia con los objetivos y con la lógica cualitativa del estudio.

4.4 Diseño de protocolos de observación y codificación asistida por inteligencia artificial

El diseño de protocolos de observación y codificación exige definir con precisión qué conductas, eventos, interacciones o condiciones serán registradas y bajo qué criterios se clasificarán. Keadle et al. (2024) permiten situar la inteligencia artificial como apoyo para

estructurar procesos de observación asistidos por tecnologías capaces de registrar y categorizar determinados comportamientos. Su utilidad puede concentrarse en la organización preliminar de categorías, la identificación de patrones y la revisión de consistencia entre criterios. Sin embargo, el protocolo debe partir de una definición conceptual clara del fenómeno, porque ninguna herramienta puede compensar categorías ambiguas o mal delimitadas desde el diseño.

La construcción de categorías observacionales constituye una fase crítica, ya que determina qué aspectos del fenómeno serán visibles para el estudio. Posso et al. (2025) permiten relacionar esta tarea con la necesidad de mantener coherencia entre objetivos, variables o categorías e instrumentos. La inteligencia artificial puede ayudar a agrupar conductas semejantes, proponer categorías provisionales y detectar posibles solapamientos. Estas funciones facilitan la organización inicial, pero la clasificación debe conservar correspondencia con el marco conceptual. Si dos categorías son demasiado próximas o una incluye comportamientos heterogéneos, el protocolo puede producir registros inconsistentes y dificultar posteriormente la interpretación de los datos.

La definición operacional de cada categoría debe especificar qué señales permiten reconocerla durante la observación. Flemotomos et al. (2022) permiten considerar la utilidad de sistemas automatizados para identificar y clasificar aspectos observables a partir de datos registrados. Aplicada al diseño de protocolos, esta capacidad puede contribuir a transformar conceptos generales en criterios más concretos de codificación. No obstante, una definición operacional no debe basarse únicamente en patrones detectados por el sistema. Debe establecer límites comprensibles para los observadores y distinguir con claridad cuándo una conducta pertenece o no a determinada categoría, reduciendo decisiones discrecionales durante el registro.

La unidad de observación también necesita definirse antes de iniciar la recolección. Puede consistir en una conducta específica, un episodio, una interacción, un intervalo temporal o una secuencia previamente delimitada. Keadle et al. (2024) permiten considerar la importancia de establecer criterios consistentes para registrar comportamientos mediante sistemas de seguimiento y clasificación. La inteligencia artificial puede ayudar a comparar distintas unidades y mostrar cómo cambia el volumen o detalle de los registros. Sin embargo, una unidad demasiado pequeña puede fragmentar artificialmente el fenómeno, mientras que una demasiado amplia puede ocultar variaciones relevantes. La elección debe responder al objetivo analítico del estudio.

Tabla 11*Matriz para diseñar protocolos de observación y codificación asistida*

Componente	Criterio de diseño	Apoyo posible de la inteligencia artificial	Riesgo que debe controlarse
Categorías	Correspondencia con el fenómeno estudiado	Agrupar patrones y detectar solapamientos	Categorías ambiguas
Definiciones operacionales	Criterios claros de inclusión y exclusión	Comparar ejemplos y casos límite	Clasificación inconsistente
Unidad de observación	Nivel adecuado de detalle	Simular distintos niveles de registro	Fragmentación o pérdida de información
Temporalidad	Momento, duración o frecuencia del registro	Organizar secuencias e intervalos	Registros no comparables
Codificación	Reglas uniformes de asignación	Señalar discrepancias preliminares	Dependencia excesiva de automatización
Verificación	Comprobación de consistencia	Facilitar contrastes entre registros	Aceptación de clasificaciones erróneas

Nota. Elaboración propia. La matriz organiza los componentes que requieren definición previa para mantener consistencia durante la observación y la codificación.

La temporalidad del protocolo debe establecer cuándo comienza y termina cada registro, con qué frecuencia se observará y qué duración tendrá cada unidad. Hua et al. (2023) permiten considerar que la estabilidad y consistencia de los procedimientos resultan necesarias cuando se emplean sistemas inteligentes dentro de procesos científicos complejos. La inteligencia artificial puede ayudar a representar diferentes esquemas temporales y detectar posibles pérdidas de información entre intervalos. Sin embargo, aumentar la frecuencia de observación no garantiza mejores datos. La decisión debe equilibrar detalle, carga de registro y capacidad real para analizar posteriormente la información obtenida.

La codificación asistida puede facilitar el tratamiento de grandes volúmenes de registros cuando existen reglas suficientemente definidas. Flemotomos et al. (2022) permiten situar la inteligencia artificial dentro de procesos de reconocimiento y clasificación automatizada que pueden complementar el trabajo humano. Un sistema puede sugerir códigos preliminares, identificar recurrencias o señalar segmentos que presentan características similares. Estas funciones reducen tareas repetitivas, pero la asignación automática debe someterse a controles de calidad. Los errores pueden aparecer cuando una conducta cambia de significado según el contexto o cuando el modelo interpreta como equivalentes patrones que requieren una distinción conceptual más precisa.

La consistencia entre observadores representa otra dimensión que puede revisarse con apoyo tecnológico. Posso et al. (2025) permiten vincular la calidad de un instrumento con la necesidad de aplicar criterios homogéneos durante su utilización. La inteligencia artificial puede facilitar comparaciones entre registros humanos y señalar discrepancias frecuentes en ciertas categorías. Este análisis ayuda a identificar definiciones poco claras o reglas de codificación que necesitan ajuste. No obstante, la concordancia no debe buscarse mediante la imposición automática de una clasificación. El objetivo es mejorar la claridad del protocolo para que diferentes observadores puedan aplicar criterios equivalentes con base en instrucciones comprensibles y justificadas.

También resulta necesario establecer procedimientos para los casos ambiguos. Keadle et al. (2024) permiten considerar que los sistemas de observación y registro deben contemplar variabilidad y situaciones difíciles de clasificar. Un protocolo robusto puede incluir reglas para datos incompletos, conductas que cumplen parcialmente varios criterios o eventos que ocurren simultáneamente. La inteligencia artificial puede ayudar a identificar estos casos durante simulaciones preliminares y proponer alternativas de resolución. Sin embargo, las reglas deben quedar establecidas antes de la aplicación sistemática, evitando que las decisiones cambien según los resultados observados o que cada caso excepcional reciba un tratamiento diferente sin justificación.

La validación preliminar del protocolo puede realizarse mediante ejercicios de simulación con registros hipotéticos o materiales de prueba. Hua et al. (2023) permiten situar la evaluación de estabilidad y desempeño como parte importante del uso de herramientas inteligentes en investigación. El protocolo puede aplicarse a situaciones diversas para comprobar si las categorías resultan distinguibles, si las reglas permiten decisiones consistentes y si existen eventos relevantes que no encuentran clasificación adecuada. Esta etapa facilita ajustes antes de la observación definitiva. Aun así, la simulación no reemplaza la prueba en condiciones reales, donde pueden aparecer comportamientos y contextos no previstos durante el diseño.

El diseño asistido de protocolos alcanza mayor rigor cuando la inteligencia artificial se utiliza para estructurar, comparar y revisar criterios, sin convertir la clasificación automática en sustituto del juicio metodológico. Flemotomos et al. (2022) permiten considerar el potencial de automatización en tareas de reconocimiento y codificación, pero la calidad final depende de la definición conceptual y de los mecanismos de verificación. Un protocolo sólido establece categorías, unidades, reglas temporales, criterios de codificación y procedimientos para casos

ambiguos antes de recopilar datos. La asistencia inteligente puede mejorar consistencia y eficiencia, siempre que sus resultados permanezcan sujetos a revisión y control.

4.5 Revisión de claridad, pertinencia y coherencia de los ítems mediante herramientas inteligentes

La revisión de claridad, pertinencia y coherencia de los ítems constituye una fase necesaria antes de someter un instrumento a procedimientos de validación y aplicación empírica. Posso et al. (2025) permiten relacionar esta tarea con la necesidad de asegurar correspondencia entre variables, dimensiones, indicadores e ítems. Las herramientas de inteligencia artificial pueden apoyar una primera evaluación al detectar formulaciones ambiguas, redundancias, inconsistencias conceptuales o problemas de correspondencia entre reactivos y dimensiones. Su utilidad se concentra en facilitar una depuración preliminar del contenido, pero no sustituye la valoración experta ni la comprobación empírica de las propiedades del instrumento.

La claridad exige que cada ítem pueda ser comprendido de manera directa por la población a la que se dirige. Salah et al. (2025) permiten situar la inteligencia artificial como apoyo para revisar formulaciones y comparar versiones alternativas de un mismo reactivo. El sistema puede señalar expresiones demasiado extensas, términos técnicos innecesarios, dobles negaciones o estructuras que contienen más de una idea. Estas observaciones pueden mejorar la legibilidad, aunque la simplificación debe realizarse con cuidado. Un ítem más breve no siempre es más claro si pierde precisión conceptual o modifica el significado del indicador que pretende representar.

La pertinencia se refiere a la relación efectiva entre el ítem y el contenido que debe medir o explorar. Terry et al. (2025) permiten considerar el uso de inteligencia artificial para examinar la correspondencia entre reactivos y constructos durante procesos iterativos de revisión. Una herramienta puede clasificar ítems según dimensiones y señalar aquellos que parecen alejados del dominio conceptual definido. Sin embargo, esta clasificación debe interpretarse como una señal preliminar. La pertinencia no depende únicamente de similitudes semánticas, sino de la función que cada reactivo cumple dentro del instrumento y de su relación con la definición teórica de la variable.

La coherencia interna del contenido exige que los ítems de una misma dimensión mantengan una orientación conceptual común sin convertirse en formulaciones repetitivas. Hommel et al. (2022) permiten comprender que la generación y organización automatizada de reactivos

requiere controles que aseguren consistencia dentro del dominio evaluado. La inteligencia artificial puede identificar ítems semánticamente cercanos y mostrar posibles solapamientos. Esta función facilita detectar redundancias, pero no debe utilizarse de forma mecánica para eliminar reactivos. Dos ítems similares pueden explorar matices distintos, mientras que otros aparentemente diferentes pueden medir prácticamente el mismo contenido y aportar escasa información adicional.

La revisión también debe examinar la correspondencia entre el enunciado y la escala de respuesta utilizada. Götz et al. (2024) permiten considerar que la calidad de un reactivo depende de la articulación entre contenido y forma de respuesta. Un ítem formulado en términos de frecuencia requiere categorías compatibles con esa lógica, mientras que uno orientado al grado de acuerdo necesita otra estructura. La inteligencia artificial puede detectar incongruencias preliminares entre ambos componentes y proponer ajustes. Sin embargo, la elección final de categorías debe responder al constructo, al propósito de medición y a la forma en que los participantes interpretarán las alternativas disponibles.

Otro criterio consiste en identificar ítems que incluyan más de una afirmación dentro del mismo enunciado. Posso et al. (2025) permiten relacionar esta revisión con la necesidad de mantener precisión en la operacionalización de variables. Las herramientas inteligentes pueden señalar conectores o estructuras que indiquen la presencia de dos contenidos diferentes y proponer su separación. Este tipo de revisión resulta útil porque un participante puede estar de acuerdo con una parte y en desacuerdo con otra, generando una respuesta difícil de interpretar. La corrección debe preservar la intención original del indicador y evitar fragmentar innecesariamente contenidos que sí forman una unidad conceptual.


La detección de sesgos lingüísticos constituye otra función relevante. Salah et al. (2025) permiten situar las herramientas inteligentes como apoyo para revisar formulaciones que puedan inducir respuestas, incorporar juicios de valor o presuponer conductas determinadas. Un modelo puede identificar expresiones cargadas o sugerir alternativas más neutrales. No obstante, la propia inteligencia artificial puede reproducir sesgos presentes en sus patrones de generación, por lo que sus recomendaciones deben ser examinadas críticamente. La neutralidad del ítem depende del contexto cultural, de la población y del significado que adquieren determinadas expresiones dentro de la situación concreta de aplicación.

La revisión asistida puede organizarse mediante ciclos sucesivos. Terry et al. (2025) permiten comprender esta lógica como un proceso de generación, evaluación y ajuste donde cada versión se compara con la anterior. El investigador puede revisar primero claridad, luego pertinencia, después redundancia y finalmente coherencia global. Separar los criterios evita que una modificación destinada a mejorar un aspecto introduzca problemas en otro. Por ejemplo, simplificar una frase puede aumentar claridad, pero reducir precisión conceptual. La inteligencia artificial facilita estas comparaciones, aunque la decisión final debe conservar trazabilidad sobre qué cambio se realizó y con qué justificación metodológica.

También resulta necesario revisar la coherencia del conjunto y no únicamente de cada ítem aislado. Götz et al. (2024) permiten considerar que los reactivos deben funcionar como parte de una estructura que representa dimensiones diferenciadas de un constructo. La inteligencia artificial puede agrupar ítems, detectar concentraciones excesivas en ciertos indicadores y señalar dimensiones con menor cobertura. Este análisis ayuda a equilibrar el instrumento antes de su aplicación. Sin embargo, una distribución aparentemente equilibrada no garantiza validez de contenido. La cobertura adecuada debe establecerse a partir de la definición conceptual y de la importancia relativa de los componentes que integran la variable.

Figura 8

Proceso de revisión de ítems asistido por IA



Nota. La figura presenta una revisión progresiva de los ítems orientada a fortalecer su calidad técnica y reducir inconsistencias antes de su aplicación.

La plausibilidad lingüística de las recomendaciones generadas constituye un riesgo que debe controlarse. Gao et al. (2023) muestran que un texto científico producido por inteligencia

artificial puede presentar una apariencia convincente sin que ello garantice calidad científica. Esta advertencia es directamente aplicable a la revisión de ítems. Una reformulación puede parecer más técnica o elegante y, al mismo tiempo, alterar el constructo, introducir un supuesto o modificar la intensidad del contenido. Por ello, la herramienta debe utilizarse para señalar problemas y proponer alternativas, mientras que la aprobación de cada cambio requiere contraste con la definición conceptual y con criterios metodológicos explícitos.

La revisión mediante herramientas inteligentes alcanza mayor valor cuando se integra con evaluación humana y comprobación posterior del instrumento. Hommel et al. (2022) permiten situar la automatización como apoyo en la construcción de reactivos, pero no como reemplazo de los controles científicos necesarios. Un conjunto depurado debe presentar ítems comprensibles, pertinentes para cada dimensión, coherentes entre sí y compatibles con la forma de respuesta prevista. La inteligencia artificial puede acelerar la detección de problemas formales y conceptuales preliminares, aunque la calidad definitiva requiere juicio experto, revisión con la población objetivo y análisis empírico de su funcionamiento.

4.6 Simulación de respuestas para detectar problemas en los instrumentos

La simulación de respuestas permite examinar de manera preliminar cómo podría comportarse un instrumento antes de aplicarlo a participantes reales. Posso et al. (2025) permiten relacionar esta práctica con la necesidad de revisar la correspondencia entre objetivos, variables, dimensiones e ítems. La inteligencia artificial puede generar respuestas hipotéticas bajo distintos perfiles y condiciones, lo que facilita identificar preguntas ambiguas, categorías poco diferenciadas o patrones de respuesta excesivamente uniformes. Su utilidad consiste en anticipar dificultades de diseño, pero las respuestas simuladas no representan evidencia empírica ni sustituyen una prueba piloto realizada con personas pertenecientes a la población objetivo.

En cuestionarios y escalas, la simulación puede utilizarse para observar si los ítems permiten distinguir adecuadamente entre niveles diferentes del constructo. Terry et al. (2025) permiten considerar la inteligencia artificial como apoyo dentro de procesos iterativos de generación y evaluación de reactivos. Si varios perfiles hipotéticos producen respuestas prácticamente idénticas, puede existir un problema de sensibilidad, redundancia o formulación. También pueden aparecer ítems cuya redacción conduce casi siempre a una misma categoría de respuesta. Estas señales ayudan a revisar el instrumento antes de su aplicación, aunque

cualquier inferencia sobre su funcionamiento real necesita posteriormente comprobarse mediante datos obtenidos empíricamente.

La generación de respuestas hipotéticas también puede ayudar a detectar reactivos con opciones poco funcionales. Attali et al. (2022) permiten situar la automatización dentro de procesos de construcción y evaluación preliminar de ítems. Cuando determinadas alternativas resultan difíciles de distinguir o parecen incompatibles con el enunciado, la simulación puede mostrar concentraciones artificiales en ciertas respuestas. Este ejercicio resulta útil para revisar escalas de frecuencia, acuerdo, intensidad u otras estructuras categóricas. Sin embargo, el comportamiento simulado depende de las instrucciones dadas al modelo y no permite estimar directamente cómo distribuirán sus respuestas los participantes reales.

En instrumentos cualitativos, la simulación cumple una función distinta. Williams y Ingleby (2025) permiten comprender la importancia de formular preguntas capaces de generar relatos, explicaciones y significados suficientemente ricos. La inteligencia artificial puede producir respuestas hipotéticas a una guía de entrevista para examinar si algunas preguntas conducen a contestaciones breves, repetitivas o demasiado dirigidas. También puede mostrar cuándo varias interrogantes exploran prácticamente el mismo contenido. Este análisis ayuda a ajustar apertura, orden y profundidad de la guía, pero no sustituye la interacción real, donde el contexto, la experiencia y la relación con el entrevistador influyen en las respuestas.

La simulación también puede incorporar perfiles contrastantes para comprobar cómo responde el instrumento ante participantes con características diferentes. Panfilova et al. (2026) permiten situar las herramientas inteligentes como apoyo para explorar escenarios y revisar procedimientos antes de su aplicación. El investigador puede establecer variaciones hipotéticas en experiencia, nivel de conocimiento o posición frente al fenómeno y observar si los ítems mantienen claridad y pertinencia. Esta estrategia puede revelar formulaciones que solo resultan comprensibles para determinados perfiles. No obstante, los perfiles simulados deben utilizarse como ejercicios analíticos y no como representaciones fieles de grupos sociales reales.

Tabla 12
Matriz para detectar problemas mediante simulación de respuestas

Aspecto evaluado	Señal observable en la simulación	Posible problema del instrumento	Acción de revisión
Variabilidad	Respuestas muy similares entre perfiles distintos	Baja capacidad de discriminación	Revisar redacción o nivel de especificidad

Aspecto evaluado	Señal observable en la simulación	Posible problema del instrumento	Acción de revisión
Distribución	Concentración repetida en una categoría	Opciones poco diferenciadas	Examinar escala de respuesta
Redundancia	Respuestas equivalentes en varios ítems	Reactivos demasiado similares	Comparar contenido y función
Comprensión	Respuestas incoherentes con el enunciado	Ambigüedad o dificultad lingüística	Reformular el ítem
Profundidad	Contestaciones breves ante preguntas abiertas	Pregunta demasiado cerrada	Aumentar apertura o incorporar sondeos
Coherencia	Respuestas incompatibles con la dimensión prevista	Desalineación conceptual	Revisar correspondencia con el constructo

Nota. Elaboración propia. La matriz orienta la identificación preliminar de fallas que requieren revisión antes de la aplicación empírica.

La tabla evidencia que las respuestas simuladas pueden funcionar como señales diagnósticas del instrumento. Terry et al. (2025) permiten comprender que la evaluación iterativa facilita revisar reactivos antes de consolidar una versión definitiva. Una concentración de respuestas, por ejemplo, no demuestra por sí sola que un ítem sea defectuoso, pero puede justificar una revisión adicional. Del mismo modo, una aparente buena diferenciación entre perfiles simulados no garantiza sensibilidad empírica. La utilidad del procedimiento radica en hacer visibles posibles fallas y orientar decisiones de depuración, manteniendo una separación clara entre evaluación preliminar y comprobación basada en participantes reales.

Otro uso consiste en comprobar la coherencia entre respuestas esperadas e interpretación prevista. Posso et al. (2025) permiten relacionar esta revisión con la correcta operacionalización de variables y dimensiones. Si una respuesta alta en determinado ítem se interpreta como mayor presencia del constructo, la simulación puede ayudar a verificar si esa dirección es consistente en todo el instrumento. Esto resulta especialmente importante cuando existen ítems invertidos o escalas con formulaciones diferentes. La detección temprana de inconsistencias evita errores posteriores de codificación, aunque las reglas de puntuación deben definirse con base en criterios teóricos y metodológicos, no mediante patrones artificialmente generados.

La simulación puede utilizarse además para preparar una prueba piloto más eficiente. Attali et al. (2022) permiten considerar que los procedimientos automatizados pueden apoyar fases preliminares de construcción y revisión de reactivos. Después de detectar preguntas potencialmente problemáticas, el investigador puede concentrar la prueba con participantes

reales en aquellos aspectos que requieren mayor observación. Esta secuencia reduce errores evidentes antes de invertir recursos en la aplicación piloto. Sin embargo, no debe utilizarse para eliminar esa fase empírica, ya que solo los participantes reales permiten observar dificultades de comprensión, tiempos de respuesta, interpretaciones inesperadas y comportamientos que una simulación no reproduce plenamente.

La simulación de respuestas adquiere mayor valor cuando se utiliza como mecanismo de detección temprana y no como sustituto de la validación. Panfilova et al. (2026) permiten situar la inteligencia artificial dentro de procesos de revisión que pueden anticipar problemas y facilitar ajustes progresivos. Un instrumento puede beneficiarse de escenarios hipotéticos que examinen variabilidad, claridad, redundancia, coherencia y profundidad de respuesta antes de su aplicación. No obstante, las respuestas generadas permanecen condicionadas por el propio modelo y por las instrucciones utilizadas. Su función es señalar puntos que merecen revisión, mientras que la calidad real del instrumento debe comprobarse mediante evaluación humana y evidencia empírica.

4.7 Apoyo de la inteligencia artificial en la validación y mejora de instrumentos

El apoyo de la inteligencia artificial en la validación y mejora de instrumentos debe entenderse como una asistencia complementaria dentro de un proceso metodológico más amplio. Posso et al. (2025) permiten relacionar esta etapa con la necesidad de comprobar que los ítems representen adecuadamente las variables, dimensiones o categorías definidas. Las herramientas inteligentes pueden contribuir a detectar inconsistencias, redundancias, ambigüedades y problemas de correspondencia conceptual. Sin embargo, estas funciones no equivalen a una validación automática. La calidad del instrumento exige distinguir entre generación de contenido, evaluación humana y comprobación empírica de sus propiedades antes de considerarlo adecuado para su aplicación definitiva.

Una primera contribución consiste en revisar la representatividad conceptual de los ítems. Terry et al. (2025) permiten considerar la inteligencia artificial como apoyo para comparar reactivos con los constructos que pretenden medir. El sistema puede agrupar preguntas según dimensiones, señalar posibles desajustes y detectar concentraciones excesivas de contenido en determinados indicadores. Esta revisión ayuda a identificar vacíos de cobertura antes de la evaluación formal. No obstante, la correspondencia semántica entre un ítem y una dimensión

no demuestra validez de contenido. La decisión requiere juicio especializado capaz de interpretar la relación entre la formulación, la teoría y el propósito específico del instrumento.

La claridad lingüística puede revisarse mediante herramientas inteligentes antes de aplicar procedimientos más complejos. Salah et al. (2025) permiten situar estos sistemas como recursos para identificar expresiones ambiguas, estructuras extensas, dobles negaciones o formulaciones con más de una idea. También pueden generar versiones alternativas para comparar niveles de comprensión. Esta función resulta útil para depurar el instrumento, pero debe evitarse que la simplificación altere el significado del constructo. Una redacción más breve o fluida no necesariamente representa mejor el contenido que se pretende medir, por lo que cada modificación debe contrastarse con la definición conceptual establecida.

Otra posibilidad consiste en analizar la coherencia del conjunto de reactivos. Götz et al. (2024) permiten considerar que los modelos generativos pueden apoyar la construcción y revisión de instrumentos mediante comparaciones entre contenido y estructura conceptual. La inteligencia artificial puede señalar ítems redundantes, detectar formulaciones demasiado semejantes y mostrar diferencias de estilo que podrían afectar la consistencia del cuestionario. Este análisis preliminar facilita el refinamiento antes de la aplicación. Sin embargo, la coherencia lingüística no debe confundirse con consistencia psicométrica, ya que esta última requiere evidencia empírica obtenida mediante procedimientos estadísticos realizados con datos reales.

La generación automatizada también puede apoyar la mejora mediante procesos iterativos. Hommel et al. (2022) permiten situar la producción de reactivos como una actividad que puede beneficiarse de ciclos sucesivos de creación, revisión y selección. A partir de un ítem problemático, la inteligencia artificial puede proponer varias reformulaciones y permitir que el investigador compare cambios en claridad, especificidad o correspondencia con una dimensión. Esta dinámica facilita la depuración progresiva, siempre que cada modificación conserve trazabilidad. El riesgo aparece cuando se acumulan cambios estilísticos sin verificar si la nueva versión sigue representando exactamente el contenido que justificó el reactivo original.

La evaluación de pertinencia puede fortalecerse mediante comparaciones entre ítems y perfiles hipotéticos de respuesta. Hernandez y Nie (2023) permiten considerar el potencial de los modelos de lenguaje para apoyar tareas relacionadas con generación y revisión de reactivos. La inteligencia artificial puede simular cómo diferentes perfiles podrían interpretar una

pregunta y señalar casos donde la formulación resulte confusa o poco diferenciadora. Estas simulaciones permiten anticipar dificultades, pero no reemplazan la respuesta de participantes reales. El funcionamiento efectivo de un instrumento depende de cómo las personas comprenden, procesan y responden a los ítems dentro de condiciones concretas de aplicación.

La revisión mediante expertos continúa siendo un componente necesario del proceso. Sigüenza et al. (2024) permiten situar la validación de instrumentos dentro de procedimientos donde la valoración especializada examina aspectos como claridad, relevancia y correspondencia entre componentes. La inteligencia artificial puede organizar las observaciones de varios evaluadores, identificar coincidencias y agrupar recomendaciones semejantes. Esta función mejora la gestión de información durante la revisión, pero no debe sustituir la deliberación experta. El juicio humano aporta conocimiento disciplinar, metodológico y contextual que resulta indispensable para interpretar por qué un ítem debe mantenerse, modificarse o eliminarse.

La mejora de instrumentos también requiere comprobar su comportamiento después de una aplicación piloto. Vasquez et al. (2025) permiten considerar la importancia de evaluar empíricamente las propiedades del instrumento antes de utilizarlo de manera definitiva. La inteligencia artificial puede ayudar a organizar resultados, detectar patrones inusuales y señalar ítems que merecen una revisión adicional. No obstante, cualquier decisión relacionada con fiabilidad, estructura interna o funcionamiento de los reactivos debe sustentarse en procedimientos estadísticos apropiados. La herramienta puede facilitar el procesamiento y la interpretación preliminar, pero no reemplaza los criterios técnicos requeridos para establecer evidencia de calidad psicométrica.

La integración de información cualitativa y cuantitativa puede enriquecer el proceso de mejora. Posso et al. (2025) permiten relacionar la evaluación de instrumentos con distintas fuentes de evidencia que aportan información complementaria. Comentarios de expertos, observaciones de participantes y resultados estadísticos pueden analizarse conjuntamente para identificar problemas que no serían visibles desde una sola perspectiva. La inteligencia artificial puede apoyar la organización de estas evidencias y mostrar convergencias o discrepancias. Sin embargo, la decisión de modificar un ítem debe considerar el peso metodológico de cada fuente y evitar que una señal aislada determine cambios sin suficiente justificación.

Un riesgo importante consiste en atribuir a la inteligencia artificial una capacidad de validación que excede sus funciones reales. Terry et al. (2025) permiten comprender que estas herramientas pueden participar en procesos de evaluación y mejora, pero su desempeño debe mantenerse sujeto a criterios científicos externos. Que un modelo considere un ítem claro, pertinente o coherente no demuestra que dicho reactivo posea validez ni que funcione adecuadamente en una población determinada. La validación requiere evidencia acumulativa procedente de revisión especializada y aplicación empírica. La inteligencia artificial puede acelerar ciertas tareas, pero no transforma una evaluación automatizada en evidencia suficiente.


El apoyo de la inteligencia artificial adquiere mayor utilidad cuando se integra dentro de una secuencia metodológica claramente diferenciada. Salah et al. (2025) permiten situar estas herramientas en las fases de generación y revisión preliminar, mientras que la evaluación humana y la comprobación empírica deben conservar funciones propias. Un proceso consistente puede utilizar inteligencia artificial para identificar problemas, producir alternativas y organizar evidencias; posteriormente, expertos y participantes permiten valorar contenido y comprensión, y los datos reales permiten examinar propiedades métricas. La mejora del instrumento surge de la convergencia entre estas etapas, no de la automatización aislada de alguna de ellas.



Capítulo 5.

Evaluación de riesgos, sesgos y viabilidad investigativa

Ángel Patricio Herrera Carrión



5.1 Identificación temprana de riesgos metodológicos mediante inteligencia artificial

La identificación temprana de riesgos metodológicos permite reconocer debilidades potenciales antes de que afecten la recolección, el análisis o la interpretación de los datos. Kapoor y Narayanan (2023) permiten advertir que determinados errores en el diseño analítico pueden producir resultados engañosos incluso cuando los procedimientos parecen técnicamente correctos. La inteligencia artificial puede apoyar esta revisión al detectar inconsistencias entre pregunta, diseño, variables, muestra y análisis previsto. Su aporte resulta especialmente útil en fases iniciales, cuando todavía es posible modificar decisiones sin comprometer recursos ni evidencia. No obstante, las alertas generadas deben someterse a evaluación metodológica y no aceptarse automáticamente.

Uno de los principales riesgos corresponde a la selección inadecuada de datos o muestras. Semmelrock et al. (2025) permiten considerar que los sistemas automatizados pueden verse afectados por la calidad, estructura y representatividad de la información utilizada. La inteligencia artificial puede ayudar a explorar escenarios donde determinados grupos estén subrepresentados, existan datos insuficientes o ciertas categorías concentren demasiados casos. Esta simulación facilita anticipar posibles distorsiones en los resultados. Sin embargo, la herramienta no puede corregir por sí sola una muestra mal definida ni reemplazar los criterios estadísticos y metodológicos necesarios para establecer cómo deben seleccionarse los participantes.

Otro riesgo aparece cuando existe desalineación entre el diseño y la pregunta científica. Ciobanu et al. (2024) permiten situar la evaluación metodológica como un proceso donde deben examinarse coherencia, supuestos y condiciones de aplicación antes de interpretar resultados. Una herramienta inteligente puede señalar, por ejemplo, cuando se pretende formular conclusiones causales a partir de un diseño que solo permite observar asociaciones. También puede detectar inconsistencias entre temporalidad, variables y técnica de análisis. Estas funciones ayudan a prevenir errores conceptuales frecuentes, aunque la decisión sobre si el diseño es suficiente debe basarse en conocimiento metodológico y en las características reales del estudio.

La inteligencia artificial también puede contribuir a identificar riesgos asociados con la calidad de los instrumentos. Contreras et al. (2024) permiten considerar que el uso de estas tecnologías en investigación requiere una evaluación crítica de las condiciones bajo las cuales se producen

y analizan los datos. Un sistema puede detectar preguntas redundantes, formulaciones ambiguas o discrepancias entre dimensiones e ítems. Estas señales permiten revisar el instrumento antes de aplicarlo. Sin embargo, una evaluación automatizada no demuestra validez ni fiabilidad. Los problemas metodológicos relacionados con medición deben confirmarse mediante revisión especializada, aplicación piloto y procedimientos empíricos compatibles con la naturaleza del instrumento.

Los riesgos derivados del análisis de datos constituyen otra dimensión relevante. Kapoor y Narayanan (2023) advierten que prácticas metodológicas inadecuadas pueden producir resultados artificialmente favorables o poco generalizables. La inteligencia artificial puede utilizarse para revisar la secuencia analítica, comprobar si existen filtraciones de información entre fases o advertir sobre decisiones que favorezcan sobreajuste. Esta función resulta particularmente importante cuando se emplean modelos predictivos o procedimientos computacionales complejos. Aun así, la herramienta debe funcionar como mecanismo de control y no como autoridad metodológica, porque algunos errores solo pueden identificarse mediante comprensión profunda del diseño y del proceso de generación de los datos.

Otro riesgo consiste en asumir que una salida generada por inteligencia artificial es correcta porque presenta una estructura convincente. Gao et al. (2023) muestran que los modelos pueden producir contenido científico aparentemente plausible sin garantizar exactitud. Esta característica obliga a revisar cualquier recomendación metodológica, diagnóstico de riesgo o explicación producida automáticamente. Una respuesta bien redactada puede contener supuestos erróneos, referencias inexistentes o inferencias que exceden la evidencia disponible. Por ello, la identificación temprana debe incluir un mecanismo de verificación independiente. La fluidez lingüística del sistema no constituye evidencia de que la recomendación sea científicamente adecuada.

También deben considerarse los riesgos derivados de la dependencia excesiva de automatización. Castillo (2023) permite situar críticamente el uso de inteligencia artificial en investigación y reconocer que su incorporación modifica la manera en que se toman decisiones académicas. Cuando el investigador delega demasiadas etapas, puede reducirse la capacidad de identificar errores, justificar elecciones o reconstruir el razonamiento metodológico. La herramienta puede asistir en comparaciones y revisiones, pero cada decisión relevante debe conservar una justificación independiente. La automatización resulta útil cuando aumenta la

capacidad de análisis, no cuando sustituye el conocimiento necesario para comprender las consecuencias de las decisiones adoptadas.

La supervisión humana constituye un componente central en la gestión temprana de riesgos. Bienefeld et al. (2023) permiten considerar que la confianza en sistemas automatizados debe ajustarse a sus capacidades reales y a las condiciones específicas de uso. En investigación, una confianza excesiva puede llevar a aceptar recomendaciones sin suficiente contraste, mientras que una desconfianza absoluta impide aprovechar funciones útiles de detección y comparación. La respuesta adecuada consiste en combinar revisión automatizada con evaluación humana. Este equilibrio permite utilizar la inteligencia artificial para ampliar la capacidad de anticipación, manteniendo bajo responsabilidad del investigador la interpretación y corrección de los riesgos identificados.

La identificación temprana también puede organizarse mediante escenarios adversos. Semmelrock et al. (2025) permiten comprender la utilidad de evaluar cómo se comportan sistemas y procedimientos bajo condiciones diferentes a las inicialmente previstas. El investigador puede simular pérdida de datos, menor participación, cambios en la distribución de variables o fallos en determinadas etapas del análisis. Estas representaciones ayudan a reconocer qué partes del diseño son más vulnerables y qué medidas preventivas pueden establecerse. La finalidad no es anticipar con certeza todos los problemas, sino aumentar la capacidad del proyecto para responder a contingencias sin alterar arbitrariamente sus criterios metodológicos.

La identificación temprana de riesgos metodológicos adquiere mayor valor cuando se integra de forma transversal desde la formulación del problema hasta el análisis previsto. Contreras et al. (2024) permiten sostener que el uso responsable de inteligencia artificial requiere evaluación crítica, supervisión y trazabilidad de las decisiones. Las herramientas inteligentes pueden señalar incoherencias, simular escenarios, detectar posibles fallas y organizar alertas, pero no eliminan la incertidumbre propia del proceso científico. Su función consiste en ampliar la capacidad preventiva del investigador. Un diseño metodológicamente robusto es aquel que reconoce sus vulnerabilidades, establece controles y conserva mecanismos de revisión antes de iniciar la ejecución.

5.2 Detección de sesgos en la formulación y delimitación del estudio

La detección de sesgos en la formulación y delimitación del estudio permite reconocer decisiones iniciales que pueden condicionar de manera injustificada el modo en que se define el problema, se selecciona la población o se interpretan las posibles relaciones entre fenómenos. Omiye et al. (2023) permiten advertir que los sistemas de inteligencia artificial pueden reproducir desigualdades o representaciones sesgadas presentes en los datos y contextos con los que operan. Por ello, utilizar estas herramientas para formular problemas exige revisar si sus sugerencias privilegian determinados grupos, perspectivas o categorías y si excluyen dimensiones relevantes del fenómeno que deberían permanecer abiertas a examen.

Un primer sesgo puede aparecer cuando el problema se formula a partir de supuestos que presentan como naturales relaciones todavía no comprobadas. Kontiainen et al. (2022) permiten considerar que los sistemas automatizados pueden reflejar patrones preexistentes y proyectarlos sobre nuevas decisiones. En investigación, esto obliga a examinar si una formulación atribuye anticipadamente causas, responsabilidades o características a determinados grupos. La inteligencia artificial puede ayudar a identificar expresiones que contienen generalizaciones o asociaciones implícitas, pero la revisión requiere criterio metodológico. El objetivo consiste en construir un problema abierto a comprobación y no una pregunta diseñada para confirmar una interpretación previamente asumida.

La delimitación poblacional constituye otro punto sensible. Joyce et al. (2023) permiten observar que los modelos de inteligencia artificial pueden mostrar diferencias de desempeño y representación entre grupos, lo que vuelve necesario examinar críticamente las categorías utilizadas. Al definir participantes, el investigador debe preguntarse si ciertos grupos quedan excluidos sin una razón metodológica suficiente o si las categorías empleadas simplifican identidades y condiciones heterogéneas. La inteligencia artificial puede comparar distintas delimitaciones y señalar posibles ausencias, aunque no determina por sí misma qué población resulta apropiada. La inclusión o exclusión debe justificarse mediante el problema, los objetivos y las condiciones del estudio.

Los sesgos también pueden introducirse mediante el lenguaje con que se describe el fenómeno. Zárate (2022) permite situar la discusión sobre inteligencia artificial dentro de una perspectiva crítica que exige examinar sus implicaciones sociales y éticas. Términos valorativos, expresiones estigmatizantes o categorías construidas desde una sola perspectiva pueden orientar el estudio antes de recopilar evidencia. Una herramienta inteligente puede utilizarse para proponer redacciones alternativas y detectar formulaciones potencialmente cargadas. Sin

embargo, la neutralidad lingüística no se logra únicamente sustituyendo palabras; requiere revisar qué supuestos conceptuales sostienen la forma en que se define el problema y a quiénes afecta esa definición.

Tabla 13

Matriz para detectar sesgos en la formulación y delimitación del estudio

Dimensión de revisión	Pregunta de control	Posible manifestación del sesgo	Acción preventiva
Formulación del problema	¿Se presupone una explicación antes de obtener evidencia?	Relaciones causales o juicios incorporados en el planteamiento	Reformular de manera abierta
Población	¿Algún grupo queda excluido sin justificación?	Subrepresentación o delimitación arbitraria	Revisar criterios de inclusión
Categorías	¿Las clasificaciones simplifican excesivamente el fenómeno?	Agrupaciones rígidas o poco pertinentes	Contrastar definiciones y contexto
Lenguaje	¿La redacción contiene valoraciones o estigmas?	Términos cargados o generalizaciones	Sustituir expresiones y revisar supuestos
Contexto	¿Se generalizan conclusiones desde escenarios específicos?	Descontextualización	Precisar límites del estudio
Uso de IA	¿Las sugerencias del sistema se aceptan sin contraste?	Reproducción de patrones preexistentes	Aplicar revisión humana y verificación

Nota. Elaboración propia. La matriz organiza puntos de control para revisar decisiones iniciales antes de consolidar el diseño.

La tabla evidencia que el sesgo puede originarse antes de la recolección de datos y quedar incorporado en decisiones aparentemente formales. Bienefeld et al. (2023) permiten considerar que la confianza depositada en sistemas automatizados debe ajustarse a sus capacidades y limitaciones reales. Si una herramienta sugiere una población, una categoría o una formulación, esa propuesta no debería adoptarse únicamente porque parezca coherente. Conviene contrastarla con alternativas, revisar quiénes podrían quedar invisibilizados y comprobar si la recomendación responde al problema científico. La supervisión humana funciona, así como un mecanismo para impedir que la automatización consolide decisiones poco justificadas.

La delimitación contextual también puede producir sesgos cuando las condiciones particulares de un escenario se presentan como representativas de una realidad más amplia. Contreras et al.

(2024) permiten relacionar el uso responsable de inteligencia artificial con la necesidad de mantener control, transparencia y revisión de las decisiones asistidas. La herramienta puede comparar contextos y señalar diferencias, pero el investigador debe precisar hasta dónde puede extenderse la formulación del problema. Una delimitación adecuada reconoce particularidades institucionales, sociales o territoriales sin convertirlas en características universales. Esto reduce el riesgo de construir preguntas cuya propia redacción ya contiene generalizaciones que exceden el alcance posible del estudio.

Otro riesgo surge cuando la búsqueda de antecedentes se orienta únicamente hacia información que confirma la formulación inicial. Omiye et al. (2023) permiten advertir que los resultados generados por sistemas inteligentes pueden reproducir patrones dominantes y dejar menos visibles perspectivas minoritarias. Para disminuir este efecto, la revisión asistida debería incorporar términos alternativos, enfoques diferentes y búsquedas dirigidas a identificar evidencia contradictoria. El objetivo no consiste en acumular referencias favorables al problema, sino en comprobar si su delimitación resiste el contraste con interpretaciones distintas. Una formulación más sólida reconoce tensiones y evita construir la investigación sobre una selección confirmatoria de antecedentes.

La detección de sesgos debe mantenerse como un proceso iterativo durante la formulación. Joyce et al. (2023) permiten considerar que las diferencias de representación o desempeño no siempre son evidentes en una primera revisión. Por ello, cada modificación de población, contexto, categorías o lenguaje debería someterse nuevamente a análisis. La inteligencia artificial puede ayudar a generar versiones alternativas y comparar sus posibles implicaciones, pero no sustituye la revisión metodológica ni la sensibilidad frente a las condiciones sociales del estudio. El propósito es identificar cómo una decisión aparentemente pequeña puede modificar quiénes quedan incluidos, qué relaciones se consideran relevantes y qué interpretaciones parecen posibles.

Una formulación y delimitación metodológicamente cuidadosas requieren combinar precisión científica con revisión crítica de los supuestos incorporados. Zárate (2022) permite situar la inteligencia artificial dentro de debates que exigen considerar sus efectos más allá de la eficiencia técnica. En este contexto, las herramientas inteligentes pueden apoyar la identificación de generalizaciones, exclusiones, categorías rígidas o lenguaje sesgado, pero sus propias respuestas también deben ser examinadas. La reducción de sesgos depende de contrastar perspectivas, justificar los límites establecidos y mantener trazabilidad sobre las

decisiones adoptadas. Detectar estas distorsiones tempranamente evita que se propaguen hacia las siguientes fases del proyecto.

5.3 Evaluación de sesgos asociados con la selección de participantes y muestras

La selección de participantes y muestras puede introducir sesgos capaces de afectar la validez, la representatividad y el alcance de los resultados. Kontiainen et al. (2022) permiten considerar que los sistemas automatizados pueden reproducir patrones presentes en los datos y amplificar desequilibrios existentes entre grupos. Aplicada al diseño de investigaciones, esta advertencia obliga a revisar si la muestra refleja de manera razonable la población definida y si ciertos segmentos quedan sistemáticamente excluidos. La inteligencia artificial puede apoyar esta evaluación mediante análisis comparativos de composición, distribución y cobertura, pero la interpretación final requiere criterios metodológicos y conocimiento del contexto.

Uno de los riesgos más frecuentes es la subrepresentación de grupos con menor presencia en los datos disponibles. Omiye et al. (2023) muestran que los modelos pueden reflejar desigualdades cuando determinadas poblaciones aparecen de forma limitada o sesgada en los conjuntos utilizados. En investigación, una muestra con distribución desequilibrada puede producir estimaciones poco estables o conclusiones que representen mejor a los grupos dominantes. La inteligencia artificial puede ayudar a identificar estas asimetrías y simular cómo cambiaría la composición bajo distintos criterios de selección. Sin embargo, la corrección del desequilibrio debe responder a objetivos científicos y no a ajustes automáticos sin justificación.

El sesgo de selección también puede aparecer cuando los criterios de inclusión favorecen participantes más accesibles, disponibles o dispuestos a colaborar. Kapoor y Narayanan (2023) permiten advertir que decisiones aparentemente prácticas pueden afectar la robustez de los resultados cuando modifican la estructura real de los datos. La inteligencia artificial puede comparar perfiles de participantes incluidos y excluidos para detectar diferencias sistemáticas. Esta revisión ayuda a reconocer si la muestra termina concentrándose en ciertos subgrupos por razones operativas. No obstante, la herramienta no puede determinar por sí sola si esas diferencias comprometen el estudio; esa valoración depende del problema y del diseño.

Las muestras obtenidas por conveniencia requieren una revisión especialmente cuidadosa. Semmelrock et al. (2025) permiten considerar que el comportamiento de sistemas analíticos puede variar cuando los datos de entrada no representan adecuadamente la diversidad esperada. En investigaciones con acceso limitado a participantes, la inteligencia artificial puede simular

escenarios con distintas composiciones y mostrar cómo ciertos subgrupos quedarían sobrerrepresentados. Esta función no transforma una muestra no probabilística en representativa, pero ayuda a anticipar restricciones en la interpretación. El investigador debe describir con transparencia el procedimiento de selección y evitar generalizaciones que excedan el alcance real de los datos obtenidos.

Otro sesgo puede derivarse de la pérdida diferencial de participantes durante el estudio. Ciobanu et al. (2024) permiten situar la evaluación de calidad metodológica dentro de procesos donde deben considerarse consistencia, estabilidad y condiciones de aplicación. Si abandonan con mayor frecuencia personas con determinadas características, la muestra final puede diferir sustancialmente de la inicial. La inteligencia artificial puede ayudar a detectar patrones de abandono y comparar perfiles entre quienes permanecen y quienes se retiran. Esta información permite valorar posibles distorsiones, pero la interpretación debe considerar las causas del abandono y su relación con las variables centrales del estudio.

La estratificación o segmentación de la muestra también puede introducir sesgos cuando las categorías utilizadas son inadecuadas. Kontiainen et al. (2022) permiten advertir que la forma en que se clasifican los grupos influye en la representación y en las conclusiones posteriores. Una herramienta inteligente puede detectar distribuciones desiguales entre estratos o señalar categorías con muy pocos casos. Sin embargo, la decisión de agrupar participantes debe basarse en criterios conceptuales y metodológicos. Crear categorías únicamente porque facilitan el análisis puede ocultar diferencias relevantes o producir agrupaciones artificiales que no corresponden con la estructura real de la población.


La inteligencia artificial puede utilizarse además para comparar escenarios de muestreo antes de ejecutar el estudio. Semmelrock et al. (2025) permiten relacionar esta práctica con la evaluación de alternativas bajo diferentes condiciones. El investigador puede simular qué ocurriría si cambian criterios de inclusión, proporciones de subgrupos o tasas previstas de respuesta. Estos escenarios ayudan a identificar configuraciones con mayor riesgo de sesgo y a anticipar dificultades de cobertura. Su función es preventiva y exploratoria. No sustituyen los procedimientos estadísticos para definir una muestra ni permiten asegurar que la distribución simulada se reproducirá en la población real.

Otro aspecto relevante es el sesgo derivado de datos históricos o registros previamente disponibles. Omiye et al. (2023) permiten considerar que los datos existentes pueden contener

desigualdades previas que luego se reproducen en análisis automatizados. Si una investigación selecciona participantes a partir de bases institucionales incompletas o registros que excluyen ciertos grupos, la muestra estará condicionada desde el inicio. La inteligencia artificial puede ayudar a comparar fuentes, detectar ausencias y señalar diferencias de cobertura. Sin embargo, la solución requiere comprender cómo se generaron esos registros y qué poblaciones pudieron quedar fuera antes de cualquier procedimiento automatizado.

Figura 9

Uso de IA en la selección de muestras



Nota. La figura sintetiza aportes y limitaciones del uso de inteligencia artificial en la selección de muestras, destacando la necesidad de supervisar posibles sesgos y problemas de representatividad.

La evaluación de sesgos debe considerar también las consecuencias para la generalización. Kapoor y Narayanan (2023) permiten advertir que resultados aparentemente sólidos pueden perder validez externa cuando la estructura de la muestra no corresponde con la población sobre la cual se pretende inferir. La inteligencia artificial puede apoyar análisis de sensibilidad y mostrar cómo cambian ciertos resultados bajo distribuciones alternativas. Esta información es útil para estimar la fragilidad de las conclusiones, pero no elimina las limitaciones del muestreo. El investigador debe ajustar el alcance de sus afirmaciones a la composición real de la muestra y a las condiciones bajo las cuales fue obtenida.

La supervisión de estos sesgos debe mantenerse durante todas las fases de selección y no limitarse al diseño inicial. Ciobanu et al. (2024) permiten comprender que la evaluación metodológica requiere seguimiento continuo de condiciones que pueden alterar la calidad de los datos. La composición puede cambiar por rechazos, pérdidas, exclusiones posteriores o errores en los registros. Las herramientas inteligentes pueden generar alertas cuando aparecen desequilibrios relevantes y facilitar comparaciones entre etapas. Aun así, cada corrección debe documentarse y justificarse para evitar modificaciones oportunistas realizadas después de observar el comportamiento de los datos.

La evaluación de sesgos asociados con participantes y muestras adquiere mayor rigor cuando combina análisis de cobertura, composición, pérdidas y capacidad de generalización. Kontiainen et al. (2022) permiten recordar que los sistemas automatizados pueden reproducir desigualdades si trabajan con datos sesgados, mientras que la responsabilidad metodológica permanece en el investigador. La inteligencia artificial puede detectar patrones, simular alternativas y señalar subgrupos insuficientemente representados, pero no sustituye la justificación del procedimiento de muestreo. Una muestra metodológicamente sólida requiere criterios explícitos, revisión continua y una interpretación de resultados proporcional a las condiciones reales de selección.

5.4 Análisis de posibles sesgos en instrumentos y procedimientos de recolección de datos

El análisis de posibles sesgos en instrumentos y procedimientos de recolección de datos busca identificar distorsiones que pueden incorporarse antes, durante o después de la obtención de la información. Omiye et al. (2023) permiten advertir que los sistemas de inteligencia artificial pueden reproducir sesgos presentes en los datos y contextos con los que operan. En investigación, esta posibilidad exige revisar no solo los resultados, sino también la forma en que se construyen preguntas, categorías y protocolos. Un instrumento aparentemente neutral puede favorecer determinadas respuestas o excluir experiencias relevantes si sus contenidos parten de supuestos no suficientemente examinados.

Los sesgos pueden originarse en la redacción de los ítems. Salah et al. (2025) permiten considerar la inteligencia artificial como apoyo para detectar preguntas ambiguas, sugestivas o formuladas desde una perspectiva demasiado restringida. Un reactivo puede inducir una respuesta cuando incorpora juicios de valor, presupone una conducta o utiliza términos que no significan lo mismo para todos los participantes. Las herramientas inteligentes pueden

proponer alternativas más neutrales y señalar expresiones problemáticas, pero sus sugerencias deben revisarse críticamente. La corrección lingüística no garantiza ausencia de sesgo si la estructura conceptual del ítem continúa orientando la respuesta.

La selección de contenidos dentro de un instrumento también puede producir sesgos. Terry et al. (2025) permiten situar la inteligencia artificial dentro de procesos iterativos de revisión donde es posible comparar la cobertura de dimensiones y detectar concentraciones excesivas. Si un cuestionario representa con mayor detalle algunos componentes del constructor y deja otros apenas considerados, los resultados pueden reflejar una visión parcial del fenómeno. La herramienta puede ayudar a identificar esta distribución desigual, aunque la evaluación definitiva requiere revisar la definición teórica de la variable. El equilibrio debe responder a la estructura conceptual y no a una distribución numérica artificial entre ítems.

Otro riesgo aparece cuando el procedimiento de aplicación no se mantiene constante. Posso et al. (2025) permiten relacionar la calidad de los datos con la coherencia entre instrumento, condiciones de aplicación y objetivos del estudio. Cambios en instrucciones, tiempo disponible, orden de preguntas o apoyo ofrecido a determinados participantes pueden introducir diferencias ajenas al fenómeno investigado. La inteligencia artificial puede ayudar a revisar protocolos y detectar variaciones entre versiones o secuencias. Sin embargo, la estandarización debe establecerse antes del trabajo de campo y mantenerse de forma documentada para reducir decisiones improvisadas durante la recolección.

En entrevistas, el sesgo puede surgir de preguntas demasiado dirigidas o de una secuencia que condicione las respuestas posteriores. Panfilova et al. (2026) permiten considerar las herramientas inteligentes como apoyo para revisar guías y simular posibles rutas de interacción. Un modelo puede señalar interrogantes que contienen respuestas implícitas, supuestos o formulaciones cerradas cuando se busca obtener relatos amplios. También puede ayudar a reorganizar la secuencia temática. No obstante, la neutralidad depende igualmente de la actuación del entrevistador, de sus intervenciones y de la forma en que profundiza o interpreta las respuestas durante la conversación.

La observación presenta riesgos específicos relacionados con la selección de conductas y categorías. Keadle et al. (2024) permiten considerar el uso de herramientas automatizadas para registrar y clasificar comportamientos, pero estas funciones dependen de criterios previamente definidos. Un protocolo puede sesgar la recolección si privilegia eventos fáciles de observar y

omite conductas menos visibles pero relevantes. La inteligencia artificial puede ayudar a revisar la cobertura de categorías y a identificar discrepancias en la codificación. Sin embargo, la automatización no elimina el problema de decidir qué se observa, qué se considera significativo y qué queda fuera del registro.

Los procedimientos automatizados de codificación también pueden introducir sesgos cuando el sistema interpreta de manera diferente conductas o expresiones según el contexto. Flemotomos et al. (2022) permiten situar la inteligencia artificial dentro de procesos de reconocimiento y clasificación que pueden complementar la codificación humana. Estas herramientas pueden reducir tareas repetitivas, pero requieren comprobación frente a criterios de referencia. Una clasificación consistente no necesariamente es correcta si reproduce una regla inadecuada. Por ello, conviene comparar resultados automatizados con evaluaciones humanas y examinar especialmente los casos ambiguos, los errores recurrentes y las categorías donde aparecen mayores discrepancias.

Otro tipo de sesgo procede del modo de administración del instrumento. Posso et al. (2025) permiten considerar que las condiciones de recolección pueden afectar la calidad y comparabilidad de las respuestas. Aplicaciones presenciales, digitales o asistidas pueden generar diferencias asociadas con acceso tecnológico, comprensión de instrucciones o disposición a responder. La inteligencia artificial puede ayudar a simular distintos escenarios y anticipar posibles dificultades, pero estas variaciones deben comprobarse en el contexto real. Cuando se utilizan modalidades distintas, conviene analizar si todas ofrecen condiciones equivalentes y si determinados grupos enfrentan mayores barreras para participar o completar el instrumento.

La detección de sesgos debe incluir una revisión de las respuestas obtenidas durante pruebas preliminares. Terry et al. (2025) permiten comprender que los procesos iterativos de evaluación pueden revelar patrones que no eran visibles durante la construcción del instrumento. Concentraciones anómalas, omisiones recurrentes o interpretaciones inesperadas pueden indicar problemas en un ítem o en el procedimiento. La inteligencia artificial puede facilitar la identificación de estos patrones y señalar segmentos que requieren revisión adicional. Sin embargo, cualquier modificación posterior debe justificarse metodológicamente y evitar cambios orientados únicamente a producir distribuciones más favorables o resultados más consistentes.

El análisis de sesgos en instrumentos y procedimientos requiere combinar revisión conceptual, control operativo y comprobación empírica. Omiye et al. (2023) permiten mantener presente que los sistemas inteligentes pueden amplificar distorsiones si se utilizan sin supervisión, mientras que su capacidad de comparación también puede emplearse para detectarlas tempranamente. La inteligencia artificial puede señalar problemas de redacción, cobertura, codificación y aplicación, pero no garantiza neutralidad por sí misma. Reducir sesgos exige decisiones explícitas, protocolos consistentes y revisión continua desde el diseño del instrumento hasta la obtención y evaluación de los datos.

5.5 Evaluación de riesgos éticos y de protección de datos en investigaciones asistidas por inteligencia artificial

La evaluación de riesgos éticos y de protección de datos resulta indispensable cuando la inteligencia artificial interviene en alguna fase del proceso investigativo. Andrade et al. (2024) permiten situar esta exigencia en relación con el tratamiento responsable de información y con la necesidad de preservar los derechos de las personas participantes. El uso de herramientas inteligentes puede ampliar las posibilidades de análisis, pero también introduce riesgos vinculados con privacidad, confidencialidad, almacenamiento y reutilización de datos. Por ello, la incorporación de estas tecnologías debe planificarse desde el diseño del estudio y no resolverse únicamente cuando comienza la recolección de información.

El consentimiento informado necesita reflejar de manera comprensible cómo se utilizará la inteligencia artificial dentro del estudio. Sánchez (2024) permite considerar que la transparencia constituye un componente relevante cuando se emplean sistemas capaces de procesar, clasificar o transformar información proporcionada por participantes. No basta con informar que los datos serán utilizados con fines académicos si parte de su tratamiento se realizará mediante plataformas automatizadas. El investigador debe definir qué información será procesada, con qué finalidad y bajo qué condiciones. Esta claridad permite que la participación se sustente en una comprensión razonable del procedimiento y de los riesgos asociados.

La confidencialidad adquiere especial importancia cuando se manejan entrevistas, historias, registros institucionales u otros materiales que pueden contener datos identificables. Contreras et al. (2024) permiten relacionar el uso responsable de inteligencia artificial con mecanismos de control y supervisión sobre la información utilizada. Ingresar datos directamente en

herramientas externas puede exponer contenidos que originalmente fueron recolectados bajo condiciones específicas de resguardo. Antes de utilizar una plataforma, conviene reducir identificadores, limitar la cantidad de información transferida y comprobar si realmente es necesario procesar datos sensibles para cumplir el objetivo analítico del estudio.

El tratamiento de información sensible requiere medidas más estrictas que el manejo de datos generales. Cabanillas-García et al. (2025) permiten situar la protección de datos como una dimensión que debe integrarse a las decisiones metodológicas y éticas del proyecto. La inteligencia artificial no debería recibir información personal innecesaria cuando el mismo análisis puede realizarse con datos anonimizados, agregados o previamente depurados. Además, la anonimización debe evaluarse según el contexto, porque eliminar nombres no siempre impide identificar indirectamente a una persona cuando permanecen combinaciones particulares de características, experiencias o referencias institucionales dentro del conjunto procesado.

Tabla 14

Matriz para evaluar riesgos éticos y de protección de datos en investigaciones asistidas por inteligencia artificial

Dimensión	Riesgo principal	Pregunta de control	Medida preventiva
Consentimiento	Uso de IA no informado	¿Los participantes conocen cómo se procesará su información?	Incorporar información clara sobre el uso de herramientas inteligentes
Confidencialidad	Exposición de datos identificables	¿La plataforma necesita recibir información personal?	Minimizar y anonimizar datos antes del procesamiento
Datos sensibles	Identificación directa o indirecta	¿Existen variables que requieren protección reforzada?	Restringir acceso y eliminar información innecesaria
Plataformas externas	Pérdida de control sobre los datos	¿Se conocen las condiciones de tratamiento de la herramienta?	Evaluar previamente el servicio utilizado
Transparencia	Ocultamiento del uso de IA	¿Puede reconstruirse qué tareas fueron asistidas?	Documentar herramientas y funciones empleadas
Integridad científica	Delegación indebida de decisiones	¿La supervisión humana se mantiene en etapas críticas?	Verificar resultados y conservar responsabilidad investigadora

Nota. Elaboración propia. La matriz funciona como control preventivo antes de incorporar herramientas inteligentes al tratamiento de información.

La utilización de plataformas de terceros introduce riesgos que deben evaluarse antes de cargar cualquier información. Gallent et al. (2023) permiten considerar que las implicaciones éticas de la inteligencia artificial en el ámbito académico incluyen cuestiones relacionadas con privacidad, responsabilidad y manejo de contenido. El investigador necesita conocer qué tipo de información está enviando y evitar asumir que todas las plataformas ofrecen las mismas condiciones de resguardo. Cuando no sea posible establecer con suficiente claridad cómo se gestionarán los datos, resulta metodológicamente más prudente limitar el contenido transferido o utilizar procedimientos alternativos que reduzcan la exposición.

La transparencia sobre el uso de inteligencia artificial también forma parte de la integridad científica. Penabad et al. (2024) permiten relacionar esta exigencia con la necesidad de hacer explícita la intervención de herramientas automatizadas en procesos académicos e investigativos. Si la inteligencia artificial participa en organización, codificación, síntesis o análisis preliminar, debe existir un registro suficiente para comprender qué función cumplió y qué decisiones permanecieron bajo control humano. Ocultar esa intervención dificulta evaluar la trazabilidad del procedimiento. La transparencia no significa atribuir autoría a la herramienta, sino documentar de manera adecuada su papel dentro del método utilizado.

Otro riesgo aparece cuando se delegan decisiones que afectan directamente a participantes o resultados sin una revisión suficiente. Contreras et al. (2024) permiten advertir que la supervisión humana sigue siendo necesaria cuando se emplean sistemas inteligentes en procesos sensibles. Una clasificación automática puede cometer errores, interpretar de forma inadecuada determinados contenidos o reproducir patrones sesgados. Si esas salidas influyen en inclusión, exclusión, categorización o interpretación de participantes, deben ser verificadas antes de convertirse en decisiones metodológicas. La responsabilidad ética permanece en el equipo investigador, incluso cuando una parte del procesamiento ha sido realizada mediante inteligencia artificial.

La protección de datos también exige considerar el ciclo completo de la información. Cabanillas-García et al. (2025) permiten comprender que los riesgos no terminan con la recolección, porque los datos atraviesan etapas de almacenamiento, procesamiento, análisis y eventual eliminación. Cuando intervienen herramientas inteligentes, conviene determinar qué versión de los datos se utiliza en cada fase, quién puede acceder a ella y qué información debe conservarse. Esta planificación reduce transferencias innecesarias y facilita controlar

materiales sensibles. La seguridad debe integrarse al procedimiento desde el inicio, en lugar de tratarse como una medida correctiva después de producirse una exposición.

La evaluación ética de investigaciones asistidas por inteligencia artificial requiere integrar consentimiento, confidencialidad, protección de información sensible, transparencia y supervisión humana dentro de una misma estrategia preventiva. Andrade et al. (2024) permiten situar estas responsabilidades como parte del diseño responsable del estudio y no como requisitos separados de la metodología. Las herramientas inteligentes pueden aportar capacidad de procesamiento y organización, pero su uso debe limitarse a funciones compatibles con los compromisos asumidos frente a participantes y datos. La decisión más adecuada será aquella que permita aprovechar la tecnología sin reducir el control, la trazabilidad ni las garantías de protección.

5.6 Análisis de viabilidad técnica, temporal, económica y operativa del proyecto

El análisis de viabilidad permite determinar si un proyecto puede ejecutarse bajo condiciones técnicas, temporales, económicas y operativas razonables antes de comprometer recursos y comenzar el trabajo de campo. Castelo (2025) permite vincular esta valoración con la necesidad de examinar la factibilidad de las decisiones investigativas en función de los recursos disponibles y de las exigencias del diseño. La inteligencia artificial puede apoyar esta fase mediante la comparación de escenarios, la identificación de restricciones y la organización de requerimientos. Su utilidad radica en anticipar incompatibilidades entre lo metodológicamente deseable y lo realmente ejecutable dentro del contexto del proyecto.

La viabilidad técnica se refiere a la disponibilidad y suficiencia de herramientas, infraestructura, conocimientos y capacidades necesarias para desarrollar el estudio. Hartung (2025) permite considerar que los entornos científicos apoyados por automatización requieren condiciones técnicas adecuadas, mecanismos de control y límites operativos claramente definidos. En un proyecto asistido por inteligencia artificial, esta dimensión incluye acceso a software, capacidad de procesamiento, compatibilidad entre plataformas y competencias para utilizar las herramientas seleccionadas. La simulación puede ayudar a identificar dependencias críticas y posibles fallas, aunque la existencia de una tecnología disponible no garantiza que resulte apropiada para las necesidades metodológicas específicas del estudio.

La viabilidad temporal exige comprobar si las actividades pueden completarse dentro del periodo previsto sin reducir controles metodológicos o eliminar etapas necesarias. Tobias y

Wahab (2025) permiten observar que los procesos científicos automatizados dependen de secuencias conectadas de planificación, ejecución, análisis y ajuste. Esta lógica puede utilizarse para construir cronogramas y detectar tareas cuyo retraso afectaría fases posteriores. La inteligencia artificial puede representar diferentes secuencias y estimar consecuencias operativas de cambios en el calendario. Sin embargo, estas proyecciones deben manejarse con prudencia, porque los tiempos reales pueden variar por acceso a participantes, permisos, revisión de datos o contingencias imprevistas.

La dimensión económica comprende los recursos financieros necesarios para sostener las actividades previstas, aunque debe evaluarse con especial prudencia cuando la evidencia disponible no aborda de manera específica todos los costos de un proyecto. Castelo (2025) permite considerar la disponibilidad de recursos como parte de la factibilidad investigativa. La inteligencia artificial puede ayudar a organizar categorías de gasto, comparar alternativas operativas y detectar actividades que incrementan las necesidades de recursos. No obstante, cualquier estimación económica debe construirse con precios, condiciones institucionales y requerimientos reales del proyecto, evitando asumir que la automatización producirá necesariamente reducciones de costos o mayores niveles de eficiencia.

La viabilidad operativa examina si el procedimiento puede funcionar de forma sostenida dentro del contexto donde será implementado. Fushimi et al. (2025) permiten considerar que los sistemas científicos automatizados requieren coordinación entre tareas, controles y mecanismos de supervisión para mantener ciclos de trabajo consistentes. En un proyecto convencional o asistido por inteligencia artificial, esta dimensión incluye disponibilidad de personal, acceso a participantes, secuencia de actividades, responsabilidades y capacidad para responder ante fallos. La simulación puede identificar cuellos de botella y dependencias entre etapas. Su propósito es anticipar dificultades prácticas sin reducir la evaluación a una simple comprobación de recursos disponibles.

Tabla 15
Matriz para analizar la viabilidad del proyecto antes de su ejecución

Dimensión	Pregunta de evaluación	Aspectos que deben comprobarse	Apoyo posible de la inteligencia artificial
Técnica	¿Existen capacidades y recursos tecnológicos suficientes?	Software, equipos, compatibilidad y competencias	Comparar requerimientos y dependencias

Dimensión	Pregunta de evaluación	Aspectos que deben comprobarse	Apoyo posible de la inteligencia artificial
Temporal	¿Las etapas pueden completarse dentro del periodo previsto?	Duración, secuencia, permisos y márgenes de contingencia	Simular cronogramas alternativos
Económica	¿Los recursos financieros cubren las actividades planificadas?	Gastos de aplicación, procesamiento, acceso y soporte	Organizar escenarios de costos
Operativa	¿El procedimiento puede ejecutarse en el contexto real?	Personal, participantes, responsabilidades y logística	Detectar cuellos de botella
Integración	¿Las cuatro dimensiones son compatibles entre sí?	Relación entre recursos, tiempo y exigencias del diseño	Comparar configuraciones del proyecto

Nota. Elaboración propia. La matriz permite examinar conjuntamente restricciones que podrían comprometer la ejecución del proyecto.

Las dimensiones de viabilidad no deben analizarse como componentes independientes. Cedeño et al. (2024) permiten situar la inteligencia artificial como apoyo para organizar decisiones complejas y explorar alternativas dentro del diseño investigativo. Una opción técnicamente posible puede resultar temporalmente inviable, mientras que una estrategia económicamente accesible puede exigir una carga operativa difícil de sostener. La simulación conjunta permite observar estas relaciones y evitar decisiones basadas en un único criterio. El proyecto adquiere mayor factibilidad cuando sus requerimientos técnicos, tiempos, recursos y procedimientos pueden mantenerse simultáneamente sin alterar los objetivos ni reducir la calidad de la evidencia.

La inteligencia artificial puede contribuir mediante análisis de escenarios que modifiquen una condición a la vez. Hartung (2025) permite considerar la utilidad de establecer límites y respuestas ante situaciones inesperadas dentro de procesos automatizados. El investigador puede explorar qué ocurre si se reduce el tiempo disponible, falla una herramienta, disminuye el acceso a participantes o aumenta la carga de procesamiento. Estas simulaciones ayudan a reconocer componentes críticos y a diseñar alternativas de contingencia. No obstante, un escenario generado representa una posibilidad condicionada por supuestos y no una predicción exacta sobre cómo evolucionará el proyecto durante su ejecución.

También conviene identificar los costos metodológicos de simplificar el proyecto para hacerlo más viable. Tobias y Wahab (2025) permiten comprender que la eficiencia operativa debe mantenerse articulada con la calidad de los ciclos científicos. Reducir número de participantes,

etapas de control o procedimientos de revisión puede disminuir tiempo y recursos, pero también debilitar la capacidad de respuesta del estudio. La inteligencia artificial puede mostrar estas compensaciones y facilitar comparaciones entre configuraciones. La opción más conveniente no debe ser necesariamente la menos costosa o rápida, sino aquella que mantenga una relación aceptable entre exigencias científicas y posibilidades reales de ejecución.

La evaluación económica y temporal requiere especial cautela porque depende en gran medida del contexto específico del proyecto. Cedeño et al. (2024) permiten considerar que las herramientas inteligentes pueden apoyar la planificación y organización de recursos, pero no sustituir información real sobre disponibilidad institucional, costos o tiempos de acceso. Una proyección automatizada puede omitir trámites, interrupciones, necesidades de capacitación o diferencias entre modalidades de aplicación. Por ello, estas dimensiones deben alimentarse con datos verificables y actualizarse cuando cambien las condiciones. La inteligencia artificial funciona mejor como herramienta de comparación que como fuente autónoma de estimaciones presupuestarias o cronogramas definitivos.

El análisis de viabilidad adquiere sentido cuando permite reconocer anticipadamente qué aspectos del proyecto necesitan ajustes antes de iniciar su ejecución. Fushimi et al. (2025) permiten situar la planificación científica como un proceso donde coordinación, control y adaptación deben mantenerse articulados. La inteligencia artificial puede organizar requisitos, comparar escenarios y señalar dependencias, pero la factibilidad final depende de condiciones concretas que deben comprobarse directamente. Un proyecto viable mantiene compatibilidad entre capacidades técnicas, tiempos, recursos económicos y procedimientos operativos, sin sacrificar elementos esenciales del diseño únicamente para facilitar su implementación.

5.7 Evaluación integral de la coherencia y factibilidad del diseño de investigación antes de su ejecución

La evaluación integral de la coherencia y factibilidad del diseño permite comprobar si los componentes metodológicos funcionan como una estructura articulada antes de iniciar la ejecución. Posso et al. (2025) permiten relacionar esta revisión con la necesidad de mantener correspondencia entre problema, objetivos, variables o categorías, participantes, instrumentos y procedimientos. La inteligencia artificial puede apoyar este examen mediante comparaciones cruzadas entre los elementos del proyecto y la detección de incompatibilidades preliminares. Su utilidad radica en facilitar una revisión sistemática del diseño completo, evitando que

decisiones correctas de manera aislada produzcan inconsistencias cuando se integran dentro de una misma estrategia investigativa.

Una primera dimensión corresponde a la coherencia entre problema, pregunta y objetivos. Cedeño et al. (2024) permiten situar la inteligencia artificial como apoyo para organizar y revisar componentes del proceso investigativo. Una herramienta puede comparar formulaciones y señalar cuando un objetivo introduce variables, poblaciones o alcances que no aparecen en la pregunta original. Esta revisión resulta útil para detectar desplazamientos conceptuales ocurridos durante el diseño. Sin embargo, la correspondencia no debe evaluarse únicamente por similitud lingüística. Dos componentes pueden compartir palabras y, aun así, responder a propósitos metodológicos diferentes, por lo que la revisión exige interpretación académica.

La coherencia entre diseño, datos y método de análisis constituye otro punto crítico. Kapoor y Narayanan (2023) permiten advertir que decisiones analíticas inadecuadas pueden producir conclusiones engañosas incluso cuando el procedimiento computacional funciona correctamente. Antes de ejecutar el estudio, conviene comprobar si el tipo de información prevista permite responder la pregunta y si el análisis seleccionado resulta compatible con la estructura de los datos. La inteligencia artificial puede señalar posibles discrepancias y comparar alternativas. No obstante, la selección final debe sustentarse en criterios técnicos, evitando que la herramienta recomiende métodos únicamente porque son frecuentes o fácilmente automatizables.

La factibilidad también depende de la estabilidad del diseño frente a condiciones distintas de las inicialmente previstas. Semmelrock et al. (2025) permiten considerar la utilidad de evaluar sistemas y procedimientos bajo escenarios variados antes de utilizarlos de manera definitiva. En investigación, esta lógica permite simular pérdidas de participantes, datos incompletos, dificultades de acceso o variaciones en la composición muestral. Si pequeñas modificaciones comprometen completamente la capacidad de responder la pregunta, el diseño puede requerir ajustes preventivos. La simulación no predice exactamente lo que ocurrirá, pero ayuda a identificar componentes excesivamente dependientes de condiciones ideales.

La evaluación integral debe examinar también si el diseño favorece comprensión e interpretación suficiente del fenómeno. Krenn et al. (2022) permiten sostener que el valor científico no se reduce al desempeño predictivo o a la obtención de resultados técnicamente


precisos. Un diseño puede producir datos abundantes y, sin embargo, responder de manera insuficiente al problema si sus procedimientos no permiten interpretar las relaciones relevantes. La inteligencia artificial puede ayudar a representar qué tipo de evidencia generará cada decisión metodológica. El investigador debe valorar si esa evidencia será suficiente para sostener las conclusiones previstas sin exceder el alcance real del estudio.

La incorporación de inteligencia artificial introduce además exigencias específicas de supervisión. Castillo (2023) permite considerar críticamente el riesgo de delegar decisiones metodológicas a sistemas cuyo funcionamiento o recomendaciones no siempre son plenamente comprendidos. La evaluación previa debe identificar qué tareas estarán automatizadas, cuáles requerirán revisión y dónde se mantendrán controles humanos. Una dependencia excesiva puede dificultar la reconstrucción del razonamiento metodológico o reducir la capacidad para detectar errores. La factibilidad no consiste únicamente en comprobar que la herramienta funciona, sino en asegurar que su utilización sea compatible con las competencias, responsabilidades y controles disponibles.

La transparencia y la trazabilidad forman parte de la coherencia global del diseño. Penabad et al. (2024) permiten vincular el uso responsable de inteligencia artificial con la necesidad de documentar de manera suficiente su intervención en el proceso académico. Antes de ejecutar el proyecto, debe ser posible identificar qué herramientas se utilizarán, con qué finalidad y qué decisiones podrán verse afectadas por sus resultados. Esta documentación permite revisar posteriormente el procedimiento y distinguir entre actividades automatizadas y decisiones investigativas. Un diseño difícil de reconstruir puede presentar problemas de verificabilidad incluso cuando sus resultados aparenten consistencia técnica.

Figura 10

Evaluación integral del diseño de investigación



Nota. La figura integra criterios complementarios para valorar la solidez del diseño de investigación, considerando su coherencia metodológica, viabilidad y el control de la intervención de la inteligencia artificial.

La factibilidad debe incorporar asimismo la relación entre capacidades tecnológicas y supervisión humana. Bienefeld et al. (2023) permiten considerar que la confianza en sistemas automatizados necesita ajustarse a sus capacidades reales y a las condiciones específicas de uso. Una herramienta puede funcionar adecuadamente en determinadas tareas y resultar insuficiente en otras que exigen interpretación contextual o juicio metodológico. Por ello, la evaluación integral debe establecer qué nivel de dependencia es razonable y dónde se requieren controles adicionales. Esta revisión ayuda a evitar tanto la aceptación automática de recomendaciones como el uso meramente decorativo de tecnologías que no aportan al diseño.

La evaluación integral se completa cuando el proyecto muestra continuidad entre sus componentes y mantiene condiciones razonables de ejecución, control y verificación. Posso et al. (2025) permiten situar la coherencia metodológica como una exigencia transversal, mientras que la inteligencia artificial puede facilitar comparaciones, simulaciones y detección de inconsistencias antes del trabajo de campo. Un diseño factible no es aquel que elimina toda incertidumbre, sino aquel que reconoce sus restricciones, conserva mecanismos de supervisión y puede ajustarse sin perder su lógica científica. Esta revisión final reduce el riesgo de ejecutar un proyecto formalmente completo, pero internamente desarticulado.

Conclusión

El diseño de proyectos de investigación asistido por inteligencia artificial adquiere sentido cuando la tecnología se incorpora como un recurso para ampliar las capacidades de exploración, contraste y revisión que intervienen antes de la ejecución del estudio. Su aporte más consistente se encuentra en aquellas tareas donde el investigador debe examinar grandes cantidades de información, comparar alternativas o detectar inconsistencias entre decisiones relacionadas. Esta función transforma la inteligencia artificial en un instrumento de apoyo metodológico cuyo valor depende de la claridad con que se definan los propósitos y criterios de cada interacción.

La incorporación de estas herramientas desde la identificación del problema modifica especialmente la forma de explorar información disponible. Organizar antecedentes, reconocer recurrencias, comparar contextos y examinar posibles vacíos permite construir una visión más estructurada del campo antes de formular una propuesta. Sin embargo, la disponibilidad de mecanismos automatizados para localizar patrones no convierte cada ausencia documental en una brecha científica ni cada tendencia en un problema relevante. La pertinencia continúa dependiendo de la capacidad para justificar qué conocimiento falta, por qué resulta necesario producirlo y bajo qué condiciones puede investigarse.

Esta distinción resulta decisiva porque una de las mayores posibilidades de la inteligencia artificial consiste precisamente en generar numerosas alternativas. Frente a un problema inicial, puede proponer enfoques, relaciones conceptuales, delimitaciones y preguntas diferentes en poco tiempo. Esa abundancia amplía el espacio de exploración, pero también exige criterios capaces de discriminar entre opciones plausibles y propuestas científicamente defendibles. El investigador necesita determinar cuáles mantienen correspondencia con la evidencia disponible, cuáles introducen supuestos no comprobados y cuáles desplazan el objeto hacia cuestiones distintas de la necesidad de conocimiento inicialmente reconocida.

La formulación de preguntas muestra con especial claridad esta relación entre generación tecnológica y razonamiento científico. Un modelo puede producir múltiples versiones, revisar ambigüedades y modificar población, contexto, variables o alcance. La utilidad de esas operaciones aparece cuando permiten observar cómo una pequeña modificación altera las exigencias del estudio. Términos relacionados con descripción, asociación, explicación o interpretación no representan diferencias meramente lingüísticas; condicionan qué evidencia será necesaria y qué inferencias podrán sostenerse posteriormente. Refinar una pregunta

implica, por ello, preservar la continuidad entre lenguaje, intención científica y posibilidades metodológicas.

La coherencia emerge, así como uno de los criterios transversales del diseño asistido. Problema, pregunta, objetivos, enfoque, población, muestra, técnicas, instrumentos y análisis forman un sistema de decisiones interdependientes. Una modificación introducida en uno de estos componentes puede exigir ajustes en varios de los restantes. La inteligencia artificial facilita la comparación simultánea de alternativas y puede señalar contradicciones que pasan inadvertidas durante una revisión lineal. Su aplicación más útil no consiste entonces en recomendar componentes aislados, sino en ayudar a comprobar si el proyecto conserva una lógica interna capaz de sostener el conocimiento que pretende producir.

La simulación metodológica amplía esta capacidad de revisión al permitir examinar decisiones antes de comprometer participantes, datos y recursos. Representar diferentes diseños, tamaños o configuraciones muestrales, procedimientos de recolección y estrategias analíticas permite anticipar consecuencias que serían más costosas de corregir después del trabajo de campo. Estas simulaciones deben interpretarse como escenarios condicionales y no como predicciones del comportamiento real del estudio. Su valor reside en hacer explícitos los supuestos utilizados, identificar dependencias entre etapas y someter las decisiones previstas a condiciones alternativas antes de consolidarlas.

Esta lógica preventiva resulta especialmente relevante porque la viabilidad metodológica no depende únicamente de que una alternativa sea conceptualmente adecuada. El acceso a participantes, la disponibilidad de información, los recursos técnicos, el tiempo y las capacidades de procesamiento condicionan lo que efectivamente puede realizarse. La inteligencia artificial permite organizar estas restricciones y comparar configuraciones posibles, pero una solución operativamente sencilla no es necesariamente la más apropiada. Reducir población, modificar técnicas o simplificar procedimientos solo resulta justificable cuando tales ajustes conservan la capacidad del proyecto para responder de manera suficiente a su pregunta científica.

El diseño de instrumentos confirma otro límite fundamental de la automatización. Generar ítems, preguntas de entrevista, categorías de observación o posibles reglas de codificación puede acelerar considerablemente una fase que exige múltiples formulaciones y revisiones. También permite identificar redundancias, ambigüedades y desajustes preliminares entre dimensiones e indicadores. Sin embargo, estas operaciones trabajan sobre representaciones

propuestas y no sobre el comportamiento real del instrumento. La claridad aparente de un reactivo o la coherencia semántica de una categoría no permiten establecer por sí mismas que el instrumento mide o registra adecuadamente aquello para lo cual fue diseñado.

Por esa razón, la simulación de respuestas y la revisión automatizada deben mantenerse dentro de sus límites metodológicos. Las respuestas producidas por un modelo pueden revelar posibles problemas estructurales, mostrar preguntas excesivamente dirigidas o identificar opciones de respuesta poco diferenciadas. No obstante, proceden de patrones generados artificialmente y no reproducen las interpretaciones, experiencias ni condiciones de participantes reales. La validación requiere procedimientos específicos y evidencia obtenida empíricamente. La inteligencia artificial puede contribuir a preparar mejor esa etapa, pero no convierte una comprobación simulada en una demostración de validez, confiabilidad o adecuación contextual.

Los riesgos asociados con el uso de estas tecnologías atraviesan todo el proceso y no aparecen únicamente cuando se analizan datos. Pueden introducirse desde la selección de antecedentes, la delimitación de una población o la forma de redactar una pregunta. Un conjunto de información incompleto puede conducir a identificar un vacío inexistente; una descripción sesgada puede orientar la selección de participantes; una formulación aparentemente neutral puede incorporar supuestos que condicionen las respuestas. Analizar estos riesgos desde el diseño permite reconocer que los errores generados o amplificadas por inteligencia artificial pueden trasladarse sucesivamente hacia decisiones posteriores.

La trazabilidad adquiere entonces una importancia metodológica específica. Cada afirmación obtenida mediante búsqueda asistida debe poder vincularse con una fuente comprobable, y cada modificación sustantiva del diseño necesita una justificación que pueda reconstruirse posteriormente. Registrar las decisiones permite distinguir qué elementos proceden de evidencia, cuáles corresponden a interpretaciones del investigador y cuáles surgieron como alternativas generadas durante la interacción con una herramienta. Esta diferenciación reduce la dependencia de procesos opacos y favorece una revisión crítica del proyecto, especialmente cuando varias iteraciones modifican progresivamente la formulación inicial.

La protección de datos establece, además, límites que no pueden definirse únicamente desde la eficiencia tecnológica. La posibilidad de procesar información mediante sistemas inteligentes no justifica incorporar datos personales, sensibles o identificables cuando estos no son indispensables. El diseño debe determinar con anticipación qué información será tratada, con

qué propósito, mediante qué herramientas y bajo qué medidas de protección. De esta manera, las decisiones sobre inteligencia artificial forman parte de la planificación ética del estudio y deben evaluarse junto con el consentimiento, la confidencialidad y las condiciones bajo las cuales se administrará la información recopilada.

En conjunto, el uso metodológicamente responsable de inteligencia artificial exige sustituir la lógica de aceptación de respuestas por una lógica de contraste. Una salida generada debe funcionar como alternativa que puede ser revisada, comparada, modificada o descartada según criterios explícitos. Este cambio de enfoque evita valorar una propuesta por su fluidez, rapidez o apariencia técnica. La utilidad científica aparece cuando la interacción obliga a examinar supuestos, considerar configuraciones diferentes y justificar decisiones con mayor precisión. La tecnología aporta capacidad de procesamiento; la solidez del diseño depende de cómo esa capacidad se incorpora al razonamiento investigativo.

Diseñar proyectos de investigación con inteligencia artificial implica, finalmente, utilizar la tecnología en aquellos puntos donde puede aumentar la capacidad de anticipación sin transferirle decisiones que requieren fundamento científico. El resultado deseable no es un proyecto construido automáticamente, sino un diseño sometido a más comparaciones, controles y preguntas antes de ejecutarse. Problemas mejor fundamentados, interrogantes más precisas, decisiones metodológicas contrastadas, instrumentos revisados y riesgos identificados constituyen resultados posibles de esta integración. Su calidad dependerá de conservar evidencia verificable, coherencia interna, trazabilidad y responsabilidad investigadora durante todo el proceso.

Bibliografía

- Andrade, D., Toapanta, M., Baño, M., y Gómez, E. (2024). Un enfoque de la inteligencia artificial para la protección de datos personales sustentando en la base legal. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, 5(4), 3808-3820. <https://doi.org/10.56712/latam.v5i4.2530>
- Arias, F., y Artigas, W. (2022). Cómo plantear problemas científicos relevantes identificando brechas de investigación. *Mujer Andina*, 1(1), 76-82. <https://doi.org/10.36881/ma.v1i1.644>
- Attali, Y., Runge, A., LaFlair, G., Yancey, K., Goodwin, S., Park, Y., y Davier, A. v. (2022). The interactive reading task: Transformer-based automatic item generation. *Frontiers in Artificial Intelligence*, 5. <https://doi.org/10.3389/frai.2022.903077>
- Ávila, E. (2024). Visualización de datos abiertos de investigación mediante grafos de conocimiento: metodología y aplicación de DDI-RDF y DataCite Ontology. *Scire: Representación Y organización Del Conocimiento*, 30(2), 59-71. <https://doi.org/10.54886/scire.v30i2.4963>
- Barradas, J. (2023). Inteligencia artificial como elemento transformador de la investigación científica. *Entrelíneas*, 2(1), 113-122. <https://doi.org/10.56368/Entrelíneas213>
- Bautista, N. (2022). *Proceso de la investigación cualitativa: epistemología, metodología y aplicaciones*. Editorial El Manual Moderno. <https://books.google.es/books?hl=es&lr=&id=yr2CEAAAQBAJ&oi=fnd&pg=PT4&dq=epistemologia+de+La+investigaci%C3%B3n+b%C3%A1sica&ots=1zM-pYLUJs&sig=VH5QaLnoknbVQ1dYtOpvdDPHxy8#v=onepage&q=epistemologia%20de%20La%20investigaci%C3%B3n%20b%C3%A1sica&f=false>
- Bienefeld, N., Boss, J., Lüthy, R., Brodbeck, D., Azzati, J., Blaser, M., . . . Keller, E. (2023). Solving the explainable AI conundrum by bridging clinicians' needs and developers' goals. *npj Digital Medicine*, 6. <https://doi.org/10.1038/s41746-023-00837-4>
- Bunge, M. (2017). El planteamiento científico. *Revista cubana de salud pública*, 43(3), 1-29. <http://scielo.sld.cu/pdf/rcsp/v43n3/spu16317.pdf>

- Cabanillas-García, J., Sánchez-Gómez, M., y Brío-Alonso, I. d. (2025). Voices of researchers: Ethics and artificial intelligence in qualitative inquiry. *Information*, 16(11), 1-22. <https://doi.org/10.3390/info16110938>
- Callirgos, L. A., Gamarra, P. C., y Cisneros, J. D. (2022). *La investigación científica. Una aventura epistémica, creativa e intelectual*. Religacion Press.
- Castelo, E. M. (2025). Problemas de la investigación tecnológica y su aplicación en la generación de innovación. *Journal of Economic and Social Science Research*, 5(1), 146-160. <https://doi.org/10.55813/gaea/jessr/v5/n1/166>
- Castillo, W. (2023). The importance of human supervision in the use of ChatGPT as a support tool in scientific writing. *Metaverse Basic and Applied Research*, 2. <https://doi.org/10.56294/mr202329>
- Cedeño, J., Maitta, I., Vélez, M., y Palomeque, J. (2024). Investigación universitaria con inteligencia artificial. *Revista Venezolana De Gerencia*, 29(106), 817-830. <https://doi.org/10.52080/rvgluz.29.106.23>
- Christou, P. (2024). Thematic analysis through artificial intelligence (AI). *The Qualitative Report*, 29(2), 560-576. <https://doi.org/10.46743/2160-3715/2024.7046>
- Ciobanu, O., Aicher, A., Kernbach, J., Regli, L., Serra, C., y Staartjes, V. (2024). A critical moment in machine learning in medicine: on reproducible and interpretable learning. *Acta Neurochirurgica*, 166. <https://doi.org/10.1007/s00701-024-05892-8>
- Contreras, L., Puma, I., Morales, J., Gil, C., y Chalco, N. (2024). Ética en el uso de la inteligencia artificial en la investigación científica: desafíos y consideraciones. *Aula virtual*, 5(12), 1-22. <https://doi.org/10.5281/zenodo.14653199>
- Díaz, L. (2024). El uso de la inteligencia artificial en la investigación científica. *Revista Historia De La Educación Latinoamericana*, 26(43), 253-272. <https://doi.org/10.19053/uplc.01227238.18014>
- Falcón, A. L., y Serpa, G. R. (2021). Acerca de los métodos teóricos y empíricos de investigación: significación para la investigación educativa. *Revista Conrado*, 17(S3), 22-31. <https://conrado.ucf.edu.cu/index.php/Conrado/article/view/2133>

- Flemotomos, N., Martinez, V., Chen, Z., Singla, K., Ardulov, V., Peri, R., . . . Narayanan, S. (2022). Automated evaluation of psychotherapy skills using speech and language technologies. *Behavior Research Methods*, 54, 690-711. <https://doi.org/10.3758/s13428-021-01623-4>
- Fushimi, K., Nakai, Y., Nishi, A., Suzuki, R., Ikegami, M., Nimura, R., . . . Hasunuma, T. (2025). Development of the autonomous lab system to support biotechnology research. *Scientific Reports*, 15, 1-13. <https://doi.org/10.1038/s41598-025-89069-y>
- Gallent, C., Zapata, A., y Ortego, J. (2023). El impacto de la inteligencia artificial generativa en educación superior: una mirada desde la ética y la integridad académica. *RELIEVE. Revista Electrónica de Investigación y Evaluación Educativa*, 29(2), 1-21. <https://doi.org/10.30827/relieve.v29i2.29134>
- Gao, C., Howard, F., Markov, N., Dyer, E., Ramesh, S., Luo, Y., y Pearson, A. (2023). Comparing scientific abstracts generated by ChatGPT to real abstracts with detectors and blinded human reviewers. *NPJ digital medicine*, 6. <https://doi.org/10.1038/s41746-023-00819-6>
- Garzón, M., Campo, G. D., y Loor, B. (2025). Análisis sistemático sobre la eficiencia comunicativa entre humanos y sistemas de inteligencia artificial mediante procesamiento del lenguaje natural. *Universitas-XX. Revista de ciencias sociales y humanas*(42). <https://doi.org/10.17163/uni.n42.2025.07>
- Gilbert, S., Kather, J., y Hogan, A. (2024). Augmented non-hallucinating large language models as medical information curators. *npj Digital Medicine*, 7(100). <https://doi.org/10.1038/s41746-024-01081-0>
- Götz, F., Maertens, R., Loomba, S., y Linden, S. v. (2024). Let the algorithm speak: How to use neural networks for automatic item generation in psychological scale development. *Psychological Methods*, 29(3), 494-518. <https://doi.org/10.1037/met0000540>
- Goyanes, M., Lopezosa, C., y Jordá, B. (2025). Thematic analysis of interview data with ChatGPT: Designing and testing a reliable research protocol for qualitative research. *Quality & Quantity*, 29, 5491-5510. <https://doi.org/10.1007/s11135-025-02199-3>

- Hartung, T. (2025). AI, agentic models and lab automation for scientific discovery. The beginning of scAInce. *Frontiers in Artificial Intelligence*, 8. <https://doi.org/10.3389/frai.2025.1649155>
- Hernandez, I., y Nie, W. (2023). The AI-IP: Minimizing the guesswork of personality scale item development through artificial intelligence. *Personnel Psychology*, 76(4), 1011-1035. <https://doi.org/10.1111/peps.12543>
- Hommel, B., Wollang, F.-J., Kotova, V., Zacher, H., y Schmukle, S. (2022). Transformer-based deep neural language modeling for construct-specific automatic item generation. *Psychometrika*, 87, 749-772. <https://doi.org/10.1007/s11336-021-09823-9>
- Hua, C., Cao, X., Liao, B., y Li, S. (2023). Advances on intelligent algorithms for scientific computing: An overview. *Frontiers in Neurorobotics*, 17. <https://doi.org/10.3389/fnbot.2023.1190977>
- Jalali, M., y Akhavan, A. (2024). Integrating AI language models in qualitative research: Replicating interview data analysis with ChatGPT. *System Dynamics Review*, 40(3), 1-9. <https://doi.org/10.1002/sdr.1772>
- Joyce, D., Kormilitzin, A., Smith, K., y Cipriani, A. (2023). Explainable artificial intelligence for mental health through transparency and interpretability for understandability. *npj Digital Medicine*, 6. <https://doi.org/10.1038/s41746-023-00751-9>
- Kapoor, S., y Narayanan, A. (2023). Leakage and the reproducibility crisis in machine-learning-based science. *Patterns*, 4(9). <https://doi.org/10.1016/j.patter.2023.100804>
- Keadle, S., Eglowski, S., Ylarregui, K., Strath, S., Martinez, J., Dekhtyar, A., y Kagan, V. (2024). Using computer vision to annotate video-recorded direct observation: Methods and validation. *Sensors*, 24(7), 1-15. <https://doi.org/10.3390/s24072359>
- Konttinen, L., Koulu, R., y Sankari, S. (2022). Research agenda for algorithmic fairness studies: Access to justice lessons for interdisciplinary research. *Frontiers in Artificial Intelligence*, 5. <https://doi.org/10.3389/frai.2022.882134>
- Krenn, M., Pollice, R., Guo, S., Aldeghi, M., Cervera, A., Friederich, P., . . . Aspuru, A. (2022). On scientific understanding with artificial intelligence. *Nature Reviews Physics*, 4, 761-769. <https://doi.org/10.1038/s42254-022-00518-3>

- Lee, V., Lubbe, S. v., Goh, L., y Valderas, J. (2024). Harnessing ChatGPT for thematic analysis: Are we ready? *Journal of Medical Internet Research*, 26. <https://doi.org/10.2196/54974>
- Mata, K., Sancán, V., Káiser, I., y Kaiser, R. (2024). Una revisión sistemática del uso de la Inteligencia artificial en el desarrollo de investigaciones científicas. *Reincisol*, 3(6), 1642-1660. [https://doi.org/10.59282/reincisol.V3\(6\)1642-1660](https://doi.org/10.59282/reincisol.V3(6)1642-1660)
- Omiye, J., Lester, J., Spichak, S., Rotemberg, V., y Daneshjou, R. (2023). Large language models propagate race-based medicine. *npj Digital Medicine*, 6. <https://doi.org/10.1038/s41746-023-00939-z>
- Panfilova, A., Bolshev, V., Mozikov, M., Latynov, V., Vanin, A., Nestik, T., . . . Nikolenko, S. (2026). The AI interviewer: Multi-faceted evaluation of adaptive questioning by large language models. *Scientific Reports*, 16. <https://doi.org/10.1038/s41598-026-46517-7>
- Paoli, S. D. (2024). Performing an inductive thematic analysis of semi-structured interviews with a large language model: An exploration and provocation on the limits of the approach. *Social Science Computer Review*, 42(4), 997-1019. <https://doi.org/10.1177/08944393231220483>
- Penabad, L., Morera, M., y Penabad, M. (2024). Guía para uso y reporte de inteligencia artificial en revistas científico-académicas. *Revista Electrónica Educare*, 28(S), 1-41. <https://doi.org/10.15359/ree.28-s.19830>
- Polo, L., y Casique, R. (2025). Propuesta metodológica para la recuperación de información documental: integración de grafos de conocimiento y redes neuronales. *Investigación Bibliotecológica: Archivonomía, Bibliotecología e Información*, 39(105), 141-163. <https://doi.org/10.22201/iibi.24488321xe.2025.105.59051>
- Posso, R., Caicedo-Quiroz, R., Maqueira, G., Barzola, J., Barba, L., y Amancha, J. (2025). Methodological Proposal for the Design and Validation of Research Instruments Supported by Artificial Intelligence. *Data and Metadata*, 4. <https://doi.org/10.56294/dm20251103>
- Salah, M., Abdelfattah, F., Halbusi, H. A., Jassem, S., Mohammed, M., Ismail, M., y Balghouni, A. A. (2025). Can generative AI craft scale items? A mixed-method study

- on AI's capability to adapt and create new scales with recommendations for best practices. *Social Sciences & Humanities Open*, 12. <https://doi.org/10.1016/j.ssaho.2025.101698>
- Sánchez, M. (2024). Inteligencia artificial generativa y los retos en la protección de datos personales. *Estudios en derecho a la información*, 9(18), 179-205. <https://doi.org/10.22201/ijj.25940082e.2024.18.18852>
- Semmelrock, H., Ross, T., Kopeinik, S., Theiler, D., Haberl, A., Thalmann, S., y Kowald, D. (2025). Reproducibility in machine-learning-based research: Overview, barriers and drivers. *AI Magazine*, 46(2), 1-19. <https://doi.org/10.1002/aaai.70002>
- Sigüenza, J., Andrade, C., y Chitacapa, J. (2024). Validación del cuestionario para docentes: Percepción sobre el uso de ChatGPT en la educación superior. *Revista Andina de Educación*, 8(1). <https://doi.org/10.32719/26312816.2024.8.1.6>
- Tang, L., Sun, Z., Idnay, B., Nestor, J., Soroush, A., Elias, P., . . . Peng, Y. (2023). Evaluating large language models on medical evidence summarization. *npj Digital Medicine*, 6. <https://doi.org/10.1038/s41746-023-00896-7>
- Terry, J., Strait, G., Alsarraf, S., Weinmann, E., y Waychof, A. (2025). Artificial intelligence in scale development: Evaluating AI-generated survey items against gold standard measures. *Current Psychology*, 44, 16339–16350. <https://doi.org/10.1007/s12144-025-08240-w>
- Tobias, A., y Wahab, A. (2025). Autonomous “self-driving” laboratories: A review of technology and policy implications. *Royal Society Open Science*, 12(7). <https://doi.org/10.1098/rsos.250646>
- Vasquez, A., Chuquisengo, E., y Santos, P. (2025). Diseño y validación de un cuestionario para evaluar el impacto del asistente de voz de Chat GPT en estudiantes universitarios. *Revista Espacios*, 46(1), 138-147. <https://doi.org/10.48082/espacios-a25v46n01p10>
- Williams, R., y Ingleby, E. (2025). The online survey in qualitative research: Can AI act as a probing tool? *Frontiers in Research Metrics and Analytics*, 10. <https://doi.org/10.3389/frma.2025.1519008>

- Zárate, L. O. (2022). Explicabilidad (de la inteligencia artificial). *EUNOMÍA. Revista en Cultura de la Legalidad*(22), 328-344. <https://doi.org/10.20318/eunomia.2022.6819>
- Zhang, H., Wu, C., Xie, J., Lyu, Y., Cai, J., y Carroll, J. (2025). Harnessing the power of AI in qualitative research: Exploring, using and redesigning ChatGPT. *Computers in Human Behavior: Artificial Humans*, 4, 1-20. <https://doi.org/10.1016/j.chbah.2025.100144>

INTELIGENCIA ARTIFICIAL

para diseñar proyectos de

INVESTIGACIÓN

ISBN: 978-9907-9574-7-1



9 789907 957471

