EDITORIAL ANDES COGNITIO

INVESTIGACIÓN 5.0

Inteligencia artificial, creatividad humana y producción científica

UN NUEVO PARADIGMA PARA LA CIENCIA DEL FUTURO



Rafael Romero Carazas
Julio César Andrade Palacios
Juan Carlos Tapia Cueva
José Ricardo Arias
Milton Gabriel Del Hierro Mosquera



Editorial Andes Cognitio

INVESTIGACIÓN 5.0

Inteligencia artificial, creatividad humana y producción científica: un nuevo paradigma para la ciencia del futuro

© Autores

Rafael Romero Carazas
Correo: rromeroc@ucsm.edu.pe
Orcid: https://orcid.org/0000-0001-8909-7782
Institución: Universidad Católica de Santa María- Perú

Julio César Andrade Palacios
Correo: jcandrade1@utn.edu.ec
Orcid: https://orcid.org/0000-0001-9193-2679
Institución: Universidad Técnica del Norte - FACAE

Juan Carlos Tapia Cueva
Correo: jctapia@utn.edu.ec
Orcid: https://orcid.org/0009-0001-8037-981X
Institución: Universidad Técnica del Norte - FACAE

José Ricardo Arias
Correo: jrariase@utn.edu.ec
Orcid: https://orcid.org/0000-0003-4289-6741
Institución: Universidad Técnica del Norte - FACAE

Milton Gabriel Del Hierro Mosquera
Correo: milton.delhierro@upec.edu.ec
Orcid: https://orcid.org/0000-0002-1735-6674
Institución: Universidad Politécnica Esta del Carchi- UPEC, Ecuador

Editorial "ANDES COGNITIO EDAC S.A.S."
DEPARTAMENTO DE EDICIÓN

Editado y Distribuido por:

Editorial:	Andes Cognitio
Sello Editorial:	978-9942-7408
Teléfono:	0995805659
Web:	https://andescognitio.org
ISBN:	978-9907-9566-6-5
DOI:	https://doi.org/10.64230/ypaahj26

© Primera Edición
© Noviembre 2026

Impreso en Ecuador

Revisión de Ortografía
Lcda. Cristina Paola Chamorro Ortega

Diseño de Portada
Ing. Pamela Rosa Taco Hernández Mgs

Diagramación
Ing. Yoselyn Andrea Rogel Gaibor

Director Editorial
Ec. Juan F. Villacis U. Mgs.

Aviso Legal
El contenido de este libro incluyendo textos, imágenes, gráficos, tablas, cuadros y referencias bibliográficas es de exclusiva responsabilidad del/ de los autor (es). Las opiniones, datos y criterios expresados no representan necesariamente la postura institucional ni el pensamiento de la Editorial Andes Cognitio.

Derechos de Autor ©

Este documento se publica bajo los términos y condiciones de la Licencia Creative Commons Reconocimiento – No Comercial – Compartirlgual 4.0 Internacional (CC BY-NC-SA 4.0).



Todos los derechos de autor y de propiedad intelectual e industrial relativos al contenido de esta publicación pertenecen exclusivamente a la "Editorial Andes Cognitio" y a sus respectivos autores. Queda expresamente prohibida, bajo las sanciones establecidas por la legislación vigente, la reproducción total o parcial de esta obra, su almacenamiento en sistemas informáticos, su tratamiento digital, así como cualquier forma de distribución, transmisión o comunicación pública por medios electrónicos, mecánicos, ópticos, químicos, de grabación o fotocopia sin la debida autorización previa y por escrito de los titulares del copyright.

Se exceptúan únicamente los usos con fines académicos o de investigación científica, siempre que no persigan propósitos comerciales y se realicen de forma gratuita, debiendo citarse en todo momento a la fuente editorial correspondiente. Las opiniones vertidas en los distintos capítulos son de exclusiva responsabilidad de los autores y no reflejan necesariamente la postura institucional de la editorial.

Comité Científico Académico

Dr. Jorge Gualberto Paredes Gavilanez PhD.
Universidad Técnica Estatal de Quevedo

Dr. Oscar Patricio López Solís PhD.
Universidad Técnica de Ambato

Ec. Carlos Roberto López Paredes PhD.
Escuela Superior Politécnica de Chimborazo Extensión Orellana

Dr. Héctor Enrique Hernández Altamirano PhD.
Universidad Técnica de Ambato

Dr. Carlos Arturo Jara Santillán PhD.
Escuela Superior Politécnica de Chimborazo

Dr. Guillermo Carrillo Espinosa PhD,
Universidad Autónoma de Chapingo - México

Dra. Doris Coromoto Pernía Barragán PhD,
Universidad de los Andes Tachira Venezuela

Ec. María Gabriela González Bautista PhD.
Universidad Nacional de Chimborazo

My. Efraín Arguello Arellano, Mgs.
Tecnológico Universitario ARGOS – Policía Nacional del Ecuador

Ing. Liliana Priscila Campos Llerena Mgs.
Universidad Técnica de Ambato

Dr. Mario Humberto Paguay Cuvi Mgs.
Escuela Superior Politécnica de Chimborazo

Ec. Oswaldo Javier Jácome Izurieta Mgs.
Universidad Técnica de Ambato

Ec. Juan Carlos Pèrez Briceño Mgs.
Instituto Superior Universitario Bolivariano

Dr. Luís Fernando Paz Villaeeoel Mgs.
Universidad Técnica Particular de Loja

Dra. Daysi Graciela Astudillo Condo Mgs.
Universidad Nacional de Chimborazo

Ec. Ligia Ximena Tapia Hermida Mgs.
Universidad Nacional de Chimborazo

Eco. Ángel Geovanny Carrión Gavilanes MBA.
Pontificia Universidad Católica del Ecuador sede Ambato

Ing. Paula Alejandra Abdo Peralta Mgs.
Escuela Superior Politécnica de Chimborazo

Ing. Milton Gabriel Del Hierro Mosquera Mgs.
Universidad Politécnica Estatal del Carchi

Ing. Catherine Gabriela Frey Erazo Mgs.
Escuela Superior Politécnica de Chimborazo

Ing. Juan Enrique Ureña Moreno Mgs.
Escuela Superior Politécnica de Chimborazo

Ing. José Fernando Esparza Parra Mgs.
Escuela Superior Politécnica de Chimborazo

Ing. Alexis Gabriel Reinoso Haro Mgs.
Universidad Estatal de Bolívar

Eco. Jaime Fernando Andrade Guamán Mgs.
Universidad Amawtay Wasi

Eco. Adriana Yamilet Herrera Granizo Mgs.
Universidad de las Fuerzas Armadas

Eco. Alejandro Carlos Lalama Freire Mgs.
Universidad Nacional de Chimborazo

Eco. Doménica Estefania Zabala Tapia
Universidad Nacional de Chimborazo

Constancia de Arbitraje

La Editorial Andes Cognitio, hace constar que este libro proviene de una investigación realizada por los autores, siendo sometido a un arbitraje bajo el sistema de doble ciego, de contenido y forma por jurados especialistas. Además, se realizó una revisión del enfoque, paradigma y método investigativo; desde la matriz epistémica asumida por los autores, aplicándose las normas APA, Séptima Edición, proceso de anti plagio en línea Compilatio, garantizándose así la cientificidad de la obra.

Comité Editorial

Eco. Juan Federico Villacis Uvidia Mgs.
Director de la Editorial Andes Cognitio

Lcda. Andrea Damaris Hernández Allauca PhD.
Editora de Andes Cognitio

PRÓLOGO

La llegada de la inteligencia artificial a la investigación científica ha transformado el trabajo cotidiano en laboratorios y universidades, mientras las tareas que requerían semanas o meses de dedicación especializada, como el análisis masivo de publicaciones, la formulación de hipótesis o la estructuración de diseños metodológicos, hoy pueden acelerarse mediante herramientas algorítmicas. En América Latina, y de manera particular en el Ecuador, donde la ciencia se desarrolla a menudo con recursos presupuestarios limitados, este avance ofrece una oportunidad valiosa para reducir brechas históricas. Sin embargo, la automatización en la generación de textos y análisis no resuelve las preguntas esenciales sobre la validez del conocimiento ni sobre la atribución de la autoría intelectual. Por ello, la reflexión sobre el uso de la IA en la ciencia supera el terreno estrictamente tecnológico y se convierte en una exigencia ética y epistemológica ineludible para la comunidad universitaria y para la sociedad.

Frente a las posturas extremas que oscilan entre la fascinación tecnológica acrítica y el rechazo rotundo, el libro plantea una perspectiva ponderada y reflexiva. Su premisa central es que la inteligencia artificial solo resulta legítima en el ámbito académico cuando potencia el juicio crítico del investigador, respeta estándares de transparencia y se orienta al bien común. En este enfoque se fundamenta el concepto de Investigación 5.0, concebido no como una ruptura con el método científico tradicional, sino como una convergencia articulada entre la inteligencia humana, la artificial y la colectiva. Este paradigma no sustituye los valores fundamentales del trabajo intelectual —como el rigor, la honestidad y la contrastación empírica—, sino que los reafirma en un contexto donde el pensamiento científico interactúa constantemente con sistemas computacionales.

El libro organiza su propuesta a través de un recorrido sistemático y comienza desentrañando los fundamentos epistemológicos del nuevo entorno tecnológico, analiza la interacción entre la creatividad humana y los modelos generativos para la formulación de ideas, examina la transformación de las metodologías de investigación, aborda los procesos de redacción y comunicación científica, y concluye con el estudio de la gobernanza, la ética y la soberanía tecnológica. Cada capítulo combina evidencia científica reciente con directrices de organismos internacionales, adaptando estos marcos a la realidad y a las necesidades de la investigación en América Latina. Además, la obra evita concentrarse en herramientas comerciales de vida corta, priorizando la construcción de criterios metodológicos y éticos duraderos para evaluar la pertinencia y validez del trabajo con tecnologías inteligentes.

Las reflexiones de esta obra ofrecen una utilidad directa para distintos actores del ámbito académico. Los investigadores encontrarán criterios claros para incorporar tecnologías sin perder rigor metodológico; los estudiantes de posgrado dispondrán de una guía para desarrollar las competencias que exige la ciencia contemporánea; las autoridades universitarias obtendrán insumos para diseñar políticas institucionales; y los editores científicos hallarán análisis sobre los cambios en la difusión del conocimiento. En definitiva, el mayor valor de este libro radica en mostrar que, en la era de la automatización algorítmica, los principios de rigor, transparencia y responsabilidad no han perdido vigencia, sino que son más indispensables que nunca para garantizar una ciencia de calidad al servicio de la sociedad.

ÍNDICE GENERAL

PRÓLOGO **2**

ÍNDICE GENERAL **4**

INTRODUCCIÓN **8**

CAPÍTULO I **12**

FUNDAMENTOS DE LA INVESTIGACIÓN 5.0: HACIA UNA NUEVA ARQUITECTURA DEL CONOCIMIENTO CIENTÍFICO **12**

1.1 Evolución de los paradigmas científicos: de la investigación tradicional a la Investigación 5.0 12

1.2 La Investigación 5.0 como propuesta de convergencia entre inteligencia humana, artificial y colectiva 16

1.3 Transformación epistemológica del conocimiento científico en entornos digitales inteligentes 20

1.4 Del pensamiento científico convencional a los modelos de investigación aumentada por inteligencia artificial 23

1.5 Nuevas arquitecturas cognitivas para la construcción, interpretación y validación del conocimiento 26

1.6 Interdisciplinariedad, transdisciplinariedad y convergencia tecnológica en la ciencia contemporánea 30

1.7 Ecosistemas científicos inteligentes: universidades, centros de investigación y redes globales de conocimiento 33

1.8 El investigador del futuro: competencias científicas, pensamiento crítico y alfabetización algorítmica 37

CAPÍTULO II **42**

INTELIGENCIA ARTIFICIAL Y CREATIVIDAD HUMANA: NUEVOS MODELOS PARA LA GENERACIÓN DE IDEAS CIENTÍFICAS **42**

2.1 Creatividad científica aumentada: interacción entre pensamiento humano y modelos generativos de inteligencia artificial..... 42

2.2 Inteligencia artificial como herramienta para identificar problemas científicos emergentes y vacíos de conocimiento 46

2.3 Ingeniería de instrucciones (prompt engineering) aplicada a la formulación de preguntas de investigación 49

2.4 Generación asistida de hipótesis científicas mediante modelos de lenguaje y sistemas inteligentes 53

2.5 Pensamiento divergente, razonamiento abductivo y creatividad computacional en la investigación 57

2.6 Diseño de modelos conceptuales y marcos teóricos mediante colaboración humano–máquina 61

2.7 Laboratorios de cocreación científica: metodologías colaborativas para transformar ideas en proyectos investigativos 64

2.8 Originalidad, autoría intelectual y límites de la creatividad artificial en la producción del conocimiento 68

CAPÍTULO III 73

METODOLOGÍAS INTELIGENTES 5.0: AUTOMATIZACIÓN, ANALÍTICA AVANZADA Y NUEVAS FORMAS DE INVESTIGAR 73

3.1 Transformación de los enfoques cuantitativos, cualitativos y mixtos mediante inteligencia artificial 73

3.2 Diseño metodológico asistido por sistemas inteligentes: selección de métodos, variables e instrumentos de investigación 77

3.3 Revisión sistemática inteligente de literatura científica mediante procesamiento del lenguaje natural 80

3.4 Bibliometría 5.0: análisis de redes científicas, identificación de tendencias y cartografía del conocimiento 84

3.5 Aprendizaje automático y modelos predictivos aplicados al descubrimiento de patrones científicos 88

3.6 Inteligencia artificial generativa para la simulación de escenarios, construcción de modelos y experimentación virtual 92

3.7 Automatización de procesos investigativos mediante agentes inteligentes y flujos de trabajo científicos 96

3.8 Validación, explicabilidad algorítmica, reproducibilidad y control de sesgos en investigaciones asistidas por inteligencia artificial 100

CAPÍTULO IV 107

PRODUCCIÓN CIENTÍFICA 5.0: REDACCIÓN INTELIGENTE, PUBLICACIÓN ACADÉMICA Y VISIBILIDAD DEL CONOCIMIENTO 107

4.1 Transformación de la escritura científica: de la redacción convencional a la producción académica asistida por inteligencia artificial..... 107

4.2 Arquitectura inteligente de artículos científicos: coherencia argumentativa, estructura IMRyD y comunicación de resultados 111

4.3 Gestión avanzada de referencias bibliográficas, identificación de fuentes y verificación automatizada de citas..... 115

4.4 Inteligencia artificial aplicada a la edición académica, corrección científica y evaluación preliminar de manuscritos..... 119

4.5 Publicación científica inteligente: selección de revistas, criterios de indexación y evaluación de calidad editorial 123

4.6 Ciencia abierta 5.0: repositorios inteligentes, datos FAIR y democratización del conocimiento científico 126

4.7 Visibilidad e impacto científico en ecosistemas digitales: bibliometría, altmetría y estrategias de difusión académica 130

4.8 Nuevos formatos de comunicación científica: artículos interactivos, visualización dinámica de resultados y divulgación multimodal 134

CAPÍTULO V 139

ÉTICA, GOBERNANZA Y FUTURO DE LA INVESTIGACIÓN 5.0: HACIA UNA CIENCIA RESPONSABLE, AUTÓNOMA Y SOSTENIBLE 139

5.1 Ética científica 5.0: integridad académica, transparencia y responsabilidad en la utilización de inteligencia artificial 139

5.2 Autoría, propiedad intelectual y reconocimiento de contribuciones humanas en investigaciones asistidas por sistemas inteligentes 143

5.3 Sesgos algorítmicos, fabricación de información y riesgos de desinformación en la producción científica 146

5.4 Gobernanza de la inteligencia artificial en universidades, centros de investigación y editoriales académicas 150

5.5 Soberanía científica y tecnológica: protección de datos, autonomía investigativa y reducción de dependencias digitales 154

5.6 Investigación sostenible e inclusiva: inteligencia artificial aplicada a los desafíos sociales, económicos y ambientales 157

5.7 Prospectiva científica: laboratorios autónomos, agentes de investigación y nuevos escenarios de descubrimiento científico 162

5.8 Hacia un modelo de Investigación 5.0 centrado en el ser humano: propuesta de principios, dimensiones e indicadores para su implementación 165

REFERENCIAS BIBLIOGRÁFICAS 170

INTRODUCCIÓN

La práctica científica experimenta una transformación estructural impulsada por la penetración de la inteligencia artificial y, de manera singular, por los modelos generativos capaces de procesar y sintetizar textos, código, imágenes y estructuras moleculares a partir de instrucciones en lenguaje natural. Estas herramientas han comenzado a intervenir en las distintas etapas de la indagación académica, desde la revisión sistemática de literatura y la formulación inicial de hipótesis hasta el procesamiento masivo de datos, la redacción de manuscritos y el apoyo a la evaluación editorial.

H. Wang et al. (2023) documentan cómo los sistemas inteligentes contribuyen activamente al planteamiento de hipótesis, el diseño de experimentos y la analítica compleja en disciplinas diversas, aunque subrayan que la calidad de los datos de entrenamiento y el reconocimiento preciso de los límites algorítmicos constituyen condicionantes críticos. De forma paralela, Messeri y Crockett (2024) advierten que una confianza desmedida en la automatización puede generar ilusiones de comprensión, propiciando un escenario en el que la ciencia incremente su volumen de producción sin expandir correlativamente su entendimiento profundo de los fenómenos. En la tensión comprendida entre la eficiencia computacional y la solidez epistemológica se sitúa el propósito central de esta obra: ofrecer criterios analíticos y metodológicos para aprovechar el potencial de las tecnologías avanzadas sin menoscabar los valores éticos y reflexivos que fundamentan la actividad científica.

En América Latina, esta transición tecnológica se despliega sobre un escenario caracterizado por asimetrías y restricciones estructurales históricas. La Red Iberoamericana de Indicadores de Ciencia y Tecnología [RICYT] (2025) señala que la inversión regional en investigación y desarrollo alcanzó en 2023 un 0,60 % del producto interno bruto, proporción distante de los promedios registrados en las economías más industrializadas, aun cuando la producción científica regional ha mantenido una trayectoria de crecimiento en la última década, con incrementos relativos destacados en el Ecuador.

En el ámbito específico de las tecnologías emergentes, el Índice Latinoamericano de Inteligencia Artificial ubica al Ecuador en una posición intermedia entre las diecinueve naciones evaluadas (Centro Nacional de Inteligencia Artificial [CENIA], 2024), con un puntaje de 34,59 que refleja la existencia de capacidades iniciales junto con la necesidad urgente de robustecer la infraestructura digital, el talento especializado y la investigación aplicada. En este contexto, la

incorporación de la inteligencia artificial plantea tanto la posibilidad de acortar brechas de productividad como el riesgo de profundizar dependencias tecnológicas si su adopción no se acompaña de formación metodológica, inversión estratégica y criterios propios formulados desde las prioridades de la sociedad regional.

Frente a este escenario, la pregunta que articula el desarrollo del libro indaga de qué manera la investigación científica puede integrar la inteligencia artificial para potenciar sus capacidades sin supeditar la creatividad humana, la integridad académica ni la responsabilidad con los problemas del entorno. Para responder a este planteamiento, la obra desarrolla el paradigma de la Investigación 5.0, concepto inspirado en la propuesta europea de Industria 5.0 (Breque et al., 2021) que reorienta la transformación digital hacia la centralidad de la persona, la sostenibilidad y la resiliencia.

La Investigación 5.0 se define como un modelo de producción de conocimiento que articula de manera deliberada la inteligencia humana, la artificial y la colectiva bajo principios de transparencia, apertura, integridad y utilidad social. El objetivo general consiste en construir un marco conceptual, metodológico y ético que guíe la integración de la inteligencia artificial en la práctica investigativa, con especial atención a las dinámicas del Ecuador y América Latina.

De este propósito derivan los objetivos específicos de la obra: analizar la evolución de los paradigmas científicos, examinar la interacción entre el pensamiento humano y los modelos generativos en la concepción de ideas, desarrollar una perspectiva metodológica enfática en la reproducibilidad y el control de sesgos, revisar los nuevos formatos de redacción, edición y difusión científica, y formular criterios de gobernanza, soberanía tecnológica y sostenibilidad.

Desde el punto de vista metodológico, el libro se sustenta en una revisión documental y analítica de literatura científica arbitrada publicada principalmente entre 2021 y 2026 en revistas de alto impacto como Nature, Science, Cell o Patterns, complementada con el examen de directrices de organismos internacionales como la UNESCO, la Comisión Europea y el Committee on Publication Ethics [COPE].

El análisis incorpora además la normativa ecuatoriana relevante, de modo particular la Ley Orgánica de Protección de Datos Personales (Asamblea Nacional del Ecuador, 2021) y el Reglamento de Régimen Académico (Consejo de Educación Superior [CES], 2022). Toda la

literatura procesada se presenta mediante paráfrasis rigurosas con su debida atribución en el texto y se consolida en la lista alfabética final de referencias bibliográficas.

La obra se organiza en cinco capítulos articulados que avanzan desde la fundamentación teórica hacia las aplicaciones metodológicas y los marcos de gobernanza. El primer capítulo establece las bases epistemológicas de la Investigación 5.0 y propone una arquitectura cognitiva para el conocimiento científico; el segundo examina la relación entre la creatividad humana y los modelos generativos en la formulación de ideas e hipótesis; el tercero aborda la transformación de las metodologías cuantitativas, cualitativas y mixtas, la automatización de procesos y la validación de modelos; el cuarto analiza la redacción asistida, la arquitectura IMRyD, la gestión de referencias, el proceso editorial y la visibilidad científica; y el quinto aborda los dilemas éticos, la soberanía tecnológica y la prospectiva, concluyendo con una propuesta operativa de principios, dimensiones e indicadores para su implementación institucional.

Cada subsección incluye una figura conceptual de elaboración propia que sintetiza sus argumentos centrales. Finalmente, conviene precisar que este volumen elude deliberadamente el formato de manual técnico enfocado en herramientas informáticas de rápida obsolescencia; su propósito es ofrecer criterios perdurables que permitan a la comunidad académica evaluar cuándo y cómo emplear tecnologías inteligentes, cómo validar sus resultados y cómo tutelar la dirección intelectual y la responsabilidad social que dan sentido a la actividad científica.

EDITORIAL ANDES COGNITIO

CAPÍTULO I

FUNDAMENTOS DE LA INVESTIGACIÓN 5.0: HACIA UNA NUEVA ARQUITECTURA DEL CONOCIMIENTO CIENTÍFICO



CAPÍTULO I

FUNDAMENTOS DE LA INVESTIGACIÓN 5.0: HACIA UNA NUEVA ARQUITECTURA DEL CONOCIMIENTO CIENTÍFICO

1.1 Evolución de los paradigmas científicos: de la investigación tradicional a la Investigación 5.0

Durante buena parte del siglo XX, la imagen dominante de la ciencia fue la de un investigador o un pequeño equipo que formulaba una hipótesis a partir de la teoría disponible, diseñaba un experimento para ponerla a prueba, recogía datos con instrumentos de laboratorio o de campo y, tras analizarlos, aceptaba o rechazaba su conjetura. Ese modelo, de raíz experimental y deductiva, convivió con una tradición teórica que avanzaba mediante razonamientos formales y, desde mediados del siglo, con una tercera vía basada en la simulación computacional, que permitió estudiar fenómenos demasiado complejos, lentos o peligrosos para ser observados directamente.

Más tarde, la acumulación de datos producidos por sensores, telescopios, secuenciadores genéticos y plataformas digitales dio lugar a una ciencia intensiva en datos, en la que la pregunta ya no siempre precede a la observación, sino que a menudo surge de ella. Cada una de estas formas de investigar no sustituyó por completo a las anteriores; más bien se fueron superponiendo, de modo que hoy un mismo laboratorio puede combinar experimentos, modelos teóricos, simulaciones y análisis de grandes volúmenes de información. Asimismo, la irrupción del aprendizaje profundo y de los modelos generativos añadió una capa nueva a esa superposición.

En una revisión publicada en Nature, H. Wang et al. (2023) documentan cómo la inteligencia artificial interviene ya en casi todas las fases del trabajo científico: ayuda a generar hipótesis, a diseñar experimentos, a recoger e interpretar conjuntos de datos de gran tamaño y a obtener resultados que con los métodos tradicionales no habrían sido posibles. Los autores destacan, entre los avances recientes, el aprendizaje autosupervisado, que permite entrenar modelos con grandes cantidades de datos sin etiquetar, y el aprendizaje profundo geométrico, que incorpora la estructura propia de los datos científicos para ganar precisión y eficiencia.

Advierten, al mismo tiempo, que la calidad deficiente de los datos y su gestión inadecuada siguen siendo obstáculos importantes, y que quienes desarrollan y utilizan estas herramientas

necesitan comprender mejor cuándo fallan. El caso más citado de este cambio es la predicción de la estructura tridimensional de las proteínas: Jumper et al. (2021) presentaron un sistema capaz de predecir esas estructuras con una precisión comparable a la de los métodos experimentales en una gran proporción de los casos, lo que resolvió en pocos años un problema que había ocupado a la biología estructural durante décadas.

Sobre este trasfondo surge la noción de Investigación 5.0, que toma su nombre de la propuesta europea de Industria 5.0. Breque et al. (2021) formularon esa propuesta como una corrección del rumbo de la transformación digital: en lugar de perseguir únicamente la eficiencia y la automatización, la tecnología debía orientarse hacia tres valores, la centralidad del ser humano, la sostenibilidad y la resiliencia.

Poco después, Carayannis y Morawska-Jancelewicz (2022) llevaron esta idea al terreno universitario y sostuvieron que las universidades del futuro deberán articular la investigación, la formación y la vinculación con la sociedad en torno a los desafíos de la Sociedad 5.0, en la que la integración entre el espacio físico y el digital debe servir al bienestar de las personas. Trasladada a la investigación, la noción de Investigación 5.0 no designa una técnica concreta, sino una manera de hacer ciencia en la que las capacidades humanas, la inteligencia artificial y los sistemas digitales se combinan de forma deliberada, bajo criterios de integridad, transparencia y utilidad social. Conviene, sin embargo, no confundir esta evolución con una sucesión lineal de etapas que se reemplazan unas a otras.

La investigación de una universidad ecuatoriana puede incorporar herramientas de análisis automatizado de literatura mientras conserva procesos de recolección de datos manuales, y un mismo grupo puede emplear modelos generativos para explorar ideas y métodos estadísticos clásicos para contrastarlas. Por ello, más que hablar del reemplazo de un paradigma por otro, resulta más preciso hablar de una ampliación del repertorio de la ciencia.

La Investigación 5.0 conserva el núcleo del método científico, es decir, la exigencia de contrastar las afirmaciones con la evidencia y de someterlas al escrutinio de la comunidad, pero cambia la escala, la velocidad y la división del trabajo entre personas y máquinas. Krenn et al. (2022) subrayan, en esta línea, que el objetivo último de la ciencia no es solo predecir con exactitud, sino comprender, y que el valor de la inteligencia artificial debe medirse también por su contribución a esa comprensión.

Esta distinción entre predecir y comprender tiene consecuencias prácticas. Un modelo puede anticipar con gran precisión el comportamiento de un sistema sin que nadie sepa explicar por qué funciona, lo que plantea preguntas sobre el tipo de conocimiento que se obtiene y sobre la confianza que merece. En la tradición experimental, la explicación causal era el centro del trabajo científico; en la ciencia intensiva en datos, la correlación robusta adquirió mayor peso; y en la Investigación 5.0 ambas exigencias deben convivir, porque la capacidad predictiva de los modelos solo se convierte en conocimiento cuando las personas pueden interpretarla, ponerla a prueba e integrarla en marcos teóricos.

De ahí que el investigador no desaparezca del proceso, sino que cambie su función: deja de ser el único productor de hipótesis y análisis para convertirse también en el responsable de orientar, verificar y dar sentido al trabajo de herramientas cada vez más potentes. A modo de ilustración, un ejemplo permite apreciar cómo conviven estas formas de investigar en un mismo proyecto. Supóngase un equipo de una universidad ecuatoriana que estudia la calidad del agua en una cuenca andina.

Durante décadas, un estudio así se habría basado en muestreos periódicos en puntos fijos, análisis de laboratorio y comparaciones con normas técnicas; hoy, el mismo equipo puede combinar esos muestreos con sensores que registran datos de manera continua, imágenes satelitales que muestran los cambios en el uso del suelo, modelos de simulación hidrológica y algoritmos de aprendizaje automático que relacionan todas estas fuentes para anticipar episodios de contaminación.

Los investigadores no abandonan el trabajo de campo ni el laboratorio, sino que los integran con capacidades computacionales que amplían la escala y la frecuencia de sus observaciones. Lo que cambia, sobre todo, es la naturaleza de las decisiones que deben tomar, porque ahora deben elegir qué datos combinar, cómo validar los modelos y cómo comunicar resultados que tienen distintos grados de incertidumbre.

En este tipo de proyectos se hace visible que la Investigación 5.0 no es una ruptura con la ciencia anterior, sino una ampliación que exige integrar tradiciones metodológicas distintas con criterio y responsabilidad. Conviene recordar, además, que la adopción de nuevas formas de investigar nunca ha sido uniforme entre disciplinas. Las ciencias naturales incorporaron la simulación y el análisis masivo de datos antes que las ciencias sociales y las humanidades, y estas últimas

desarrollaron, a su vez, tradiciones propias de análisis textual y de interpretación que hoy dialogan con las herramientas de procesamiento del lenguaje.

Esta diversidad no debe interpretarse como un retraso de unas disciplinas respecto de otras, sino como la expresión de objetos de estudio y de preguntas diferentes. La Investigación 5.0 se enriquece precisamente cuando cada campo incorpora las herramientas inteligentes según sus propias necesidades y criterios de calidad, en lugar de adoptar acríticamente los modelos de otras disciplinas.

Un historiador que utiliza modelos de lenguaje para explorar archivos digitalizados, un sociólogo que analiza millones de publicaciones en redes sociales o un lingüista que estudia la variación del español en distintas regiones están participando en esta transformación, aunque sus prácticas sean muy distintas de las de un laboratorio de biología molecular. Esta diversidad de prácticas obliga, por otra parte, a revisar la manera en que se enseña la historia y la filosofía de la ciencia en los programas de formación.

Durante mucho tiempo, estos contenidos se presentaron como una sucesión de grandes figuras y de descubrimientos individuales, con escasa atención a los instrumentos, las instituciones y las comunidades que hicieron posible el conocimiento. Una enseñanza adecuada a la Investigación 5.0 debería mostrar, en cambio, cómo las herramientas han transformado en cada época lo que los científicos podían observar, calcular y comunicar, y cómo esas transformaciones plantearon preguntas sobre la validez del conocimiento semejantes a las que hoy plantea la inteligencia artificial. Comprender que la ciencia ya ha atravesado cambios profundos en sus medios sin perder su identidad ayuda a los investigadores a situar la transformación actual en una perspectiva histórica, lejos tanto del entusiasmo ingenuo como del temor paralizante.

Para los sistemas científicos de América Latina, este tránsito presenta oportunidades y riesgos particulares. Las herramientas de inteligencia artificial pueden reducir algunas barreras históricas, como el costo de revisar la literatura internacional, de procesar datos o de redactar en otros idiomas, y permitir que equipos con recursos modestos participen en líneas de investigación antes reservadas a centros con grandes presupuestos.

Sin embargo, si su adopción no se acompaña de formación, infraestructura y criterios éticos propios, la región podría limitarse a consumir tecnologías diseñadas en otros contextos, con datos que no reflejan sus realidades y bajo reglas que no participó en definir. La evolución hacia

la Investigación 5.0 exige, por tanto, algo más que incorporar herramientas, ya que obliga a repensar cómo se forman los investigadores, cómo se organizan las instituciones y qué tipo de ciencia se quiere producir para responder a los problemas del propio territorio.

A ello se suma que las instituciones de la región han acumulado experiencias valiosas en la adaptación de tecnologías a contextos con recursos limitados, una capacidad que puede resultar decisiva para aprovechar la inteligencia artificial de manera creativa y pertinente, en lugar de reproducir sin más los modelos de los países con mayores recursos.

Figura 1.1

Evolución de los paradigmas científicos



Fuente: Elaboración autores

1.2 La Investigación 5.0 como propuesta de convergencia entre inteligencia humana, artificial y colectiva

La ciencia siempre ha sido una empresa colectiva. Incluso los descubrimientos atribuidos a figuras individuales dependieron de instrumentos construidos por otros, de datos recogidos por equipos anónimos y de debates sostenidos en revistas, congresos y correspondencias. Lo que cambia en el presente es la naturaleza de los participantes en esa conversación: junto a las personas y las instituciones aparecen sistemas capaces de procesar información, proponer alternativas y ejecutar tareas que antes requerían intervención humana.

La Investigación 5.0 puede entenderse, desde esta perspectiva, como una propuesta para organizar la convergencia de tres formas de inteligencia, la humana, la artificial y la colectiva, de manera que cada una aporte lo que mejor sabe hacer y compense las limitaciones de las otras. Además, la inteligencia humana aporta capacidades que los sistemas actuales no reproducen de

forma confiable. Entre ellas se encuentran la formulación de preguntas relevantes a partir de una comprensión profunda del contexto, el juicio sobre qué problemas merecen atención, la capacidad de reconocer cuándo un resultado carece de sentido aunque sea estadísticamente significativo, la responsabilidad moral por las decisiones y la creatividad que surge de la experiencia vivida.

La inteligencia artificial, por su parte, destaca en tareas que exigen procesar volúmenes de información imposibles de abarcar para una persona, detectar patrones en datos de alta dimensión, explorar rápidamente grandes espacios de alternativas y ejecutar procedimientos repetitivos sin fatiga. La inteligencia colectiva, finalmente, emerge de la interacción entre muchos participantes y se manifiesta en la revisión por pares, en la acumulación de conocimiento a lo largo de generaciones y en la capacidad de las comunidades científicas para corregir sus propios errores.

Cui y Yasseri (2024), en una revisión sobre la inteligencia colectiva ampliada por la inteligencia artificial, proponen analizar estos sistemas como redes de múltiples capas. En la capa cognitiva se sitúan los procesos de pensamiento y conocimiento de personas y máquinas; en la capa física, la infraestructura que conecta a los agentes; y en la capa de información, los flujos de datos y mensajes que circulan entre ellos.

Los autores sostienen que las personas y la inteligencia artificial tienen fortalezas complementarias, por lo que su trabajo conjunto puede superar el desempeño de cada una por separado, aunque advierten que las interacciones entre ambas son complejas e interdependientes. Señalan, además, que la diversidad de los participantes, desde los rasgos visibles hasta las diferencias profundas de conocimiento y perspectiva, y la variedad de funciones de los agentes artificiales influyen de manera decisiva en la calidad de los resultados colectivos.

Esta mirada resulta útil para la ciencia, porque recuerda que la incorporación de herramientas inteligentes no solo modifica la productividad individual, sino también la dinámica de los equipos y de las comunidades de investigación. En esta misma línea, en la práctica, esta convergencia puede adoptar formas muy distintas.

En un grupo de investigación en salud pública, por ejemplo, los modelos de lenguaje pueden ayudar a revisar miles de artículos sobre una enfermedad, los algoritmos de aprendizaje automático pueden identificar patrones en los registros epidemiológicos y las personas investigadoras pueden interpretar esos resultados a la luz de su conocimiento del sistema de salud local,

discutirlos con profesionales de campo y validarlos con la comunidad afectada. Krenn et al. (2022) describen esta colaboración mediante tres papeles posibles de la inteligencia artificial: como microscopio computacional, que proporciona información sobre sistemas que no pueden observarse directamente; como fuente de inspiración, que sugiere conexiones, datos sorprendentes o soluciones que las personas desarrollan después; y como agente de comprensión, capaz de generar por sí misma conocimiento nuevo y transmitirlo a los científicos. Los autores reconocen que este tercer papel aún no se ha materializado plenamente, lo que confirma que, por ahora, la comprensión científica sigue dependiendo de la interpretación humana.

La convergencia entre estas inteligencias no está exenta de tensiones. Cuando los equipos confían excesivamente en las sugerencias de los sistemas automáticos, pueden reducir la diversidad de perspectivas que caracteriza a una comunidad científica sana, ya que todos tienden a explorar las mismas alternativas propuestas por herramientas similares. Del mismo modo, la delegación de tareas en sistemas opacos puede debilitar la capacidad de los investigadores para comprender y cuestionar los resultados.

Por esta razón, la Investigación 5.0 no se limita a sumar herramientas, sino que propone principios de organización: mantener a las personas en las decisiones relevantes, preservar la diversidad de enfoques, documentar el papel de cada participante y someter los resultados al escrutinio colectivo. Estos principios conectan con la visión centrada en el ser humano que inspira la propuesta europea de Industria 5.0 (Breque et al., 2021).

En la práctica, la experiencia de algunos proyectos de ciencia ciudadana ilustra el potencial de esta convergencia. En iniciativas de monitoreo de la biodiversidad, miles de personas registran observaciones de aves, plantas o insectos mediante aplicaciones móviles; los algoritmos de reconocimiento de imágenes sugieren la identificación de las especies; y especialistas revisan los registros dudosos y validan la información que se incorpora a las bases de datos científicas.

Cada forma de inteligencia aporta algo distinto: las personas contribuyen con su presencia en el territorio y su capacidad de observación, la inteligencia artificial con la rapidez para clasificar grandes volúmenes de imágenes y los especialistas con el juicio experto que garantiza la calidad de los datos. En un país megadiverso como el Ecuador, este tipo de iniciativas puede ampliar de manera notable el conocimiento sobre especies y ecosistemas que los equipos de investigación, por sí solos, no podrían cubrir. Su éxito depende, sin embargo, de reglas claras sobre la

propiedad y el uso de los datos, del reconocimiento a quienes participan y de mecanismos de control de calidad que eviten que los errores automáticos se propaguen.

La convergencia exige, asimismo, reglas explícitas sobre la distribución de las responsabilidades. Cuando en un proyecto participan personas, sistemas automatizados y comunidades amplias, es necesario definir quién decide qué preguntas se investigan, quién valida los datos, quién interpreta los resultados y quién responde por las conclusiones publicadas. Sin estas definiciones, la responsabilidad puede diluirse entre los participantes, y los errores pueden atribuirse a la herramienta o a la comunidad sin que nadie los asuma.

La experiencia de los grandes consorcios científicos internacionales, que han desarrollado políticas detalladas de autoría, uso de datos y resolución de conflictos, ofrece un modelo útil para proyectos más pequeños que incorporan inteligencia artificial y participación ciudadana. En las universidades de la región, estas reglas pueden recogerse en acuerdos de colaboración sencillos, firmados al inicio de cada proyecto, que establezcan los papeles de cada participante, las condiciones de uso de los datos y la forma en que se reconocerán las contribuciones en las publicaciones.

En este marco, para las universidades y centros de investigación latinoamericanos, pensar en términos de convergencia tiene una implicación estratégica. Las capacidades de cómputo y los grandes modelos se concentran en pocas empresas y países, pero la inteligencia colectiva de la región, es decir, sus redes académicas, su conocimiento de los problemas locales y su diversidad cultural y lingüística, constituye un recurso propio que puede potenciarse.

Figura 1.2

La Investigación 5.0 como propuesta de convergencia entre inteligencia humana, artificial y colectiva.



Fuente: Elaboración autores

1.3 Transformación epistemológica del conocimiento científico en entornos digitales inteligentes

La epistemología se ocupa de preguntas que a menudo parecen alejadas del trabajo cotidiano de un laboratorio: qué cuenta como conocimiento, cómo se justifica una afirmación, qué significa comprender un fenómeno. Sin embargo, la incorporación de la inteligencia artificial a la investigación ha devuelto estas preguntas al centro del debate científico. Cuando un modelo predice con gran precisión el plegamiento de una proteína o la evolución de una epidemia sin que sus creadores puedan explicar en detalle cómo llega a esos resultados, surge la duda de si ese resultado constituye conocimiento en el mismo sentido que una ley física o una explicación causal.

La transformación epistemológica de la ciencia en entornos digitales inteligentes consiste, precisamente, en la reconfiguración de los criterios con los que se produce, justifica y valida el saber científico. De igual manera, una de las preocupaciones más discutidas es la opacidad de los modelos de aprendizaje profundo. Estos sistemas ajustan millones o miles de millones de parámetros a partir de los datos, y su funcionamiento interno resulta difícil de interpretar incluso para quienes los diseñan. Duede (2023) ofrece una perspectiva matizada sobre este problema a partir de la clásica distinción entre el contexto de descubrimiento, en el que se generan las ideas, y el contexto de justificación, en el que se evalúa su validez.

El autor sostiene que la preocupación filosófica por la opacidad se debe en parte a que no se ha examinado cómo se utiliza realmente la inteligencia artificial en la ciencia: cuando los modelos opacos se emplean como parte de un proceso de descubrimiento más amplio, sus resultados pueden justificarse por otras vías, como la verificación experimental, de modo que la opacidad no impide necesariamente obtener conocimiento valioso. En otras palabras, un modelo puede sugerir dónde buscar sin que se le exija explicar por qué, siempre que lo encontrado se someta después a las pruebas habituales de la ciencia.

Otros autores advierten, en cambio, sobre riesgos epistémicos más profundos. Messeri y Crockett (2024), por ejemplo, analizan las visiones con las que los científicos imaginan el papel de la inteligencia artificial y sostienen que estas herramientas resultan atractivas porque prometen superar las limitaciones humanas de tiempo, atención y objetividad. Sin embargo, precisamente por esa promesa, pueden explotar nuestras propias limitaciones cognitivas y generar ilusiones

de comprensión, en las que los investigadores creen entender el mundo mejor de lo que realmente lo entienden.

Las autoras alertan, además, sobre la posible formación de monoculturas científicas, en las que ciertos métodos, preguntas y puntos de vista dominan porque se adaptan mejor a las herramientas disponibles, lo que haría a la ciencia menos innovadora y más vulnerable al error. Su conclusión es inquietante: existe el riesgo de entrar en una fase en la que la ciencia produzca más, pero comprenda menos.

Por otra parte, estas dos posiciones no son incompatibles. La de Duede (2023) muestra que la opacidad puede gestionarse si los resultados de los modelos se integran en procesos de justificación rigurosos, mientras que la de Messeri y Crockett (2024) recuerda que esa integración no ocurre de manera automática y que la abundancia de resultados puede debilitar la reflexión crítica.

Ambas coinciden, en el fondo, en que la validez del conocimiento científico no depende de la herramienta que lo genera, sino del proceso social y metodológico en el que se inserta. Krenn et al. (2022) aportan un criterio adicional al proponer que la contribución de la inteligencia artificial se evalúe por su capacidad de favorecer la comprensión, entendida como la habilidad de reconocer consecuencias cualitativas de una teoría sin necesidad de realizar cálculos exactos. Desde esta perspectiva, un modelo que predice bien pero no ayuda a comprender aporta menos a la ciencia que uno que, aun siendo menos preciso, permite a los investigadores formular nuevas ideas.

La transformación epistemológica afecta también a la relación entre teoría y datos. En la ciencia intensiva en datos, los patrones se descubren a menudo antes de disponer de una teoría que los explique, lo que invierte el orden tradicional de la investigación. Este cambio puede ser fecundo, porque permite detectar regularidades que las teorías existentes no anticipaban, pero también conlleva el peligro de confundir correlaciones espurias con relaciones significativas.

La experiencia acumulada en el uso del aprendizaje automático muestra que errores metodológicos aparentemente menores, como la filtración de información entre los datos de entrenamiento y los de evaluación, pueden producir resultados espectaculares que no se sostienen cuando se intentan reproducir (Kapoor y Narayanan, 2023). La epistemología de la

Investigación 5.0 debe, por tanto, combinar la apertura a los patrones que emergen de los datos con una vigilancia metodológica más estricta que nunca.

Paralelamente, estas discusiones tienen consecuencias directas para la evaluación de los trabajos que utilizan inteligencia artificial. Un comité de tesis o un revisor de una revista que recibe un estudio basado en un modelo predictivo debería preguntarse no solo si el modelo obtiene buenos resultados, sino también qué tipo de conocimiento produce: si permite explicar el fenómeno, si sus resultados han sido contrastados por otras vías, si se conocen las condiciones en que deja de funcionar y si los autores comprenden los supuestos de las herramientas que utilizaron.

Del mismo modo, los investigadores deberían explicitar en sus trabajos el estatus epistemológico de sus hallazgos, distinguiendo entre las predicciones obtenidas, las interpretaciones propuestas y las afirmaciones causales que efectivamente pueden sostener. Esta claridad no resta valor a los resultados, sino que permite a los lectores situarlos adecuadamente y evita que las predicciones se confundan con explicaciones. En los programas de posgrado de la región, incorporar estas preguntas en la formación metodológica contribuiría a que los futuros investigadores utilicen las herramientas inteligentes con plena conciencia de lo que pueden y no pueden aportar al conocimiento.

Existe, asimismo, una dimensión pedagógica en estas discusiones que no debería descuidarse. Los estudiantes que hoy se forman en investigación crecen en un entorno en el que las respuestas parecen estar siempre disponibles en una consulta a un asistente conversacional, lo que puede debilitar la paciencia necesaria para comprender un problema en profundidad.

Enseñar epistemología en este contexto no significa añadir un curso teórico desconectado de la práctica, sino incorporar en cada actividad de investigación preguntas sobre la procedencia de la evidencia, la solidez de las inferencias y los límites de las herramientas utilizadas. Un estudiante que aprende a preguntarse cómo sabe lo que afirma, y qué tendría que ocurrir para que su conclusión fuera falsa, está mejor preparado para trabajar con herramientas que producen respuestas con gran facilidad. Esta actitud reflexiva constituye quizá el aporte más valioso que la formación universitaria puede ofrecer frente a la abundancia de información generada automáticamente.

Por ello, para quienes investigan en contextos latinoamericanos, estas discusiones no son meramente teóricas. Los modelos entrenados con datos de otras poblaciones pueden incorporar

supuestos que no se cumplen en la región, y su apariencia de objetividad puede ocultar esos sesgos. Una epistemología crítica, atenta a la procedencia de los datos y a los límites de los modelos, permite aprovechar las ventajas de las herramientas inteligentes sin renunciar a la comprensión situada de los fenómenos.

Figura 1.3

Transformación epistemológica del conocimiento científico en entornos digitales inteligentes.



Fuente: Elaboración autores

1.4 Del pensamiento científico convencional a los modelos de investigación aumentada por inteligencia artificial

El pensamiento científico convencional se apoya en un conjunto de operaciones intelectuales que se enseñan en los cursos de metodología: observar con atención, formular preguntas precisas, revisar lo que otros ya han investigado, proponer hipótesis, diseñar procedimientos para ponerlas a prueba, analizar los resultados y comunicar las conclusiones de manera que otros puedan evaluarlas.

Durante generaciones, cada una de estas operaciones dependió casi por completo de las capacidades de las personas, apoyadas en instrumentos que ampliaban sus sentidos o su capacidad de cálculo, pero que no participaban en el razonamiento. La investigación aumentada por inteligencia artificial cambia este reparto, porque introduce herramientas que intervienen activamente en varias de esas operaciones, desde la búsqueda de literatura hasta la generación de hipótesis y la ejecución de experimentos.

Sobre esta base, el término «aumentada» resulta adecuado porque describe una ampliación de las capacidades humanas y no su sustitución. H. Wang et al. (2023) muestran que la inteligencia artificial ya contribuye a generar hipótesis, diseñar experimentos y analizar grandes conjuntos de datos en disciplinas tan diversas como la física, la química, la biología o las ciencias de la

Tierra, y que los modelos generativos permiten diseñar objetos como moléculas o proteínas a partir de datos de distinta naturaleza.

En cada caso, la herramienta amplía el espacio de alternativas que un equipo puede considerar o reduce el tiempo necesario para explorarlo, pero la definición del problema, la elección de los criterios de evaluación y la interpretación de los resultados siguen requiriendo el juicio de los investigadores. Esta combinación es, precisamente, lo que distingue la investigación aumentada de una investigación completamente automatizada.

Los ejemplos más avanzados muestran hasta dónde puede llegar esa ampliación. Boiko et al. (2023) presentaron un sistema basado en un modelo de lenguaje de gran escala capaz de diseñar, planificar y ejecutar experimentos químicos complejos de manera semiautónoma, utilizando herramientas como la búsqueda en internet y en documentación técnica, la ejecución de código y el control de equipos de laboratorio automatizados.

El sistema fue puesto a prueba en seis tareas distintas, entre ellas la optimización de reacciones de acoplamiento catalizadas por paladio, y los autores destacan su versatilidad y su capacidad para explicar los pasos que seguía. Experiencias como esta permiten imaginar laboratorios en los que la máquina se ocupa de buena parte de la ejecución, mientras las personas definen los objetivos, supervisan el proceso e interpretan los hallazgos. No obstante, estos casos corresponden todavía a entornos muy controlados y a problemas bien delimitados, y su traslado a la investigación cotidiana exige cautela.

Desde esta perspectiva, el paso del pensamiento convencional al aumentado modifica, además, las competencias que se valoran en un investigador. Si antes la habilidad para revisar manualmente cientos de artículos o para programar análisis estadísticos complejos constituía una ventaja decisiva, hoy cobra mayor importancia la capacidad de formular buenas preguntas, de evaluar críticamente las respuestas de las herramientas y de integrar resultados provenientes de fuentes diversas.

Esta transformación no reduce la exigencia intelectual, sino que la desplaza: el investigador debe conocer suficientemente bien los métodos para detectar cuándo una herramienta produce resultados erróneos, aunque ya no sea quien ejecuta cada cálculo. La experiencia reciente muestra, por ejemplo, que los modelos de lenguaje pueden generar referencias bibliográficas inexistentes o con errores sustanciales (Walters y Wilder, 2023), lo que obliga a verificar cada afirmación antes de incorporarla a un trabajo científico.

Conviene advertir también sobre el riesgo de que la investigación aumentada amplifique las debilidades metodológicas en lugar de corregirlas. Kapoor y Narayanan (2023) documentaron problemas de filtración de datos en 294 artículos de 17 campos científicos que utilizaban aprendizaje automático, errores que producían estimaciones exageradas del desempeño de los modelos y que comprometían la reproducibilidad de los resultados.

Los autores propusieron una clasificación de ocho tipos de filtración y unas fichas de información de los modelos que los investigadores pueden completar para verificar si sus análisis están libres de estos problemas. Este hallazgo muestra que la potencia de las herramientas no garantiza la calidad de la ciencia, ya que una técnica sofisticada aplicada sin rigor puede generar conclusiones más convincentes, pero igualmente equivocadas, que las de un análisis sencillo.

De forma complementaria, la transición puede observarse en la manera de organizar la jornada de trabajo de un investigador. En el modelo convencional, buena parte del tiempo se dedicaba a tareas de búsqueda, transcripción, limpieza de datos y formateo de resultados; en el modelo aumentado, estas tareas pueden delegarse parcialmente en herramientas, lo que libera tiempo para actividades de mayor valor intelectual, como la lectura en profundidad de los trabajos clave, la discusión con colegas, la reflexión sobre los resultados o la vinculación con los actores que podrían utilizar el conocimiento.

Este beneficio, sin embargo, no se produce de manera automática. Si el tiempo liberado se dedica simplemente a producir más artículos con menos reflexión, la investigación aumentada puede contribuir a la saturación de la literatura con trabajos de escaso valor. Por ello, las instituciones deberían acompañar la adopción de estas herramientas con sistemas de evaluación que valoren la calidad y la relevancia de la investigación por encima de la cantidad de publicaciones, de modo que la ganancia de productividad se traduzca en mejor ciencia y no solo en más ciencia.

Las universidades pueden acompañar este tránsito mediante iniciativas de bajo costo y alto impacto. Una de ellas consiste en crear comunidades de práctica en las que investigadores de distintas facultades compartan sus experiencias con herramientas inteligentes, discutan los problemas encontrados y elaboren orientaciones comunes. Otra consiste en ofrecer servicios de apoyo metodológico que ayuden a los investigadores a evaluar si una herramienta es adecuada para su problema y a diseñar procedimientos de verificación.

También resulta útil documentar casos institucionales, tanto exitosos como fallidos, que sirvan de referencia para la formación de nuevos investigadores. Estas iniciativas contribuyen a que la adopción de la investigación aumentada se produzca de manera reflexiva y colectiva, en lugar de depender de la iniciativa aislada de cada investigador, y permiten que las lecciones aprendidas en un grupo beneficien al conjunto de la institución.

En consecuencia, para las instituciones de educación superior del Ecuador y de la región, el tránsito hacia modelos de investigación aumentada plantea una tarea doble. Por un lado, es necesario facilitar el acceso a las herramientas y formar a docentes y estudiantes en su uso, porque de lo contrario se ampliarían las brechas entre quienes pueden aprovecharlas y quienes no. Por otro, resulta indispensable fortalecer la formación metodológica y ética, de manera que la ampliación de capacidades no se traduzca en una pérdida de rigor.

Figura 1.4

Del pensamiento científico convencional a los modelos de investigación aumentada por inteligencia artificial.



Fuente: Elaboración autores

1.5 Nuevas arquitecturas cognitivas para la construcción, interpretación y validación del conocimiento

Toda forma de producir conocimiento descansa en una arquitectura cognitiva, es decir, en una manera de distribuir las tareas de percibir, recordar, razonar, decidir y comunicar entre las

personas, los instrumentos y las instituciones. En la ciencia tradicional, esa arquitectura era relativamente sencilla de describir: los investigadores pensaban, los instrumentos medían, las bibliotecas almacenaban la memoria colectiva y las revistas organizaban la validación mediante la revisión por pares.

La incorporación de sistemas inteligentes obliga a redibujar ese esquema, porque introduce componentes que no solo almacenan o miden, sino que también clasifican, infieren, sugieren y, en algunos casos, actúan. Pensar en nuevas arquitecturas cognitivas supone, entonces, preguntarse qué funciones conviene asignar a cada componente para que el conjunto produzca conocimiento confiable.

Vinculado con lo anterior, en la construcción del conocimiento, los sistemas inteligentes amplían sobre todo la capacidad de exploración. Krenn et al. (2022) describen cómo la inteligencia artificial puede actuar como un microscopio computacional, que permite estudiar sistemas inaccesibles a la observación directa mediante datos o representaciones generadas computacionalmente, y como una fuente de inspiración que revela datos sorprendentes, conexiones entre literaturas distantes o soluciones inesperadas que las personas transforman después en conceptos nuevos.

En ambos casos, la máquina contribuye a ampliar el campo de lo pensable, mientras que la construcción del concepto científico propiamente dicho sigue a cargo de los investigadores. Una arquitectura cognitiva bien diseñada aprovecha esta complementariedad asignando a los sistemas la exploración amplia y a las personas la selección, la conceptualización y la conexión con el cuerpo teórico existente.

La interpretación constituye la segunda función clave y, probablemente, la más delicada. Los resultados de un modelo no se interpretan solos; requieren que alguien determine qué significan, en qué condiciones son válidos y qué consecuencias tienen para el problema estudiado. Las técnicas de aprendizaje automático interpretable ofrecen herramientas para esta tarea, ya que permiten identificar qué variables influyen en una predicción, cómo cambia el resultado al modificar los datos de entrada o qué ejemplos resultan más representativos del comportamiento del modelo (Molnar, 2022).

Sin embargo, estas técnicas no sustituyen la interpretación sustantiva, que depende del conocimiento del dominio. En un estudio sobre rendimiento académico, por ejemplo, un modelo puede

señalar que la distancia entre el hogar y la universidad predice el abandono, pero solo el conocimiento del contexto permite entender si esa variable refleja costos de transporte, responsabilidades laborales o falta de conectividad, y diseñar intervenciones en consecuencia.

En concordancia con ello, la validación es la tercera función y la que más garantiza la confiabilidad del conjunto. Duede (2023) recuerda que los resultados obtenidos mediante modelos opacos pueden justificarse si se integran en procesos de verificación independientes, como la comprobación experimental o la contrastación con otras fuentes de evidencia.

Esta idea sugiere un principio de diseño para las arquitecturas cognitivas de la Investigación 5.0: separar las funciones de generación y de validación, de modo que los resultados producidos por un sistema inteligente sean verificados por procedimientos distintos, preferiblemente transparentes y reproducibles. Messeri y Crockett (2024) añaden una advertencia complementaria, porque cuando las mismas herramientas se emplean para generar y evaluar resultados, aumenta el riesgo de ilusiones de comprensión y de errores que nadie detecta, de ahí que la diversidad de métodos y de evaluadores actúe como una protección frente a esos riesgos.

Estas consideraciones permiten esbozar una arquitectura cognitiva por capas. En la base se sitúan los datos y su gestión, con criterios de calidad, documentación y acceso que permitan reutilizarlos y verificarlos. Sobre ella operan las herramientas de exploración y análisis, que amplían la capacidad de los investigadores para revisar literatura, procesar datos y generar alternativas. En un nivel superior se ubican los procesos de interpretación, en los que las personas integran los resultados con el conocimiento teórico y contextual.

Más arriba se encuentran los mecanismos de validación, que incluyen la replicación, la revisión por pares y la discusión pública. Y de forma transversal operan las reglas éticas y de gobernanza, que definen qué usos son aceptables, cómo se documenta la participación de cada componente y quién responde por los resultados. A modo de ilustración, un ejemplo concreto ayuda a comprender cómo funciona esta arquitectura en un estudio aplicado.

Un equipo que analiza los factores asociados a la desnutrición infantil en zonas rurales podría utilizar herramientas de procesamiento del lenguaje para revisar la literatura nacional e internacional, algoritmos de aprendizaje automático para identificar patrones en los datos de una encuesta de salud y técnicas de interpretación para conocer qué variables pesan más en las predicciones.

Hasta aquí, las herramientas han contribuido a la construcción y a una primera interpretación del conocimiento. Sin embargo, el equipo debe después contrastar esos resultados con estudios de campo, conversar con profesionales de salud y con las familias afectadas para comprender los mecanismos detrás de los patrones, y someter sus conclusiones a la revisión de especialistas. Solo cuando los resultados han superado esta validación pueden convertirse en recomendaciones para las políticas públicas. La arquitectura cognitiva, en este caso, no es una abstracción, sino la secuencia de controles que permite pasar de una correlación encontrada por un algoritmo a un conocimiento confiable sobre el que pueden tomarse decisiones que afectan la vida de las personas. La documentación de estas arquitecturas tiene, además, un valor que trasciende cada proyecto individual.

Cuando los grupos de investigación registran de manera sistemática qué herramientas utilizaron, cómo verificaron sus resultados y qué problemas encontraron, generan un conocimiento metodológico que puede compartirse con otros grupos y que contribuye a mejorar las prácticas de toda la comunidad. Las revistas científicas podrían favorecer esta acumulación de experiencias al pedir a los autores que describan con detalle sus procedimientos de verificación, y las universidades podrían crear repositorios de protocolos y lecciones aprendidas.

En la región, donde muchos grupos enfrentan desafíos similares con recursos limitados, compartir estas experiencias puede evitar la repetición de errores y acelerar el aprendizaje colectivo sobre el uso responsable de la inteligencia artificial en la investigación. Por lo demás, esta arquitectura puede trasladarse con facilidad al trabajo cotidiano. Un grupo de investigación que utiliza modelos de lenguaje para revisar literatura puede aplicarla registrando qué herramienta empleó, con qué instrucciones y con qué resultados; verificando manualmente una muestra de las clasificaciones realizadas por la máquina; discutiendo en equipo la interpretación de los hallazgos y declarando en la publicación el papel que tuvo cada componente.

Estas prácticas, que pueden parecer meramente formales, constituyen en realidad la infraestructura cognitiva que permite que el conocimiento producido con ayuda de sistemas inteligentes sea confiable, transparente y susceptible de crítica.

Figura 1.5

Nuevas arquitecturas cognitivas para la construcción, interpretación y validación del conocimiento.



Fuente: Elaboración autores

1.6 Interdisciplinariedad, transdisciplinariedad y convergencia tecnológica en la ciencia contemporánea

Los problemas que hoy ocupan a la ciencia rara vez respetan las fronteras disciplinares. El cambio climático, las pandemias, la seguridad alimentaria, la transformación de las ciudades o los efectos sociales de la propia inteligencia artificial involucran simultáneamente procesos físicos, biológicos, económicos, políticos y culturales.

Frente a esta complejidad, la organización tradicional del conocimiento en disciplinas separadas, cada una con sus revistas, sus métodos y sus departamentos universitarios, muestra límites evidentes. La interdisciplinariedad, entendida como la integración de conceptos y métodos de varias disciplinas para abordar un problema común, y la transdisciplinariedad, que añade la participación de actores no académicos en la producción del conocimiento, se han convertido por ello en aspiraciones centrales de la ciencia contemporánea.

A ello se suma que la inteligencia artificial ocupa un lugar singular en este panorama, porque es al mismo tiempo un campo de investigación y una herramienta transversal que atraviesa todas las disciplinas. H. Wang et al. (2023) documentan su aplicación en ámbitos que van desde la física de partículas y la astronomía hasta la biología molecular, la química de materiales y las ciencias de la Tierra, lo que muestra que los mismos tipos de modelos pueden adaptarse a problemas muy distintos.

En América Latina, el CENIA (2024), en el Índice Latinoamericano de Inteligencia Artificial elaborado junto con la Comisión Económica para América Latina y el Caribe, estimó que una proporción muy elevada de las publicaciones regionales sobre inteligencia artificial tiene carácter multidisciplinario, y que buena parte de las publicaciones citadas se concentra en un número reducido de disciplinas, entre las que destaca la medicina clínica. Estos datos indican que la inteligencia artificial actúa ya como un lenguaje común que conecta comunidades científicas antes separadas.

Esta capacidad de conexión se manifiesta en lo que suele denominarse convergencia tecnológica, es decir, la integración de tecnologías de la información, biotecnología, nanotecnología y ciencias cognitivas en proyectos que combinan sus aportes. Los laboratorios autónomos constituyen un buen ejemplo de ello. Tom et al. (2024), en una extensa revisión sobre los laboratorios autoconducidos en química y ciencia de materiales, describen cómo estos sistemas integran equipos robóticos, programas de planificación autónoma, bases de datos y modelos de aprendizaje automático para acelerar el descubrimiento, y examinan sus aplicaciones en el desarrollo de fármacos, la ciencia de materiales, la genómica y la química.

Proyectos de esta naturaleza requieren equipos en los que participan químicos, ingenieros, informáticos, estadísticos y especialistas en automatización, que deben aprender a comunicarse y a coordinar métodos y lenguajes muy distintos. La interdisciplinariedad, sin embargo, no surge espontáneamente por el solo hecho de compartir una herramienta.

Los equipos que reúnen especialistas de diferentes campos enfrentan dificultades conocidas: vocabularios distintos, criterios de calidad divergentes, sistemas de evaluación académica que premian la publicación en revistas disciplinares y estructuras institucionales que dificultan la colaboración entre facultades.

La inteligencia artificial puede ayudar a superar algunas de estas barreras, por ejemplo, al facilitar la búsqueda y síntesis de literatura de campos ajenos o al traducir conceptos entre lenguajes disciplinares, pero también puede generar una ilusión de integración en la que los especialistas aplican herramientas comunes sin comprender realmente los supuestos de las otras disciplinas. Messeri y Crockett (2024) advierten, precisamente, que la difusión de las mismas herramientas puede favorecer monoculturas científicas en las que se privilegian los problemas que mejor se adaptan a ellas.

La transdisciplinariedad plantea desafíos adicionales y, al mismo tiempo, oportunidades especialmente relevantes para la región. Incorporar a comunidades, organizaciones sociales, gobiernos locales o empresas en la definición de los problemas y en la interpretación de los resultados permite producir conocimiento más pertinente y aplicable, pero exige metodologías de diálogo, tiempo y reglas claras sobre la propiedad de los datos y de los resultados.

La Recomendación de la UNESCO sobre la ciencia abierta reconoce explícitamente la importancia de abrir la ciencia a la participación de actores sociales y de dialogar con otros sistemas de conocimiento, entre ellos los saberes de los pueblos indígenas y las comunidades locales (Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO], 2021a). En países como el Ecuador, con una notable diversidad cultural y ecológica, esta apertura puede enriquecer la investigación sobre biodiversidad, agricultura, salud o gestión del territorio.

Además, las universidades latinoamericanas cuentan con experiencias que muestran el valor de estas formas de trabajo. Proyectos sobre la gestión de cuencas hidrográficas, la adaptación de la agricultura al cambio climático o la reducción del riesgo de desastres han reunido a hidrólogos, agrónomos, sociólogos, economistas y comunidades locales para producir conocimiento útil para la toma de decisiones.

La incorporación de la inteligencia artificial puede potenciar estos proyectos, por ejemplo, al integrar datos satelitales, climáticos y socioeconómicos en modelos que ayuden a anticipar escenarios, o al facilitar el procesamiento de entrevistas y documentos en distintos idiomas, incluidas las lenguas indígenas. Para que esta incorporación sea fructífera, los equipos deben dedicar tiempo a construir un lenguaje común, acordar los criterios de calidad de cada componente del proyecto y definir desde el inicio cómo se integrarán los resultados.

La experiencia muestra que los proyectos interdisciplinarios exitosos no son los que acumulan más disciplinas o herramientas, sino los que logran articularlas en torno a un problema compartido y a una pregunta que todos los participantes consideran relevante. La evaluación de los proyectos interdisciplinarios plantea también dificultades particulares. Los comités de evaluación suelen estar organizados por disciplinas, y un proyecto que combina, por ejemplo, ciencia de datos, ecología y antropología puede ser juzgado por especialistas que solo conocen una de esas áreas, lo que dificulta una valoración justa.

Algunos organismos de financiamiento han comenzado a constituir comités mixtos o a solicitar evaluaciones de especialistas de distintos campos para estos proyectos. Las universidades ecuatorianas podrían adoptar prácticas similares en sus convocatorias internas, así como criterios de evaluación que valoren explícitamente la integración entre disciplinas y la participación de actores no académicos. Sin estos cambios, los incentivos institucionales seguirán favoreciendo los proyectos disciplinares tradicionales, aunque el discurso oficial promueva la interdisciplinariedad.

Ahora bien, para que la interdisciplinariedad y la transdisciplinariedad prosperen en la era de la inteligencia artificial, las instituciones deben revisar algunas de sus prácticas. Los sistemas de evaluación académica podrían reconocer la participación en proyectos colaborativos y la publicación en revistas de diferentes campos; los programas de posgrado podrían incorporar formación en métodos de otras disciplinas y en herramientas de análisis de datos; y las universidades podrían crear espacios físicos y virtuales donde investigadores de distintas áreas trabajen sobre problemas comunes.

Figura 1.6

Interdisciplinariedad, transdisciplinariedad y convergencia tecnológica en la ciencia contemporánea.



Fuente: Elaboración autores

1.7 Ecosistemas científicos inteligentes: universidades, centros de investigación y redes globales de conocimiento

La investigación científica no ocurre en el vacío, sino dentro de ecosistemas formados por universidades, institutos públicos, centros privados, organismos de financiamiento, editoriales, bibliotecas, empresas y redes de colaboración nacionales e internacionales. La calidad de la

ciencia que produce un país depende tanto de la capacidad de sus investigadores como de la densidad y el funcionamiento de esas relaciones.

Un ecosistema científico inteligente puede definirse como aquel en el que los actores comparten información, datos e infraestructuras mediante plataformas digitales, utilizan herramientas de inteligencia artificial para mejorar sus procesos y cuentan con reglas comunes que permiten colaborar de manera confiable y abierta. Ahora bien, los datos más recientes sobre la ciencia latinoamericana muestran tanto avances como limitaciones estructurales. Según la RICYT (2025), América Latina y el Caribe invirtió en 2023 alrededor del 0,60 % de su producto interno bruto en investigación y desarrollo, una proporción muy inferior a la de las economías más desarrolladas, aunque la región representó cerca del 4,4 % de la inversión mundial en este rubro.

El mismo informe señala que el número de investigadores de la región creció de manera significativa en la última década, que las universidades concentran casi tres cuartas partes de los investigadores activos y que la producción científica indexada aumentó en casi todos los países, con incrementos relativos especialmente notables en el Ecuador y el Perú. Estos datos confirman que las universidades constituyen el núcleo de los ecosistemas científicos latinoamericanos, de modo que su transformación resulta decisiva para el desarrollo de la Investigación 5.0 en la región.

En el plano de la inteligencia artificial, el panorama es heterogéneo. El Índice Latinoamericano de Inteligencia Artificial, que evalúa a diecinueve países en tres dimensiones, los factores habilitantes, la investigación, desarrollo y adopción, y la gobernanza, ubicó a Chile, Brasil y Uruguay en las primeras posiciones, mientras que el Ecuador obtuvo un puntaje de 34,59 y ocupó el undécimo lugar (CENIA, 2024).

Esta posición intermedia sugiere que el país cuenta con capacidades iniciales, pero que necesita fortalecer su infraestructura, su talento especializado y su producción científica en el área para aprovechar plenamente las oportunidades que ofrece la inteligencia artificial. El informe destaca, asimismo, que los países de la región aumentaron su proporción relativa de talento en inteligencia artificial, aunque todavía se encuentran lejos de los niveles alcanzados por los países más avanzados.

En esta misma línea, las universidades ecuatorianas desarrollan su labor investigadora dentro de un marco normativo que reconoce la investigación como una de sus funciones sustantivas, junto con la docencia y la vinculación con la sociedad. El Reglamento de Régimen Académico

expedido por el CES (2022) regula la organización de la formación académica y establece las bases para articular la investigación con los procesos formativos en los distintos niveles. En un ecosistema científico inteligente, esta articulación puede fortalecerse mediante repositorios institucionales interoperables, sistemas de información que registren los proyectos y resultados de investigación, plataformas compartidas de cómputo y datos, y programas de formación en métodos digitales para docentes y estudiantes.

La dimensión global de los ecosistemas científicos es igualmente importante. La ciencia contemporánea se produce cada vez más en redes internacionales, y la participación en ellas permite a los investigadores latinoamericanos acceder a infraestructuras, datos y conocimientos que serían inalcanzables de manera aislada.

La Recomendación de la UNESCO sobre la ciencia abierta propone, en este sentido, que el conocimiento científico, los datos y las infraestructuras se compartan de manera más amplia y equitativa, y que se reduzcan las brechas entre países en el acceso y la participación en la ciencia (UNESCO, 2021a). Sin embargo, la integración en redes globales también plantea riesgos de dependencia, cuando las agendas de investigación se definen fuera de la región o cuando los datos producidos localmente se procesan y explotan en otros países sin beneficios para las comunidades que los generaron. De igual manera, un ecosistema científico inteligente se reconoce, en la práctica, por la facilidad con que circulan la información y los recursos entre sus actores.

Cuando una universidad ecuatoriana puede acceder a los datos de un instituto público de investigación, utilizar la infraestructura de cómputo de otra institución, publicar en una revista regional indexada y depositar sus datos en un repositorio interoperable, sus investigadores disponen de capacidades muy superiores a las que tendrían de manera aislada. En cambio, cuando cada institución trabaja con sus propios sistemas, sin acuerdos de intercambio ni estándares comunes, los recursos se duplican y el conocimiento se dispersa.

La construcción de estos ecosistemas requiere, por ello, acuerdos interinstitucionales, estándares técnicos compartidos y una cultura de colaboración que supere la competencia entre instituciones por recursos escasos. Las redes académicas nacionales y regionales, los consorcios de bibliotecas y los sistemas de información científica cumplen aquí una función decisiva, que la inteligencia artificial puede potenciar al facilitar la búsqueda, la integración y el análisis de la información distribuida entre muchas instituciones.

La sostenibilidad de estos ecosistemas depende también de su financiamiento. La investigación requiere inversiones continuas en infraestructura, personal y acceso a información, y los ciclos de financiamiento irregulares, frecuentes en la región, dificultan la consolidación de grupos y de líneas de trabajo. Las herramientas de inteligencia artificial pueden reducir algunos costos, pero también introducen otros, como las suscripciones a servicios, el cómputo o la formación especializada. Una estrategia de financiamiento coherente con la Investigación 5.0 debería combinar fondos públicos estables para las capacidades básicas, convocatorias competitivas para proyectos específicos y alianzas con otros sectores para problemas de interés común.

La cooperación regional, mediante la compra conjunta de licencias o el uso compartido de infraestructuras, puede contribuir a que los recursos disponibles rindan más y a que las instituciones más pequeñas también accedan a las herramientas necesarias. Construir ecosistemas científicos inteligentes en el Ecuador y en América Latina requiere, por consiguiente, una estrategia que combine la apertura con la construcción de capacidades propias.

Entre los elementos de esa estrategia pueden mencionarse la inversión sostenida en infraestructura digital y en formación especializada, la creación de redes nacionales y regionales que compartan datos y herramientas, la adopción de políticas institucionales sobre el uso responsable de la inteligencia artificial en la investigación y el fortalecimiento de revistas y repositorios regionales que den visibilidad a la producción local. El ecosistema resultante sería inteligente no por la cantidad de tecnología que incorpora, sino por su capacidad de aprender, coordinarse y orientar la investigación hacia los problemas que más importan a la sociedad.

Figura 1.7

Ecosistemas científicos inteligentes: universidades, centros de investigación y redes globales de conocimiento.



Fuente: Elaboración autores

1.8 El investigador del futuro: competencias científicas, pensamiento crítico y alfabetización algorítmica

Cada transformación de la ciencia ha exigido nuevas competencias a quienes la practican. La generalización de la estadística obligó a los investigadores a comprender la inferencia y la incertidumbre; la llegada de la computación, a programar o al menos a dialogar con quienes programaban; la expansión de internet, a buscar y evaluar información en fuentes digitales. La incorporación de la inteligencia artificial a la investigación no es una excepción, aunque presenta una particularidad: las herramientas actuales no solo amplían la capacidad de cálculo o de búsqueda, sino que intervienen en tareas que antes se consideraban exclusivamente intelectuales, como formular preguntas, sintetizar argumentos o redactar textos.

Por ello, el perfil del investigador del futuro debe combinar competencias científicas clásicas, un pensamiento crítico reforzado y una alfabetización algorítmica que le permita trabajar con estas herramientas sin quedar subordinado a ellas. Por otra parte, las competencias científicas clásicas no pierden vigencia, sino que adquieren mayor importancia. La capacidad de formular problemas relevantes, de conocer en profundidad la literatura de un campo, de diseñar estudios

metodológicamente sólidos, de interpretar resultados con prudencia y de comunicar hallazgos con claridad sigue siendo la base de cualquier investigación de calidad.

Cuando una herramienta puede producir en segundos una síntesis plausible de la literatura o un análisis estadístico, el valor diferencial del investigador reside precisamente en su capacidad para juzgar si esa síntesis es correcta, si ese análisis es apropiado y si las conclusiones se sostienen. Sin un dominio sólido de su disciplina, el investigador carece de los criterios necesarios para detectar los errores de las herramientas, que pueden ser sutiles y estar presentados con apariencia de autoridad.

El pensamiento crítico constituye, por ello, la segunda dimensión del perfil. Messeri y Crockett (2024) advierten que las herramientas de inteligencia artificial pueden generar ilusiones de comprensión, en las que los investigadores creen saber más de lo que realmente saben. La defensa frente a esas ilusiones es una actitud deliberadamente crítica, que se traduce en hábitos concretos: verificar las afirmaciones contra las fuentes originales, buscar evidencia que contradiga las propias hipótesis, comparar los resultados de distintos métodos y someter las conclusiones a la discusión con colegas.

La experiencia muestra que estos hábitos no son superfluos, puesto que los modelos de lenguaje pueden fabricar referencias bibliográficas o introducir errores sustanciales en referencias reales (Walters y Wilder, 2023), y solo una lectura crítica permite detectar estas fallas antes de que lleguen a una publicación. Paralelamente, la alfabetización algorítmica es la tercera dimensión y la más novedosa. Ng et al. (2021), en una revisión exploratoria sobre el concepto de alfabetización en inteligencia artificial, propusieron organizarla en cuatro aspectos: conocer y comprender la inteligencia artificial, usarla y aplicarla, evaluarla y crear con ella, y reconocer las cuestiones éticas que plantea.

Trasladados al ámbito de la investigación, estos aspectos implican que el investigador comprenda, al menos en términos generales, cómo funcionan los modelos que utiliza, qué datos los alimentan y cuáles son sus limitaciones; que sepa aplicarlos adecuadamente a sus problemas; que pueda evaluar críticamente sus resultados e incluso adaptarlos o desarrollar herramientas propias; y que conozca las implicaciones éticas de su uso en relación con la privacidad, los sesgos, la autoría y la transparencia. Miao y Holmes (2023), en la guía de la UNESCO sobre inteligencia artificial generativa en educación e investigación, insisten precisamente en la

necesidad de un enfoque centrado en las personas, en el que el desarrollo de estas competencias acompañe la adopción de las herramientas.

A estas tres dimensiones se suman competencias relacionales e integradoras. El investigador del futuro trabajará con frecuencia en equipos interdisciplinarios e internacionales, en los que deberá comunicarse con especialistas de otros campos y coordinar el trabajo de personas y sistemas automatizados. Deberá también gestionar datos de acuerdo con principios de apertura y reutilización, comprender las normas de integridad académica y de propiedad intelectual, y declarar con transparencia el uso de herramientas de inteligencia artificial en su trabajo, tal como lo exigen hoy las principales organizaciones de ética editorial (Committee on Publication Ethics [COPE], 2023).

Estas competencias no se adquieren de una vez, sino que requieren actualización permanente, porque las herramientas evolucionan con rapidez y las normas que regulan su uso cambian con ellas. Sobre esta base, estas competencias pueden traducirse en experiencias formativas concretas. Un curso de metodología de la investigación podría incluir, por ejemplo, un ejercicio en el que los estudiantes utilicen un modelo de lenguaje para obtener una síntesis de la literatura sobre su tema, verifiquen después cada afirmación y cada referencia en las fuentes originales, y presenten un informe sobre los errores encontrados.

Otro ejercicio podría consistir en comparar los resultados de un análisis estadístico realizado manualmente con los sugeridos por una herramienta automatizada, identificando las diferencias y sus causas. También resulta útil que los estudiantes redacten una declaración sobre el uso de herramientas de inteligencia artificial en sus trabajos, siguiendo las orientaciones de las organizaciones de ética editorial, de modo que la transparencia se convierta en un hábito desde las primeras etapas de la formación.

Estas experiencias desarrollan simultáneamente el dominio disciplinar, el pensamiento crítico y la alfabetización algorítmica, y preparan a los futuros investigadores para trabajar con herramientas que seguirán cambiando a lo largo de su carrera. El perfil descrito no debe entenderse como una lista de requisitos que cada investigador debe cumplir de manera individual. En la práctica, los equipos de investigación pueden distribuir estas competencias entre sus integrantes, de modo que algunos se especialicen en el dominio disciplinar, otros en los métodos computacionales y otros en la comunicación o la gestión de datos. Lo importante es que el equipo, en

su conjunto, disponga de las capacidades necesarias y que sus miembros compartan un lenguaje común que les permita colaborar.

Esta perspectiva colectiva resulta especialmente pertinente en la región, donde no siempre es posible encontrar en una misma persona todas las competencias requeridas, y donde la colaboración entre instituciones puede compensar las limitaciones de cada una. La formación de investigadores debería, por ello, cultivar también la capacidad de trabajar en equipo y de reconocer el valor de los saberes ajenos.

En este contexto, para las universidades del Ecuador y de América Latina, formar a este nuevo perfil de investigador constituye un desafío de primer orden. Los programas de grado y posgrado deberían incorporar contenidos sobre el funcionamiento y las limitaciones de la inteligencia artificial, prácticas supervisadas de uso responsable de estas herramientas en la investigación y espacios de reflexión ética sobre sus implicaciones.

Figura 1.8

El investigador del futuro: competencias científicas, pensamiento crítico y alfabetización algorítmica.



Fuente: Elaboración autores

EDITORIAL ANDES COGNITIO

CAPÍTULO II

INTELIGENCIA ARTIFICIAL Y CREATIVIDAD HUMANA: NUEVOS MODELOS PARA LA GENERACIÓN DE IDEAS CIENTÍFICAS



CAPÍTULO II

INTELIGENCIA ARTIFICIAL Y CREATIVIDAD HUMANA: NUEVOS MODELOS PARA LA GENERACIÓN DE IDEAS CIENTÍFICAS

2.1 Creatividad científica aumentada: interacción entre pensamiento humano y modelos generativos de inteligencia artificial

La creatividad científica suele asociarse con momentos de inspiración súbita, como la manzana de Newton o el sueño de Kekulé con la serpiente que se muerde la cola. La investigación sobre los procesos creativos muestra, sin embargo, que esos momentos son la culminación de un trabajo prolongado de inmersión en un problema, de acumulación de conocimiento, de ensayo y error y de conversación con otros. La creatividad científica combina la capacidad de generar ideas nuevas con la de evaluarlas, seleccionarlas y desarrollarlas hasta convertirlas en preguntas investigables, hipótesis contrastables o teorías coherentes.

La aparición de los modelos generativos de inteligencia artificial, capaces de producir textos, imágenes, códigos o moléculas a partir de instrucciones en lenguaje natural, ha abierto un debate intenso sobre si estas herramientas pueden participar en ese proceso y de qué manera. Desde esta perspectiva, los estudios experimentales recientes ofrecen una respuesta matizada. Koivisto y Grassini (2023) compararon el desempeño de personas y de varios asistentes conversacionales en una tarea clásica de pensamiento divergente, que consiste en proponer usos alternativos para objetos cotidianos.

En promedio, los sistemas de inteligencia artificial obtuvieron puntuaciones superiores a las de los participantes humanos, pero las personas con mejor desempeño igualaron o superaron a los mejores sistemas, lo que llevó a los autores a concluir que los humanos más creativos todavía aventajan a la inteligencia artificial en este tipo de tareas. Doshi y Hauser (2024), por su parte, realizaron un experimento en el que algunos participantes escribían relatos breves con acceso a ideas generadas por un modelo de lenguaje y otros lo hacían sin ayuda.

Las historias escritas con apoyo de la inteligencia artificial fueron evaluadas como más creativas, mejor escritas y más agradables, y el beneficio fue mayor para quienes tenían menor creatividad inicial. Sin embargo, esas historias resultaron más parecidas entre sí que las escritas sin ayuda, lo que los autores interpretan como una pérdida de novedad colectiva.

Este último hallazgo resulta especialmente relevante para la ciencia. Si cada investigador, al utilizar las mismas herramientas, produce ideas individualmente mejores pero colectivamente más homogéneas, la comunidad científica en su conjunto podría perder la diversidad de enfoques que impulsa el avance del conocimiento. Messeri y Crockett (2024) advierten sobre un riesgo similar al hablar de monoculturas científicas, en las que los métodos y preguntas que mejor se adaptan a las herramientas disponibles terminan desplazando a otros igualmente valiosos.

La creatividad científica aumentada exige, por tanto, un equilibrio cuidadoso entre el aprovechamiento de la capacidad generativa de los modelos y la preservación de la originalidad y la diversidad del pensamiento humano. De forma complementaria, la evidencia sobre la generación de ideas de investigación propiamente dichas apunta en la misma dirección. Si et al. (2025) organizaron un estudio a gran escala en el que más de cien investigadores en procesamiento del lenguaje natural redactaron ideas de investigación originales y evaluaron, sin conocer su origen, tanto esas ideas como otras generadas por un modelo de lenguaje.

Las ideas producidas por el modelo fueron juzgadas como más novedosas que las de los expertos humanos, aunque ligeramente menos factibles. Los autores identificaron, además, limitaciones importantes en los sistemas, como su incapacidad para evaluar adecuadamente sus propias propuestas y la falta de diversidad en las ideas generadas cuando se les pedía producir muchas. Estos resultados sugieren que los modelos pueden funcionar como generadores de alternativas novedosas, pero que la selección, la evaluación de la factibilidad y el desarrollo de las ideas siguen requiriendo el juicio de investigadores con experiencia.

A partir de esta evidencia es posible describir varias formas productivas de interacción entre el pensamiento humano y los modelos generativos. Una de ellas es la ampliación del espacio de ideas, en la que el investigador utiliza el modelo para generar un abanico amplio de posibilidades que después filtra y refina con su conocimiento del campo.

Otra consiste en el contraste, en el que se pide al modelo que cuestione una idea propia, que proponga objeciones o que identifique supuestos implícitos, de manera que el investigador fortalezca su razonamiento. Una tercera forma es la conexión entre dominios, en la que la herramienta ayuda a identificar analogías o métodos de otras disciplinas que podrían aplicarse al problema estudiado. Krenn et al. (2022) se refieren a esta función cuando describen a la

inteligencia artificial como una fuente de inspiración que revela conexiones o soluciones inesperadas que las personas transforman después en conceptos científicos.

Vinculado con lo anterior, para que estas interacciones resulten verdaderamente creativas, conviene adoptar algunas prácticas. Resulta útil, en primer término, formular las propias ideas antes de consultar al modelo, de modo que la herramienta amplíe el pensamiento del investigador en lugar de sustituirlo y homogeneizarlo. También conviene variar las instrucciones, las herramientas y las fuentes, buscando deliberadamente perspectivas divergentes, y registrar el proceso para poder reconstruir después qué aportó cada participante. Finalmente, la evaluación de las ideas debe realizarse con criterios explícitos de novedad, relevancia y factibilidad, preferiblemente en discusión con otros investigadores, porque es en esa conversación donde las ideas se transforman en proyectos sólidos.

En la práctica de un grupo de investigación, la creatividad aumentada puede organizarse mediante sesiones de trabajo con una estructura definida. Un esquema útil comienza con un momento individual en el que cada integrante formula sus ideas sin apoyo de herramientas, sigue con una fase en la que el grupo consulta a uno o varios modelos para ampliar el abanico de alternativas, y concluye con una discusión colectiva en la que se comparan las propuestas humanas y las generadas, se identifican las más prometedoras y se registran los criterios utilizados para seleccionarlas.

Este esquema aprovecha la capacidad generativa de las herramientas, preserva la originalidad individual y aprovecha la inteligencia colectiva del grupo para la evaluación. Además, al documentar el proceso, el grupo puede reconstruir después el origen de cada idea y declararlo con transparencia en sus publicaciones. Para los semilleros de investigación y los programas de posgrado de las universidades ecuatorianas, este tipo de dinámicas puede convertirse en un recurso pedagógico valioso, que enseña a utilizar las herramientas sin renunciar al pensamiento propio.

Los riesgos de la creatividad aumentada se manifiestan con particular intensidad en la formación de los investigadores jóvenes. Un estudiante que recurre a un modelo generativo cada vez que necesita una idea puede no desarrollar la capacidad de generarlas por sí mismo, del mismo modo que quien utiliza siempre una calculadora puede perder la destreza para el cálculo mental. Por ello, los programas de formación deberían alternar momentos de trabajo con herramientas

y momentos de trabajo sin ellas, de manera que los estudiantes cultiven su propia creatividad y aprendan, al mismo tiempo, a utilizar las herramientas como complemento.

Los directores de tesis tienen aquí una responsabilidad especial, porque pueden orientar a sus estudiantes en el uso equilibrado de la inteligencia artificial y valorar explícitamente las ideas originales que estos aporten, aun cuando sean menos pulidas que las sugeridas por una máquina.

En concordancia con ello, en el contexto latinoamericano, la creatividad científica aumentada puede contribuir a democratizar el acceso a ciertas formas de apoyo intelectual. Un estudiante de posgrado en una universidad pequeña, sin acceso cotidiano a una comunidad amplia de especialistas, puede utilizar estas herramientas para explorar enfoques alternativos, identificar literatura relevante o poner a prueba sus argumentos.

Sin embargo, este beneficio solo se materializa si el estudiante cuenta con la formación necesaria para evaluar críticamente lo que la herramienta le propone y si su institución promueve un uso transparente y reflexivo. La creatividad aumentada no reemplaza la formación de comunidades de investigación, sino que puede complementarla, siempre que se preserve el espacio para el pensamiento propio, la discusión entre pares y la originalidad que surge de la experiencia y del conocimiento situado.

Figura 2.1

Creatividad científica aumentada



Fuente: Elaboración autores

2.2 Inteligencia artificial como herramienta para identificar problemas científicos emergentes y vacíos de conocimiento

Encontrar un buen problema de investigación es, probablemente, la tarea más difícil y decisiva del trabajo científico. Un problema bien planteado orienta todas las decisiones posteriores, desde la elección del método hasta la interpretación de los resultados, mientras que un problema mal definido puede conducir a investigaciones técnicamente impecables pero irrelevantes.

Tradicionalmente, la identificación de problemas y vacíos de conocimiento dependía de la lectura extensa de la literatura, de la experiencia acumulada en un campo y de la participación en congresos y redes de colegas. Sin embargo, el crecimiento exponencial de la producción científica ha vuelto imposible que una persona lea todo lo que se publica incluso en un área especializada, lo que dificulta reconocer qué preguntas ya han sido respondidas, cuáles permanecen abiertas y dónde surgen temas emergentes. No obstante, la inteligencia artificial ofrece herramientas para enfrentar este desafío.

Los sistemas de procesamiento del lenguaje natural pueden leer y clasificar miles de resúmenes en poco tiempo, agrupar los trabajos por temas, identificar los conceptos que aparecen con mayor frecuencia y detectar aquellos cuya presencia crece con rapidez. Van de Schoot et al. (2021) desarrollaron un marco de código abierto que utiliza el aprendizaje activo para apoyar la selección de estudios en revisiones sistemáticas: el sistema aprende de las decisiones del investigador sobre qué artículos son relevantes y prioriza la presentación de los textos con mayor probabilidad de serlo, lo que reduce de manera considerable el número de documentos que es necesario revisar manualmente.

Aunque esta herramienta se diseñó para las revisiones sistemáticas, su lógica resulta útil para cualquier exploración amplia de la literatura orientada a identificar vacíos de conocimiento, porque permite concentrar la lectura humana en los textos más pertinentes.

Más allá de la clasificación de documentos, los modelos de lenguaje pueden ayudar a sintetizar el estado del conocimiento sobre un tema, a comparar los resultados de distintos estudios y a señalar contradicciones o preguntas sin respuesta. H. Wang et al. (2023) destacan que la capacidad de la inteligencia artificial para procesar grandes volúmenes de información heterogénea permite detectar relaciones que pasarían inadvertidas en un análisis manual, por ejemplo, entre resultados publicados en disciplinas distintas. Krenn et al. (2022) señalan, en la misma línea, que una de las funciones más prometedoras de estos sistemas es la de servir como fuente de

inspiración, al revelar conexiones sorprendentes entre literaturas distantes que los investigadores pueden convertir después en nuevas preguntas.

Un vacío de conocimiento no siempre es un tema que nadie ha estudiado; a menudo es la ausencia de diálogo entre dos campos que trabajan sobre problemas relacionados sin conocerse. Con todo, estas capacidades deben utilizarse con plena conciencia de sus limitaciones. Los modelos de lenguaje pueden generar síntesis que parecen completas pero omiten trabajos importantes, atribuyen hallazgos a autores equivocados o inventan referencias inexistentes, como han documentado Walters y Wilder (2023) en su análisis de las citas bibliográficas producidas por estos sistemas.

Por otra parte, las bases de datos con las que se entrenan los modelos y las que utilizan los sistemas de búsqueda están dominadas por publicaciones en inglés y por revistas de los países con mayor producción científica, lo que puede invisibilizar la investigación publicada en español, en portugués o en revistas regionales. Un vacío de conocimiento detectado por una herramienta automatizada puede no ser real, sino reflejar simplemente que la literatura relevante no está incluida en las fuentes consultadas.

Dwivedi et al. (2023), en un trabajo que reunió perspectivas de numerosos especialistas sobre las oportunidades y desafíos de la inteligencia artificial conversacional para la investigación, coinciden en reconocer su potencial para acelerar la revisión de literatura y la identificación de temas, pero advierten sobre los riesgos de inexactitud, sesgo y dependencia excesiva.

Una advertencia adicional proviene de Messeri y Crockett (2024), quienes señalan que el uso generalizado de las mismas herramientas puede conducir a que muchos investigadores identifiquen los mismos vacíos y se concentren en las mismas preguntas, reduciendo la diversidad temática de la ciencia. Para evitarlo, la identificación de problemas asistida por inteligencia artificial debe combinarse con fuentes de inspiración diversas, entre ellas la observación directa de la realidad, el diálogo con actores sociales y la experiencia profesional de los investigadores.

A ello se suma que en la práctica, un procedimiento razonable para identificar problemas con apoyo de la inteligencia artificial podría organizarse en varias fases. En un primer momento, el investigador define el campo general de interés y construye, con ayuda de herramientas de búsqueda y clasificación, un corpus amplio de literatura que incluya deliberadamente fuentes regionales y en distintos idiomas.

Posteriormente, utiliza técnicas de agrupamiento temático y de análisis de tendencias para identificar las líneas de investigación consolidadas, las emergentes y las que muestran poca actividad. A continuación, examina directamente los trabajos más relevantes de cada línea para verificar las conclusiones de las herramientas y para identificar preguntas abiertas, contradicciones o limitaciones reconocidas por los propios autores.

Finalmente, contrasta esos vacíos con las necesidades de su contexto, preguntándose si su resolución aportaría conocimiento relevante para la sociedad en la que trabaja. Esta última fase es la que otorga sentido a todo el proceso, especialmente en América Latina. Muchos problemas de gran relevancia para la región, como las enfermedades desatendidas, la gestión de ecosistemas tropicales, la informalidad laboral o la educación en contextos rurales, reciben menos atención en la literatura internacional que los problemas de los países con mayor producción científica.

Una herramienta que solo detecta vacíos en la literatura global podría pasar por alto estas prioridades. Por ello, la inteligencia artificial resulta más útil cuando se pone al servicio de una agenda de investigación definida desde las necesidades del territorio, en la que la tecnología ayuda a conocer qué se sabe y qué falta saber, pero la decisión sobre qué investigar responde al juicio de los investigadores y al diálogo con la sociedad.

Un ejemplo permite mostrar el valor y los límites de este procedimiento. Un equipo interesado en la salud mental de los estudiantes universitarios en el Ecuador podría utilizar herramientas automatizadas para analizar miles de artículos sobre el tema y descubrir que la literatura internacional se concentra en ciertos factores, como el estrés académico o el uso de redes sociales, mientras que otros, como la migración de familiares, la violencia de género o la inseguridad económica, aparecen con menor frecuencia.

Este hallazgo podría sugerir vacíos de conocimiento relevantes para el contexto nacional. Sin embargo, antes de formular su pregunta, el equipo debería revisar la literatura regional que las herramientas pudieron omitir, consultar a profesionales de bienestar estudiantil y a los propios estudiantes, y examinar los datos institucionales disponibles. Solo la combinación de la exploración automatizada con este conocimiento situado permitiría identificar un problema de investigación a la vez original, pertinente y factible.

La inteligencia artificial habría acelerado la exploración, pero la definición del problema seguiría dependiendo del juicio del equipo y de su diálogo con el contexto. Las bases de datos y los

repositorios regionales desempeñan un papel decisivo en este proceso. Cuando los investigadores latinoamericanos depositan sus trabajos en repositorios abiertos, con metadatos completos y en varios idiomas, contribuyen a que las herramientas de búsqueda y de análisis automatizado incluyan la producción de la región en sus resultados.

Del mismo modo, cuando los sistemas regionales de información científica ofrecen interfaces que permiten la descarga masiva de registros, facilitan los análisis de literatura que combinan fuentes internacionales y regionales. Fortalecer estas infraestructuras no es solo una cuestión de visibilidad, sino también una condición para que la identificación de problemas y vacíos de conocimiento mediante inteligencia artificial refleje adecuadamente la investigación realizada en América Latina y no la invisibilice.

Figura 2.2

Identificación de problemas y vacíos de conocimiento



Fuente: Elaboración autores

2.3 Ingeniería de instrucciones (prompt engineering) aplicada a la formulación de preguntas de investigación

Los modelos de lenguaje de gran escala responden a instrucciones escritas en lenguaje natural, y la calidad de sus respuestas depende en buena medida de la manera en que esas instrucciones se formulan. Una petición vaga produce, por lo general, una respuesta genérica; una petición precisa, que define el contexto, el propósito, el formato esperado y los criterios de calidad, tiende a producir resultados más útiles.

A este conjunto de técnicas para diseñar instrucciones efectivas se le conoce como ingeniería de instrucciones o, en su denominación inglesa más difundida, prompt engineering. Aunque nació en el ámbito técnico del procesamiento del lenguaje natural, se ha convertido en una competencia práctica para cualquier persona que utilice estas herramientas en su trabajo, incluidos los investigadores que buscan apoyo para formular sus preguntas de investigación.

Además, desde el punto de vista técnico, Liu et al. (2023) describen en una revisión sistemática cómo el paradigma de trabajo con modelos de lenguaje pasó del entrenamiento específico para cada tarea a un esquema en el que un modelo preentrenado de propósito general se adapta a distintas tareas mediante instrucciones cuidadosamente diseñadas, sin necesidad de modificar sus parámetros internos.

Los autores muestran que pequeñas variaciones en la redacción de una instrucción pueden modificar sustancialmente el desempeño del modelo, y clasifican las técnicas disponibles según la forma de las instrucciones, la manera de incluir ejemplos y las estrategias para combinar varias instrucciones. Esta sensibilidad a la formulación explica por qué dos investigadores que consultan la misma herramienta sobre el mismo tema pueden obtener respuestas de calidad muy distinta, y por qué conviene tratar la redacción de instrucciones como una habilidad que se aprende y se perfecciona.

En el ámbito de la escritura académica, Giray (2023) sostiene que los autores y los investigadores necesitan adquirir competencias de ingeniería de instrucciones para aprovechar adecuadamente los modelos de lenguaje, y examina tanto las técnicas útiles como los errores frecuentes en la redacción de instrucciones. Aplicadas a la formulación de preguntas de investigación, estas técnicas pueden organizarse en torno a algunos elementos básicos.

Ante todo está el contexto, que consiste en describir el campo disciplinar, el problema general, la población o el territorio de interés y los antecedentes que el investigador ya conoce. Luego viene el rol, en el que se pide al modelo que adopte una perspectiva determinada, por ejemplo, la de un evaluador metodológico exigente o la de un especialista de otra disciplina. Un tercer elemento es la tarea concreta, como generar posibles preguntas, evaluar la claridad de una pregunta ya formulada o identificar variables y supuestos. Y el último son los criterios y el formato, que indican qué características debe cumplir una buena pregunta, como la relevancia, la factibilidad o la delimitación, y cómo deben presentarse los resultados.

En la práctica, un ejemplo permite ilustrar el contraste entre una instrucción pobre y una bien diseñada. Una investigadora interesada en la deserción universitaria podría escribir simplemente «dame preguntas de investigación sobre deserción», y obtendría probablemente una lista de preguntas generales y poco originales. En cambio, si describe que trabaja en una universidad pública de la Sierra ecuatoriana, que dispone de registros académicos de cinco cohortes, que le interesa la relación entre la condición laboral de los estudiantes y el abandono en los primeros semestres, y pide que se le propongan preguntas delimitadas, factibles con esos datos y que eviten repetir lo ya estudiado, obtendrá sugerencias mucho más útiles. Más aún, si luego solicita al modelo que critique cada pregunta desde el punto de vista metodológico, podrá refinar su planteamiento de manera iterativa.

La ingeniería de instrucciones tiene, sin embargo, límites que conviene reconocer. Una instrucción excelente no convierte al modelo en una fuente confiable de información factual: las herramientas pueden afirmar que cierto tema no ha sido estudiado cuando sí lo ha sido, o citar trabajos inexistentes para respaldar sus sugerencias, como han documentado Walters y Wilder (2023), quienes encontraron que una proporción considerable de las citas generadas por estos sistemas eran inventadas o contenían errores sustanciales.

Por ello, la ingeniería de instrucciones debe entenderse como una técnica para mejorar el diálogo con la herramienta, no como un sustituto de la revisión directa de la literatura ni del juicio del investigador. La pregunta de investigación definitiva debe surgir del contraste entre las sugerencias del modelo, la literatura verificada y el conocimiento del contexto. En esta misma línea, existe también un aspecto ético que no debe pasarse por alto.

Al formular instrucciones, los investigadores pueden introducir en las herramientas información confidencial, datos personales de participantes o ideas inéditas, sin saber cómo se almacenará o utilizará esa información. Miao y Holmes (2023), en la guía de la UNESCO sobre inteligencia artificial generativa en educación e investigación, insisten en la protección de la privacidad de los datos como una de las condiciones para el uso responsable de estas herramientas.

En el Ecuador, la Ley Orgánica de Protección de Datos Personales establece obligaciones específicas sobre el tratamiento de información personal (Asamblea Nacional del Ecuador, 2021), que se aplican también cuando esa información se introduce en plataformas de inteligencia artificial. Antes de incluir datos de participantes en una instrucción, el investigador debe

asegurarse de que estén debidamente anonimizados y de que el uso de la herramienta sea compatible con el consentimiento otorgado.

Algunas pautas prácticas pueden ayudar a los investigadores a formular instrucciones más efectivas para trabajar sus preguntas de investigación. Conviene dividir las tareas complejas en pasos sucesivos, por ejemplo, pedir primero una lista de enfoques posibles, luego la evaluación de cada uno según criterios explícitos y finalmente la formulación de preguntas para los enfoques seleccionados. Resulta útil también pedir al modelo que explique su razonamiento, lo que facilita la detección de supuestos equivocados, y solicitar varias alternativas en lugar de una única respuesta, para no quedar atrapado en la primera sugerencia.

Del mismo modo, es recomendable indicar explícitamente lo que no se desea, como preguntas demasiado amplias o centradas en contextos ajenos, y pedir que las sugerencias se ajusten a los recursos y datos disponibles. Por último, conviene guardar un registro de las instrucciones utilizadas y de las respuestas obtenidas, tanto para documentar el proceso como para aprender de él. Estas pautas no garantizan buenas preguntas, pero aumentan la probabilidad de que el diálogo con la herramienta resulte útil y de que el investigador mantenga el control sobre su propio planteamiento.

Conviene advertir, por último, que la ingeniería de instrucciones evoluciona con rapidez. Las técnicas que resultan eficaces con una generación de modelos pueden volverse innecesarias o incluso contraproducentes con la siguiente, a medida que los sistemas mejoran su capacidad para interpretar peticiones imprecisas.

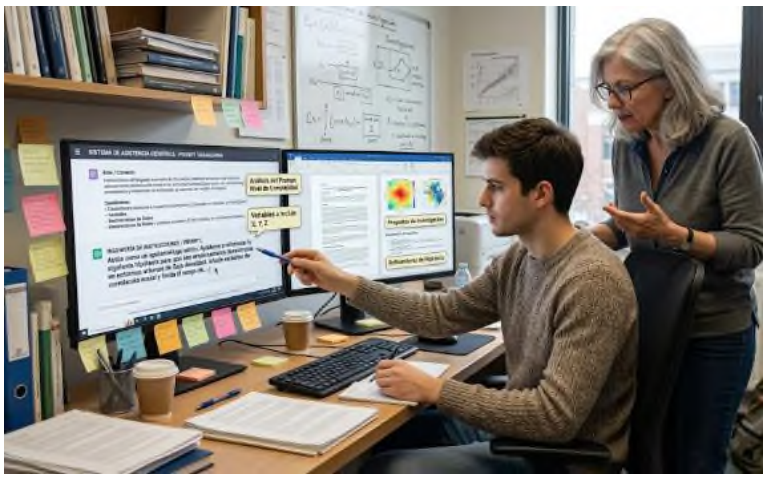
Por ello, más que memorizar fórmulas específicas, los investigadores deberían comprender los principios generales que hacen útil una instrucción, como la claridad del propósito, la explicitación del contexto, la definición de criterios de calidad y la verificación de los resultados. Estos principios coinciden, en gran medida, con los de cualquier buena comunicación y con los del buen planteamiento de un problema de investigación, lo que sugiere que la formación en ingeniería de instrucciones puede integrarse de manera natural en la enseñanza de la metodología y de la escritura académica.

En esos cursos, los estudiantes pueden aprender a explicitar el contexto de sus problemas, a definir criterios de calidad para sus preguntas, a dialogar críticamente con las herramientas y a documentar ese diálogo. Paradójicamente, aprender a formular buenas instrucciones obliga a pensar con mayor claridad sobre el propio problema de investigación, porque exige explicitar

supuestos, delimitar el alcance y definir qué se espera obtener. Bien enseñada, la ingeniería de instrucciones no debilita la formación metodológica, sino que puede reforzarla, siempre que se acompañe de la verificación rigurosa y de la reflexión sobre el papel que la herramienta desempeña en el proceso.

Figura 2.3

Ingeniería de instrucciones y preguntas de investigación



Fuente: Elaboración autores

2.4 Generación asistida de hipótesis científicas mediante modelos de lenguaje y sistemas inteligentes

Una hipótesis científica es una respuesta tentativa a una pregunta de investigación, formulada de manera que pueda ser contrastada con la evidencia. Su generación ha sido tradicionalmente considerada una de las actividades más creativas de la ciencia, porque exige combinar el conocimiento existente con la imaginación para proponer explicaciones que todavía no han sido demostradas.

Los filósofos de la ciencia distinguieron durante mucho tiempo entre el momento de la generación de hipótesis, que consideraban difícil de sistematizar, y el de su contrastación, que podía someterse a reglas metodológicas. La inteligencia artificial está desafiando esa distinción, porque ofrece herramientas capaces de proponer hipótesis de manera sistemática a partir de grandes volúmenes de datos y de literatura científica. H. Wang et al. (2023) identifican la generación de hipótesis como una de las áreas en las que la inteligencia artificial ya contribuye de manera significativa a la investigación.

Los autores describen cómo los modelos pueden explorar espacios de posibilidades demasiado amplios para la búsqueda humana, por ejemplo, el conjunto de moléculas candidatas para un fármaco o de materiales con determinadas propiedades, y proponer aquellas que tienen mayor probabilidad de cumplir los objetivos de la investigación. En estos casos, la hipótesis adopta la forma de una predicción concreta, como que determinada molécula se unirá a una proteína o que cierto material tendrá una conductividad elevada, que después se verifica experimentalmente. Los modelos generativos permiten incluso diseñar candidatos que no existen en las bases de datos, ampliando el repertorio de hipótesis más allá de lo ya conocido.

Los modelos de lenguaje de gran escala añaden una modalidad diferente de generación de hipótesis, basada en el procesamiento de la literatura y en el razonamiento en lenguaje natural. Estos sistemas pueden leer miles de artículos, identificar resultados aparentemente contradictorios, proponer mecanismos que los expliquen y sugerir experimentos para ponerlos a prueba. S. Gao et al. (2024) describen, en el ámbito biomédico, la perspectiva de agentes de inteligencia artificial capaces de razonar de manera escéptica, planificar flujos de trabajo de descubrimiento y evaluar sus propios conocimientos para identificar y reducir sus lagunas, colaborando con plataformas experimentales.

Los autores subrayan, no obstante, que las personas deben permanecer en el proceso de descubrimiento y que el papel de los agentes es complementar la creatividad y la experiencia humanas, encargándose del análisis de grandes conjuntos de datos, de la exploración del espacio de hipótesis y de las tareas repetitivas. Paralelamente, la evidencia empírica sobre la calidad de las hipótesis generadas por estos sistemas es todavía limitada, pero ofrece algunas orientaciones.

En el estudio de Si et al. (2025), las ideas de investigación producidas por un modelo de lenguaje fueron evaluadas por expertos como más novedosas que las propuestas por investigadores humanos, aunque algo menos factibles, y los autores observaron que el sistema tenía dificultades para evaluar sus propias ideas y para mantener la diversidad cuando generaba muchas propuestas.

Este patrón sugiere una división del trabajo razonable, según la cual los modelos pueden aportar amplitud y novedad en la generación, mientras que los investigadores aportan el juicio sobre la factibilidad, la relevancia y la coherencia con el conocimiento establecido. Una hipótesis novedosa pero imposible de contrastar con los recursos disponibles, o que contradice sin justificación evidencias sólidas, tiene escaso valor científico.

Krenn et al. (2022) ofrecen un marco útil para pensar el papel de estos sistemas en la generación de hipótesis. En su función de fuente de inspiración, la inteligencia artificial puede revelar datos atípicos, conexiones entre literaturas o comportamientos de los modelos que sugieren nuevas hipótesis, pero son las personas quienes transforman esas señales en conceptos y explicaciones. Esta perspectiva evita dos errores opuestos. Uno es subestimar el aporte de las herramientas, ignorando que pueden señalar caminos que los investigadores no habrían considerado; el otro, sobreestimarlo, atribuyendo a los sistemas una comprensión que no poseen.

La hipótesis sigue siendo una construcción humana, aunque los materiales con los que se construye puedan provenir, cada vez más, del trabajo de sistemas inteligentes. Sobre esta base, el uso de herramientas inteligentes para generar hipótesis exige, además, precauciones metodológicas específicas. Cuando un investigador genera muchas hipótesis con ayuda de un modelo y luego contrasta todas ellas con los mismos datos, aumenta el riesgo de encontrar resultados significativos por azar, un problema conocido en estadística como el de las comparaciones múltiples.

Para evitarlo, conviene separar los datos utilizados para generar hipótesis de los empleados para contrastarlas, registrar previamente las hipótesis que se pondrán a prueba y aplicar correcciones estadísticas apropiadas. Kapoor y Narayanan (2023) mostraron que la falta de separación adecuada entre los datos de entrenamiento y de evaluación es una de las principales causas de resultados irreproducibles en la ciencia basada en aprendizaje automático, una advertencia que se aplica igualmente a la generación asistida de hipótesis.

Un caso hipotético ayuda a ilustrar el proceso. Un grupo que investiga el rendimiento de cultivos de cacao en la Costa ecuatoriana dispone de datos de varios años sobre producción, clima, prácticas de manejo y características del suelo. Mediante herramientas de aprendizaje automático, el grupo identifica que ciertas combinaciones de precipitación y temperatura durante la floración se asocian con caídas en el rendimiento, y un modelo de lenguaje, alimentado con la literatura agronómica, sugiere varias explicaciones posibles, desde efectos sobre la polinización hasta la proliferación de enfermedades.

Con esa información, el equipo selecciona las hipótesis más plausibles según su conocimiento del cultivo, diseña ensayos de campo y observaciones específicas para ponerlas a prueba y reserva una parte de los datos para la contrastación independiente. Al publicar sus resultados,

describe con precisión cómo se generaron y seleccionaron las hipótesis y qué papel desempeñaron las herramientas.

En este caso, la inteligencia artificial amplió el repertorio de explicaciones consideradas, pero la selección, el diseño de la contrastación y la interpretación final se apoyaron en el conocimiento agronómico y en el rigor metodológico del equipo. La transparencia sobre el proceso de generación de hipótesis adquiere, en este contexto, una importancia especial. Tradicionalmente, los artículos científicos presentaban las hipótesis como si hubieran surgido directamente de la teoría, sin describir el proceso, a menudo desordenado, por el que los investigadores llegaron a ellas.

Cuando intervienen herramientas de inteligencia artificial, esta omisión puede ocultar información relevante para evaluar el trabajo, por ejemplo, si las hipótesis contrastadas fueron seleccionadas entre muchas generadas automáticamente. El registro previo de las hipótesis y de los análisis, una práctica que se ha extendido en varias disciplinas para combatir los sesgos de publicación, ofrece una solución, porque permite distinguir claramente entre los análisis confirmatorios, planificados antes de ver los datos, y los exploratorios, que generan nuevas hipótesis para investigaciones futuras.

Desde esta perspectiva, para los grupos de investigación de la región, la generación asistida de hipótesis puede ser especialmente valiosa en campos con abundancia de datos y escasez de especialistas, como el análisis de registros de salud, de datos ambientales o de información educativa. Un equipo pequeño puede utilizar estas herramientas para explorar relaciones en sus datos y en la literatura, y concentrar sus limitados recursos experimentales en las hipótesis más prometedoras.

Sin embargo, el éxito de esta estrategia depende de que el equipo conozca bien el dominio, de que documente el proceso de generación y selección de hipótesis y de que las someta después a contrastaciones rigurosas. La inteligencia artificial puede acelerar el camino hacia una buena hipótesis, pero no puede reemplazar la responsabilidad del investigador de justificar por qué esa hipótesis merece ser investigada y de demostrar, con evidencia, si es correcta o no.

Figura 2.4

Generación asistida de hipótesis científicas



Fuente: Elaboración autores

2.5 Pensamiento divergente, razonamiento abductivo y creatividad computacional en la investigación

La investigación científica combina dos formas de pensamiento que a menudo se presentan como opuestas. El pensamiento divergente consiste en generar muchas alternativas posibles frente a un problema, explorando caminos distintos sin descartarlos prematuramente; el convergente, en cambio, selecciona entre esas alternativas la más adecuada según criterios definidos. Ambos son necesarios, porque sin divergencia la ciencia se limitaría a repetir las soluciones conocidas, y sin convergencia se dispersaría en ideas que nunca se ponen a prueba.

A estas dos formas de pensamiento se suma un tipo de razonamiento particularmente importante para el descubrimiento: el razonamiento abductivo, que consiste en inferir la explicación más plausible de un fenómeno sorprendente. Cuando un médico propone un diagnóstico a partir de un conjunto de síntomas, o cuando un astrónomo postula la existencia de un planeta para explicar una anomalía en la órbita de otro, está razonando abductivamente.

De forma complementaria, la creatividad computacional, entendida como el estudio y el desarrollo de sistemas capaces de producir resultados que serían considerados creativos si los produjera una persona, ha avanzado considerablemente con los modelos generativos. En el terreno del pensamiento divergente, la evidencia experimental muestra que estos sistemas pueden igualar o superar el desempeño promedio de las personas en tareas que consisten en generar ideas originales.

Como se señaló en el apartado 2.1, Koivisto y Grassini (2023) encontraron que, en una tarea de usos alternativos de objetos y en promedio, los sistemas obtuvieron mejores puntuaciones, aunque las personas más creativas superaron a los mejores sistemas. Este resultado sugiere que los modelos generativos pueden actuar como un potente generador de alternativas, útil especialmente en las fases iniciales de exploración de un problema.

El razonamiento abductivo plantea un desafío mayor para los sistemas computacionales. Inferir la mejor explicación de un fenómeno requiere no solo generar alternativas, sino evaluarlas según su coherencia con el conocimiento existente, su simplicidad, su capacidad para explicar otros fenómenos y su contrastabilidad. Los modelos de lenguaje pueden producir explicaciones plausibles para casi cualquier observación, pero la plausibilidad lingüística no equivale a la validez científica. Bender et al. (2021) advirtieron, en un trabajo muy influyente, que los modelos de lenguaje generan textos a partir de patrones estadísticos aprendidos de grandes volúmenes de datos, sin una comprensión del significado comparable a la humana, por lo que su fluidez puede inducir a los usuarios a atribuirles un entendimiento que no poseen.

En el razonamiento abductivo, esta fluidez puede resultar engañosa, porque una explicación bien redactada puede parecer convincente aunque carezca de fundamento. Por ello, la combinación más productiva no consiste en delegar la abducción en las máquinas, sino en utilizarlas para enriquecer cada etapa del proceso. En la fase divergente, los modelos pueden proponer explicaciones alternativas que el investigador no había considerado, incluidas algunas procedentes de otras disciplinas.

En la fase de evaluación, pueden ayudar a identificar las implicaciones de cada explicación y los datos que permitirían distinguir entre ellas. Y en la fase de contrastación, pueden contribuir al diseño de experimentos o análisis que pongan a prueba las explicaciones más prometedoras. A lo largo de todo el proceso, el investigador conserva la responsabilidad de juzgar qué explicaciones merecen atención y cuáles deben descartarse. Krenn et al. (2022) enfatizan que la

comprensión científica, es decir, la capacidad de razonar cualitativamente sobre las consecuencias de una teoría, sigue siendo una capacidad humana que las herramientas pueden estimular, pero no sustituir.

El uso de la creatividad computacional en la investigación presenta, además, un riesgo colectivo que ya se ha mencionado: la homogeneización. El experimento de Doshi y Hauser (2024), comentado en el apartado 2.1, mostró que las ideas producidas con ayuda de un modelo generativo eran individualmente mejor valoradas, pero colectivamente más parecidas entre sí. Si muchos investigadores recurren a las mismas herramientas para generar explicaciones, la diversidad de hipótesis de una comunidad científica podría reducirse, justamente en el ámbito en que la diversidad resulta más valiosa.

La propia evidencia sobre la generación de ideas de investigación indica que los modelos tienden a producir propuestas poco variadas cuando se les pide generar muchas (Si et al., 2025). Frente a este riesgo, conviene combinar diferentes herramientas, variar las instrucciones, incorporar deliberadamente perspectivas minoritarias y valorar las ideas que se apartan de las sugerencias de los modelos. Vinculado con lo anterior, en la formación de investigadores, el pensamiento divergente y el razonamiento abductivo pueden ejercitarse de manera intencionada con apoyo de estas herramientas.

Un ejercicio útil consiste en pedir a los estudiantes que formulen sus propias explicaciones de un fenómeno antes de consultar a un modelo, que comparen después sus propuestas con las generadas por la herramienta y que evalúen todas según criterios explícitos. Otro consiste en solicitar al modelo explicaciones deliberadamente heterodoxas para obligar a los estudiantes a argumentar por qué son o no plausibles. Estos ejercicios no solo enseñan a utilizar las herramientas, sino que fortalecen las capacidades que estas no pueden reemplazar, como el juicio crítico, el conocimiento del dominio y la imaginación disciplinada que caracteriza a la buena ciencia.

La enseñanza del razonamiento abductivo en la formación de investigadores puede apoyarse en casos tomados de la propia historia de la ciencia y de la realidad local. Analizar cómo los investigadores identificaron las causas de una epidemia, explicaron la presencia de una especie fuera de su área habitual o interpretaron un comportamiento inesperado en un sistema social permite a los estudiantes comprender que la inferencia de la mejor explicación combina imaginación, conocimiento y rigor.

Las herramientas de inteligencia artificial pueden incorporarse a estos ejercicios como interlocutores que proponen hipótesis alternativas, pero el énfasis debe ponerse en los criterios para evaluarlas: la coherencia con la evidencia disponible, la capacidad para explicar otros hechos, la simplicidad, la posibilidad de contrastarlas y la consistencia con el conocimiento establecido.

Un estudiante que domina estos criterios puede aprovechar la creatividad computacional sin dejarse seducir por explicaciones bien redactadas pero infundadas, una habilidad cada vez más necesaria en un entorno donde abundan los textos plausibles y escasea la verificación. Para los grupos de investigación, una forma práctica de aprovechar estas reflexiones consiste en institucionalizar momentos de divergencia y de convergencia en sus reuniones de trabajo.

En los momentos de divergencia, se privilegia la generación libre de ideas, con o sin apoyo de herramientas, y se evita la crítica prematura; en los de convergencia, se aplican criterios explícitos para seleccionar las ideas más prometedoras y se discute su fundamentación. Separar estos momentos permite que la creatividad no se vea inhibida por la evaluación inmediata y que la evaluación no se vea contaminada por el entusiasmo de la generación. Las herramientas de inteligencia artificial pueden participar en ambos momentos, pero conviene que el grupo mantenga el control sobre los criterios de selección y que registre las razones por las que se adoptan o descartan las distintas ideas.

En concordancia con ello, en América Latina, donde la investigación se enfrenta a menudo a fenómenos poco estudiados, como ecosistemas únicos, enfermedades propias de la región o dinámicas sociales particulares, el razonamiento abductivo adquiere una importancia especial. Los modelos entrenados con la literatura internacional pueden carecer de información suficiente sobre estos fenómenos y proponer explicaciones basadas en contextos muy distintos.

Figura 2.5

Pensamiento divergente y razonamiento abductivo



Fuente: Elaboración autores

2.6 Diseño de modelos conceptuales y marcos teóricos mediante colaboración humano–máquina

Todo proyecto de investigación se apoya en un marco teórico, es decir, en un conjunto organizado de conceptos, supuestos y relaciones que orienta la formulación del problema, la selección de las variables y la interpretación de los resultados. El modelo conceptual traduce ese marco en una representación más concreta, a menudo gráfica, que muestra cómo se relacionan los elementos del fenómeno estudiado.

Construir un buen marco teórico requiere conocer en profundidad la literatura, identificar las teorías pertinentes, compararlas críticamente, seleccionar o combinar aquellas que mejor explican el problema y justificar esa elección. Es una tarea intelectualmente exigente, que en los estudiantes de posgrado suele ser una de las principales fuentes de dificultad y en los investigadores experimentados, una de las principales fuentes de originalidad.

A ello se suma que la colaboración entre personas y sistemas inteligentes puede apoyar varias fases de esta tarea. En la fase de exploración, las herramientas de procesamiento del lenguaje pueden ayudar a identificar las teorías que se han utilizado para estudiar un fenómeno, a reconocer los autores y obras más influyentes, y a mapear cómo han evolucionado los conceptos a lo largo del tiempo.

En la fase de comparación, los modelos de lenguaje pueden sintetizar los supuestos y las proposiciones principales de distintas teorías, señalar sus coincidencias y divergencias, y sugerir

posibles combinaciones. En la fase de representación, algunas herramientas pueden generar borradores de diagramas conceptuales a partir de una descripción verbal de las relaciones entre variables, que el investigador refina después. En cada caso, la herramienta acelera tareas laboriosas y amplía el campo de alternativas consideradas.

Sin embargo, la construcción de marcos teóricos es precisamente el tipo de tarea en la que las limitaciones de los modelos de lenguaje resultan más problemáticas. Bender et al. (2021) advirtieron que estos sistemas producen textos coherentes a partir de patrones estadísticos, sin un acceso al significado comparable al humano, y que su apariencia de fluidez puede llevar a los usuarios a atribuirles comprensión.

En el terreno teórico, esto puede traducirse en síntesis que mezclan conceptos de tradiciones incompatibles, atribuyen a un autor ideas que pertenecen a otro o presentan como consensuadas posiciones que son objeto de debate. Un marco teórico construido sin verificar estas síntesis contra las fuentes originales puede tener una apariencia sólida y, sin embargo, carecer de coherencia interna o de fidelidad a las teorías que dice utilizar. Messeri y Crockett (2024) añaden, por su parte, una advertencia de orden epistemológico, pues las herramientas de inteligencia artificial pueden generar ilusiones de comprensión, en las que el investigador cree dominar un campo teórico porque dispone de resúmenes bien redactados, aunque no haya leído ni comprendido las obras originales.

En la construcción de marcos teóricos, esta ilusión es particularmente peligrosa, porque el valor de un marco reside en la comprensión profunda de sus conceptos y en la capacidad de usarlos con precisión. Un investigador que conoce una teoría solo a través de síntesis automáticas difícilmente podrá aplicarla con creatividad, defenderla frente a críticas o identificar sus limitaciones en el contexto de su estudio.

Por estas razones, la colaboración humano–máquina en el diseño de marcos teóricos debería organizarse según una división clara de responsabilidades. A la herramienta pueden asignarse tareas de búsqueda, organización preliminar, síntesis provisional y generación de alternativas. Al investigador corresponden la lectura directa de las obras fundamentales, la verificación de las síntesis, la selección justificada de las teorías, la articulación de los conceptos en un marco coherente y la explicación de por qué ese marco es pertinente para el problema y el contexto estudiados.

Duede (2023) recuerda que los resultados obtenidos con ayuda de herramientas opacas pueden ser científicamente valiosos siempre que se integren en procesos de justificación independientes, y en el caso de los marcos teóricos esa justificación consiste, precisamente, en el examen crítico de las fuentes y en la argumentación razonada del investigador. Además, la perspectiva de la inteligencia colectiva ofrece una vía adicional para enriquecer esta colaboración. Cui y Yasseri (2024) sostienen que los sistemas en los que interactúan personas e inteligencia artificial pueden superar el desempeño de cada una por separado, siempre que se cuide la diversidad de los participantes y la calidad de sus interacciones.

Aplicado al diseño de marcos teóricos, esto sugiere que el trabajo más fecundo no es el de un investigador aislado frente a una herramienta, sino el de un equipo que discute las propuestas teóricas, contrasta las síntesis automáticas con su conocimiento de las fuentes y construye colectivamente un marco que integra perspectivas diversas. Los seminarios de investigación, las comunidades de práctica y las redes académicas cumplen aquí una función que una herramienta individual no puede reemplazar.

En la práctica de la dirección de tesis, estas orientaciones pueden traducirse en acuerdos explícitos entre directores y estudiantes. Puede convenirse, por ejemplo, que el estudiante utilice herramientas de inteligencia artificial para explorar la literatura y obtener síntesis preliminares de las teorías, pero que lea directamente las obras fundamentales de su marco teórico, que elabore una matriz propia de conceptos y autores verificada contra las fuentes originales y que justifique por escrito la elección de su enfoque.

El director, por su parte, puede revisar no solo el texto final del marco teórico, sino también el proceso seguido para construirlo, incluidas las herramientas utilizadas y las verificaciones realizadas. Este tipo de acuerdos protege la integridad del trabajo y refuerza su valor formativo, ya que el estudiante aprende a construir un marco teórico y no solo a producir un texto que lo describa. Además, prepara al estudiante para defender oralmente su marco ante un tribunal, situación en la que la comprensión profunda de los conceptos resulta imposible de simular.

Los marcos teóricos construidos con apoyo de herramientas inteligentes deberían someterse, además, a una prueba sencilla pero reveladora: la capacidad del investigador para explicarlos sin apoyo de la herramienta. Si el autor puede exponer oralmente los conceptos centrales de su marco, las relaciones entre ellos, las razones por las que eligió esas teorías y no otras, y las limitaciones de su enfoque, es probable que haya comprendido y apropiado el marco.

Si, en cambio, depende del texto generado para explicarlo, es probable que la herramienta haya sustituido su trabajo intelectual. Esta prueba, que los tribunales de tesis aplican de manera natural en las defensas orales, podría incorporarse también en los seminarios de investigación y en las revisiones de avance de los proyectos, como una forma de fortalecer la comprensión teórica de los investigadores en formación.

Ahora bien, para la investigación latinoamericana, el diseño de marcos teóricos con apoyo de inteligencia artificial plantea un desafío particular. Los modelos de lenguaje reflejan en buena medida la literatura más difundida internacionalmente, en la que las teorías elaboradas en América Latina, como las aportaciones del pensamiento latinoamericano a la economía del desarrollo, la educación popular o los estudios sobre la colonialidad, pueden estar subrepresentadas.

Figura 2.6

Modelos conceptuales y marcos teóricos



Fuente: Elaboración autores

2.7 Laboratorios de cocreación científica: metodologías colaborativas para transformar ideas en proyectos investigativos

Entre una buena idea y un proyecto de investigación viable existe una distancia considerable. Muchas ideas prometedoras nunca llegan a convertirse en investigaciones porque no se delimitan adecuadamente, porque no encuentran el equipo, los recursos o los datos necesarios, o porque quienes las formularon no reciben la retroalimentación que les permitiría mejorarlas.

Los laboratorios de cocreación científica surgen como espacios diseñados precisamente para recorrer esa distancia. Se trata de entornos, presenciales o virtuales, en los que investigadores de distintas disciplinas, estudiantes, actores sociales y, cada vez más, herramientas de inteligencia artificial trabajan de manera estructurada para transformar ideas iniciales en proyectos de investigación con objetivos, métodos y planes de trabajo definidos.

En esta misma línea, la lógica de la cocreación descansa en la evidencia sobre la inteligencia colectiva. Cui y Yasseri (2024) sostienen que las personas y la inteligencia artificial poseen fortalezas complementarias, de modo que su trabajo conjunto puede superar el desempeño de cada una por separado, y destacan que la diversidad de los participantes, desde sus características visibles hasta sus diferencias profundas de conocimiento y perspectiva, influye decisivamente en la calidad de los resultados colectivos.

Un laboratorio de cocreación aprovecha esta complementariedad al reunir a personas con saberes distintos, entre ellos especialistas, profesionales, miembros de comunidades y estudiantes, y al incorporar herramientas que facilitan la búsqueda de información, la organización de ideas y la elaboración de documentos. La clave está en el diseño del proceso, que debe garantizar que todas las voces sean escuchadas y que las herramientas apoyen la deliberación sin dominarla.

Una metodología de cocreación puede organizarse en varias fases sucesivas. El proceso arranca con la exploración del problema, en la que los participantes comparten sus experiencias y conocimientos sobre una situación que consideran relevante, y en la que las herramientas de inteligencia artificial pueden ayudar a reunir rápidamente información sobre lo que ya se ha investigado al respecto.

Sigue la fase de divergencia, en la que se generan múltiples enfoques posibles para abordar el problema, combinando las propuestas de los participantes con alternativas sugeridas por modelos generativos. Viene luego la convergencia, en la que el grupo evalúa las alternativas según criterios de relevancia, novedad y factibilidad, y selecciona las más prometedoras. Durante el diseño, por su parte, las ideas seleccionadas se transforman en proyectos con preguntas, objetivos, metodologías, cronogramas y presupuestos.

La validación cierra el proceso, presentando los proyectos a evaluadores externos o a los actores interesados para recibir retroalimentación antes de su ejecución. De igual manera, la participación de actores no académicos constituye uno de los rasgos distintivos de estos laboratorios. La Recomendación de la UNESCO sobre la ciencia abierta reconoce la importancia de abrir los procesos científicos a la participación de la sociedad y de dialogar con otros sistemas de conocimiento, incluidos los de los pueblos indígenas y las comunidades locales (UNESCO, 2021a).

Cuando una comunidad participa desde el inicio en la definición del problema, la investigación resultante tiene mayores probabilidades de responder a necesidades reales y de que sus

resultados sean utilizados. En el Ecuador, laboratorios de cocreación que reúnan a universidades, gobiernos autónomos descentralizados, organizaciones campesinas o asociaciones productivas podrían orientar la investigación hacia problemas como la gestión del agua, la adaptación de la agricultura al cambio climático o la mejora de los servicios públicos locales.

Las universidades tienen un papel central en la promoción de estos espacios. Carayannis y Morawska-Jancelewicz (2022) sostienen que las universidades del futuro deberán articular sus funciones de investigación, docencia y vinculación en torno a los desafíos de la Sociedad 5.0, y actuar como nodos de ecosistemas de innovación en los que colaboran gobiernos, empresas y sociedad civil.

Los laboratorios de cocreación pueden materializar esa articulación, puesto que en ellos los estudiantes aprenden a investigar trabajando sobre problemas reales, los docentes encuentran nuevas líneas de investigación y la sociedad participa en la producción del conocimiento que la afecta. Esta perspectiva coincide con la orientación de la Industria 5.0, que propone colocar a las personas y a la sostenibilidad en el centro de la transformación tecnológica (Breque et al., 2021).

El uso de la inteligencia artificial en estos laboratorios requiere, no obstante, reglas claras. Conviene definir desde el inicio qué herramientas se utilizarán, para qué tareas y cómo se documentará su participación; asegurar que los datos compartidos por los participantes, especialmente los de comunidades o personas vulnerables, se traten con confidencialidad; y evitar que la rapidez de las herramientas reemplace el tiempo necesario para la deliberación y la construcción de confianza entre los participantes.

También es importante reconocer la contribución de cada persona al proyecto resultante y acordar desde el principio cómo se distribuirán la autoría, la propiedad intelectual y los beneficios derivados de la investigación. Estas reglas no son trámites burocráticos, sino condiciones para que la cocreación sea genuina y sostenible.

Algunas experiencias universitarias de la región muestran el potencial de estos espacios. Los laboratorios de innovación social, los centros de vinculación con la comunidad y los programas de investigación participativa reúnen ya a docentes, estudiantes y actores sociales en torno a problemas concretos, como la gestión de residuos, la producción agroecológica o la mejora de servicios públicos locales.

La incorporación de herramientas de inteligencia artificial puede fortalecer estos espacios, por ejemplo, al facilitar la sistematización de las experiencias, el análisis de datos recogidos en el territorio o la preparación de propuestas para convocatorias de financiamiento. Para que los laboratorios de cocreación se consoliden, sin embargo, necesitan algo más que herramientas, como financiamiento estable, personal con competencias de facilitación, reconocimiento académico para quienes participan y acuerdos claros con las comunidades sobre el uso de los resultados.

Las universidades que logren institucionalizar estos espacios podrán convertirlos en motores de investigación pertinente y en escuelas de colaboración para sus estudiantes. La evaluación de los laboratorios de cocreación plantea desafíos propios, porque sus resultados no se limitan a los proyectos de investigación generados, también incluyen el fortalecimiento de las relaciones entre la universidad y la sociedad, el desarrollo de capacidades en los participantes y la circulación de conocimientos entre actores diversos.

Para valorar estos resultados, conviene combinar indicadores cuantitativos, como el número de proyectos formulados, financiados y ejecutados, con métodos cualitativos, como entrevistas a los participantes o el seguimiento de los cambios producidos en las comunidades. Esta evaluación permite mejorar las metodologías de cocreación, justificar su financiamiento ante las autoridades y comunicar su valor a la comunidad académica, que a menudo desconoce los aportes de este tipo de iniciativas donde paralelamente, los laboratorios de cocreación científica representan una forma de organizar la investigación coherente con el espíritu de la Investigación 5.0.

Figura 2.7

Laboratorios de cocreación científica



Fuente: Elaboración autores

2.8 Originalidad, autoría intelectual y límites de la creatividad artificial en la producción del conocimiento

La originalidad es uno de los valores fundamentales de la ciencia. Un trabajo científico se considera valioso cuando aporta algo nuevo, ya sea un dato, un método, una explicación o una perspectiva, y cuando ese aporte puede atribuirse a personas identificables que responden por él. La autoría intelectual cumple, en este sentido, una doble función: reconoce el mérito de quienes produjeron el conocimiento y asigna la responsabilidad por su exactitud e integridad.

La aparición de herramientas capaces de generar textos, ideas, imágenes y análisis plantea preguntas inéditas sobre ambos aspectos: ¿qué significa la originalidad cuando parte de un trabajo ha sido generado por una máquina?, ¿quién es el autor de una idea propuesta por un modelo y desarrollada por una persona?, ¿hasta dónde puede llegar la creatividad artificial? Sobre esta base, la respuesta de la comunidad científica a la cuestión de la autoría ha sido relativamente rápida y consistente.

El Committee on Publication Ethics estableció que las herramientas de inteligencia artificial no pueden figurar como autoras de trabajos científicos, porque no pueden asumir la responsabilidad por el trabajo enviado y, al no ser entidades jurídicas, tampoco pueden declarar conflictos de interés ni gestionar derechos de autor o acuerdos de licencia (COPE, 2023).

Según esta posición, los autores que utilicen estas herramientas para redactar textos, producir imágenes o elementos gráficos, o recopilar y analizar datos deben declararlo de forma transparente, indicando qué herramienta utilizaron y cómo, y son plenamente responsables del contenido de su manuscrito, incluidas las partes producidas por la herramienta. Thorp (2023), editor de la revista Science, expresó una posición semejante al afirmar que los textos generados por estos sistemas no pueden ser utilizados en los trabajos publicados en sus revistas sin autorización explícita y que un programa no puede ser autor.

Estas posiciones reflejan una comprensión de la autoría como responsabilidad y no solo como producción de texto. Lund et al. (2023), al analizar las implicaciones éticas de los modelos de lenguaje para la publicación académica, coinciden en que su uso plantea problemas de transparencia, de atribución adecuada y de integridad, y subrayan la necesidad de normas claras sobre su empleo en la investigación y en la redacción científica.

La originalidad, desde esta perspectiva, no se mide por quién escribió cada frase, sino por quién concibió las preguntas, diseñó los métodos, interpretó los resultados y asume la responsabilidad por las conclusiones. Un investigador que utiliza una herramienta para mejorar la redacción de un texto propio no pierde la autoría, siempre que lo declare; uno que presenta como propio un trabajo sustancialmente generado por una máquina, sin declararlo, incurre en una falta de integridad comparable al plagio por lo que desde esta perspectiva, los límites de la creatividad artificial constituyen una cuestión más abierta.

La evidencia experimental muestra que los modelos generativos pueden producir ideas evaluadas como novedosas, en ocasiones más que las de expertos humanos (Si et al., 2025), y superar el desempeño promedio de las personas en tareas de pensamiento divergente (Koivisto y Grassini, 2023). Sin embargo, la misma evidencia revela límites importantes.

Los modelos tienen dificultades para evaluar la factibilidad y el valor de sus propias propuestas, tienden a producir ideas poco diversas cuando se les pide generar muchas y, cuando son utilizados por muchas personas, reducen la variedad colectiva de las producciones (Doshi y Hauser, 2024). La creatividad científica no consiste únicamente en generar ideas novedosas, sino en reconocer cuáles son valiosas, desarrollarlas con rigor y defenderlas frente a la crítica, capacidades que siguen dependiendo de las personas.

Existe, además, un límite de naturaleza más profunda. Los modelos generativos producen sus resultados a partir de patrones aprendidos de grandes volúmenes de textos y datos existentes, lo que plantea la pregunta de si pueden generar conocimiento verdaderamente nuevo o solo recombinaciones de lo ya conocido. Krenn et al. (2022) señalan que todavía no existen ejemplos de sistemas que actúen como verdaderos agentes de comprensión, capaces de generar por sí mismos conocimiento científico nuevo y transmitirlo a las personas.

Aunque esta situación podría cambiar en el futuro, por ahora la originalidad científica sigue requiriendo la intervención humana, tanto para orientar las herramientas como para dar sentido a sus resultados. De forma complementaria, en el plano jurídico, la cuestión de la autoría se vincula con la propiedad intelectual. En el Ecuador, como en la mayoría de los países, el marco legal de los derechos de autor y de la propiedad intelectual se construyó sobre la premisa de que las obras protegidas son creaciones humanas.

La generalización de las herramientas generativas plantea interrogantes que la legislación aún no resuelve de manera explícita, como la titularidad de los resultados producidos con su ayuda o el uso de obras protegidas para entrenar los modelos, y que serán objeto de debate en los próximos años.

La cuestión de la originalidad adquiere también una dimensión práctica en la evaluación de los trabajos académicos. Los programas de detección de similitud, diseñados para identificar textos copiados de otras fuentes, no detectan necesariamente los textos producidos por modelos generativos, que no reproducen literalmente fragmentos existentes, como mostraron C. A. Gao et al. (2023) al comprobar que los resúmenes generados obtenían puntuaciones bajas en estos programas. Los detectores de textos generados por inteligencia artificial, por su parte, ofrecen indicios y no pruebas, y pueden producir falsos positivos.

Por ello, la protección de la originalidad no puede descansar únicamente en herramientas de detección, sino que requiere una cultura de integridad, normas claras sobre los usos permitidos, la exigencia de declarar el uso de herramientas y formas de evaluación que valoren el proceso de investigación, como las defensas orales, los avances periódicos o la presentación de los datos y los borradores. Estas prácticas permiten verificar que el autor domina el contenido de su trabajo y que la originalidad declarada corresponde a su aporte intelectual.

La discusión sobre la originalidad invita, por último, a revisar los incentivos que operan en los sistemas académicos. Cuando la evaluación de los investigadores se basa principalmente en el número de publicaciones, se crea una presión que favorece el uso de herramientas para producir más textos en menos tiempo, a veces a costa de la originalidad y de la integridad. El Acuerdo sobre la Reforma de la Evaluación de la Investigación propone, precisamente, basar la evaluación en el juicio cualitativo de la calidad y del impacto de las contribuciones, y no en indicadores de cantidad (CoARA, 2022).

Una reforma de este tipo reduciría los incentivos para el uso abusivo de las herramientas generativas y permitiría valorar la originalidad genuina, incluso cuando se expresa en un número menor de publicaciones. Vinculado con lo anterior, para las instituciones de educación superior y los investigadores de la región, estas reflexiones se traducen en orientaciones concretas.

Las universidades deberían adoptar políticas claras sobre el uso de la inteligencia artificial en los trabajos académicos, que exijan su declaración transparente y definan los usos aceptables según el tipo de trabajo. Los investigadores, por su parte, deberían documentar el papel de las

herramientas en cada fase de su trabajo, verificar todo contenido generado antes de incorporarlo y asumir plenamente la responsabilidad por sus publicaciones.

Figura 2.8

Originalidad y autoría intelectual



Fuente: Elaboración autores

EDITORIAL ANDES COGNITIO

CAPÍTULO III

METODOLOGÍAS INTELIGENTES 5.0: AUTOMATIZACIÓN, ANALÍTICA AVANZADA Y NUEVAS FORMAS DE INVESTIGAR



CAPÍTULO III

METODOLOGÍAS INTELIGENTES 5.0: AUTOMATIZACIÓN, ANALÍTICA AVANZADA Y NUEVAS FORMAS DE INVESTIGAR

3.1 Transformación de los enfoques cuantitativos, cualitativos y mixtos mediante inteligencia artificial

La metodología de la investigación ha organizado tradicionalmente sus procedimientos en torno a tres grandes enfoques. El cuantitativo busca medir variables, establecer relaciones entre ellas y generalizar resultados a poblaciones mediante procedimientos estadísticos; el cualitativo procura comprender los significados, las experiencias y los contextos desde la perspectiva de los participantes, mediante entrevistas, observaciones y análisis de documentos; y el mixto combina ambos para aprovechar sus fortalezas complementarias.

Cada enfoque desarrolló sus propias técnicas, criterios de calidad y comunidades de práctica, y durante décadas su relación estuvo marcada por debates sobre cuál ofrecía un conocimiento más válido. La inteligencia artificial está transformando los tres enfoques al mismo tiempo, aunque de maneras diferentes, y está modificando también las fronteras entre ellos. En concordancia con ello, en la investigación cuantitativa, la transformación es quizá la más visible.

Los algoritmos de aprendizaje automático permiten analizar conjuntos de datos con miles de variables, detectar relaciones no lineales e interacciones complejas que los modelos estadísticos clásicos no capturan con facilidad, y realizar predicciones con gran precisión. H. Wang et al. (2023) muestran que estas capacidades han permitido avances en disciplinas que trabajan con volúmenes enormes de datos, como la astronomía, la genómica o las ciencias del clima. Sin embargo, la potencia predictiva de estos métodos no siempre se acompaña de capacidad explicativa, y su uso inadecuado puede generar resultados engañosos.

Como se señaló en el capítulo 1, Kapoor y Narayanan (2023) documentaron problemas de filtración de datos en cientos de estudios de distintas disciplinas que utilizaban aprendizaje automático, errores que inflaban artificialmente el desempeño de los modelos y que comprometían la validez de las conclusiones. La transformación del enfoque cuantitativo exige, por tanto, combinar las nuevas técnicas con la disciplina estadística de siempre: muestras adecuadas,

separación entre datos de entrenamiento y de evaluación, control de las variables de confusión e interpretación prudente de los resultados.

En la investigación cualitativa, la inteligencia artificial abre posibilidades que hasta hace poco parecían impensables. Los sistemas de transcripción automática reducen drásticamente el tiempo necesario para convertir entrevistas en texto; los modelos de lenguaje pueden proponer códigos iniciales, identificar temas recurrentes y resumir grandes volúmenes de material; y las herramientas de análisis de sentimiento o de redes semánticas permiten explorar corpus documentales extensos.

Estas capacidades pueden ampliar la escala de los estudios cualitativos y liberar tiempo para la interpretación en profundidad. No obstante, también plantean riesgos específicos para un enfoque que valora la comprensión de los significados en su contexto. Bender et al. (2021) advirtieron que los modelos de lenguaje producen textos a partir de patrones estadísticos sin comprender el significado como lo hacen las personas, y en el análisis cualitativo esta limitación puede traducirse en interpretaciones superficiales, en la pérdida de matices culturales o en la reproducción de sesgos presentes en los datos de entrenamiento.

Por ello, el uso de la inteligencia artificial en la investigación cualitativa requiere salvaguardas particulares. Conviene que el investigador realice una lectura directa de al menos una parte significativa del material, que compare los códigos propuestos por la herramienta con su propia codificación, que discuta las discrepancias con otros miembros del equipo y que mantenga la reflexividad sobre su propio papel en la interpretación.

También es indispensable atender a la confidencialidad: las entrevistas y los documentos cualitativos contienen a menudo información sensible sobre los participantes, cuyo procesamiento en plataformas externas puede vulnerar el consentimiento otorgado y la normativa de protección de datos. En el Ecuador, la Ley Orgánica de Protección de Datos Personales establece principios como la finalidad, la minimización y la confidencialidad que deben respetarse también en estos casos (Asamblea Nacional del Ecuador, 2021).

Los enfoques mixtos pueden beneficiarse especialmente de la integración que facilita la inteligencia artificial. Las mismas herramientas que permiten cuantificar patrones en grandes corpus textuales ayudan a seleccionar casos para un análisis cualitativo en profundidad, y los hallazgos cualitativos pueden orientar la construcción de variables para modelos cuantitativos. Esta

integración puede hacer más fluida la combinación de enfoques, que en la práctica tradicional suele implicar procesos separados y difíciles de articular.

Dwivedi et al. (2023), en su análisis de las oportunidades y desafíos de la inteligencia artificial conversacional para la investigación, señalan precisamente que estas herramientas pueden apoyar distintas etapas del proceso investigativo, aunque advierten sobre la necesidad de mantener el juicio crítico y la responsabilidad del investigador. A ello se suma que la transformación de los enfoques metodológicos no implica, sin embargo, la desaparición de sus diferencias. Cada enfoque responde a preguntas distintas y descansa en supuestos epistemológicos diferentes sobre la naturaleza del conocimiento y de la realidad social.

La inteligencia artificial puede facilitar el trabajo dentro de cada enfoque y la integración entre ellos, pero no resuelve por sí misma las preguntas sobre qué tipo de conocimiento se busca y con qué criterios se valida. Antes bien, la incorporación de estas herramientas obliga a los investigadores a reflexionar con mayor claridad sobre sus opciones metodológicas, a justificar por qué utilizan determinada técnica y a explicitar cómo garantizan la calidad de sus resultados.

La documentación del uso de estas herramientas en cada enfoque merece una mención específica. En los estudios cuantitativos, conviene registrar las versiones de los programas y de los modelos, los parámetros utilizados y los procedimientos de validación; en los cualitativos, describir cómo se emplearon las herramientas de transcripción y codificación, qué proporción del material se revisó manualmente y cómo se resolvieron las discrepancias entre la codificación humana y la automatizada; y en los mixtos, explicar cómo se integraron los resultados de ambos componentes.

Esta documentación permite a los lectores y evaluadores valorar la calidad del trabajo y contribuye a construir, en la comunidad académica, un conocimiento compartido sobre las ventajas y los límites de cada herramienta en cada enfoque.

Un ejemplo de investigación mixta muestra cómo estas herramientas pueden articularse. Un estudio sobre la inserción laboral de los graduados de una universidad podría comenzar con el análisis cuantitativo de los registros de seguimiento a graduados mediante modelos que identifiquen los factores asociados al empleo en el área de formación, continuar con entrevistas a graduados seleccionados según los patrones encontrados y concluir con el análisis de esas entrevistas, apoyado en herramientas de transcripción y de codificación asistida.

En cada fase, la inteligencia artificial ahorraría tiempo y ampliaría la escala del análisis, pero las decisiones clave seguirían a cargo del equipo, como qué variables considerar, cómo seleccionar a los entrevistados, cómo interpretar los relatos y cómo integrar ambos tipos de resultados. La validez del estudio dependería, en última instancia, de la coherencia entre sus fases y de la transparencia con que se documenten los procedimientos.

Este tipo de diseños puede resultar especialmente útil para las universidades ecuatorianas, que necesitan información de calidad sobre sus graduados para los procesos de evaluación y mejora de sus carreras. La formación de los equipos de investigación en estos nuevos enfoques requiere también la colaboración entre especialistas. Los estadísticos y los científicos de datos pueden aportar su conocimiento sobre los métodos cuantitativos y el aprendizaje automático, los investigadores cualitativos su experiencia en la interpretación de significados y en la reflexividad, y los especialistas en cada disciplina su conocimiento del fenómeno estudiado.

Las universidades pueden favorecer esta colaboración mediante centros de apoyo metodológico que reúnan a especialistas de distintos enfoques y que ofrezcan asesoría a los investigadores de todas las facultades. Estos centros pueden, además, evaluar las herramientas disponibles, elaborar guías de uso y ofrecer formación continua, contribuyendo a que la adopción de la inteligencia artificial en la investigación se produzca con criterios comunes y con el respaldo de especialistas. Asimismo, para la formación metodológica en las universidades de la región, esta transformación sugiere algunas orientaciones.

Los cursos de metodología podrían incorporar el uso crítico de herramientas de inteligencia artificial en cada enfoque, mostrando tanto sus ventajas como sus riesgos; enseñar a documentar su uso de manera transparente; y fortalecer la comprensión de los fundamentos de cada enfoque, que se vuelven más importantes, no menos, cuando parte del trabajo técnico se automatiza. Miao y Holmes (2023) insisten en que la adopción de la inteligencia artificial generativa en la educación y la investigación debe acompañarse de formación y de criterios que garanticen un uso centrado en las personas.

Un investigador que comprende bien los fundamentos de su enfoque está en mejores condiciones de aprovechar las herramientas sin perder el rigor que define a la buena investigación. Debe recordarse, además, que las herramientas no resuelven por sí solas los dilemas propios de cada enfoque, como la tensión entre generalización y profundidad, o entre objetividad y comprensión de los significados.

Figura 3.1

Transformación de los enfoques cuantitativos, cualitativos y mixtos mediante inteligencia artificial.



Fuente: Elaboración autores

3.2 Diseño metodológico asistido por sistemas inteligentes: selección de métodos, variables e instrumentos de investigación

El diseño metodológico es el puente entre la pregunta de investigación y la evidencia que permitirá responderla. En él se decide qué tipo de estudio se realizará, qué población o casos se analizarán, qué variables o categorías se considerarán, con qué instrumentos se recogerá la información y mediante qué procedimientos se analizará.

Un diseño bien construido aumenta la probabilidad de obtener resultados válidos y confiables, mientras que un diseño deficiente puede invalidar una investigación, aunque sus demás componentes sean impecables. Por ello, el diseño metodológico es una de las fases en las que más se aprecia la experiencia del investigador y una de las que más dificultades plantea a quienes se inician en la investigación. Además, los sistemas inteligentes pueden asistir el diseño metodológico de varias maneras.

En la selección del tipo de estudio, los modelos de lenguaje pueden ayudar a contrastar las ventajas y limitaciones de distintos diseños para una pregunta determinada, por ejemplo, si conviene un estudio transversal, longitudinal, experimental o cuasiexperimental, o si resulta más apropiado un estudio de caso, una investigación etnográfica o una teoría fundamentada. En la definición de variables, pueden sugerir dimensiones e indicadores a partir de la literatura y ayudar a construir la matriz de operacionalización.

En la elaboración de instrumentos, pueden proponer borradores de cuestionarios, guías de entrevista o protocolos de observación que el investigador adapta después. Y en la planificación del análisis, pueden recomendar técnicas estadísticas o cualitativas apropiadas para los datos y las preguntas planteadas. Giray (2023) destaca, en este sentido, que el dominio de las técnicas de formulación de instrucciones permite a los investigadores aprovechar mejor estas herramientas en sus tareas académicas.

Estas posibilidades tienen un valor evidente, especialmente para investigadores noveles o para equipos que no cuentan con asesoría metodológica especializada. Sin embargo, el diseño metodológico es un terreno en el que los errores de las herramientas pueden tener consecuencias graves. Un modelo de lenguaje puede recomendar una prueba estadística inadecuada para el tipo de datos, sugerir un tamaño de muestra sin justificación o proponer preguntas de cuestionario sesgadas, y presentar esas recomendaciones con total seguridad.

Además, las sugerencias de las herramientas tienden a reflejar las prácticas más frecuentes en la literatura, que no siempre son las más apropiadas para el problema específico ni para el contexto en que se realiza la investigación. En esta misma línea, un aspecto particularmente importante del diseño asistido es la prevención de errores metodológicos característicos del uso de aprendizaje automático.

Kapoor y Narayanan (2023) mostraron que la filtración de información entre los datos utilizados para entrenar un modelo y los empleados para evaluarlo es una causa frecuente de resultados irreproducibles, y propusieron fichas de información de los modelos que obligan a los investigadores a documentar, antes de presentar sus resultados, cómo separaron los datos, qué variables utilizaron y cómo evitaron los distintos tipos de filtración. Incorporar este tipo de verificaciones al diseño metodológico, desde el inicio, es una forma eficaz de prevenir errores que después resultan difíciles de detectar. En términos más generales, el diseño de investigaciones que utilizan inteligencia artificial debería especificar con anticipación qué datos se usarán para cada fin, qué métricas se emplearán para evaluar los modelos y qué comparaciones con métodos más sencillos se realizarán.

Un cuestionario propuesto por un modelo de lenguaje debe someterse, como cualquier otro, a la revisión de expertos, a pruebas piloto con participantes similares a los de la población estudiada y a análisis de confiabilidad y validez. Las herramientas pueden facilitar algunas de estas

tareas, por ejemplo, al analizar las respuestas de la prueba piloto o al identificar preguntas ambiguas, pero no reemplazan el juicio de los expertos ni la experiencia de los participantes.

Del mismo modo, las guías de entrevista sugeridas por un sistema deben adaptarse al lenguaje y a la cultura de las personas entrevistadas, tarea que requiere conocimiento del contexto. De igual manera, la documentación del diseño metodológico adquiere una importancia renovada cuando intervienen herramientas inteligentes.

Para que una investigación sea evaluable y reproducible, el informe debería indicar qué herramientas se utilizaron en el diseño, para qué tareas, con qué instrucciones o configuraciones y cómo se verificaron sus sugerencias. Esta documentación no solo responde a exigencias de transparencia, como las que establecen las organizaciones de ética editorial (COPE, 2023), sino que permite a otros investigadores comprender las decisiones tomadas y evaluar su pertinencia. Las guías de presentación de informes, como la declaración PRISMA para las revisiones sistemáticas, ofrecen un modelo de cómo la explicitación detallada de los procedimientos contribuye a la calidad y la confiabilidad de la investigación (Page et al., 2021).

Los comités de investigación de las universidades pueden desempeñar un papel importante en la promoción de un diseño metodológico asistido de calidad. Al revisar los proyectos, estos comités podrían pedir que los investigadores expliciten qué herramientas de inteligencia artificial utilizarán y para qué fines, cómo validarán los instrumentos y los modelos, cómo separarán los datos de entrenamiento y de evaluación cuando corresponda, y cómo protegerán la confidencialidad de los participantes.

Estas exigencias no deberían convertirse en obstáculos burocráticos, sino en oportunidades de mejora, porque un proyecto que ha respondido a estas preguntas antes de comenzar tiene mayores probabilidades de producir resultados válidos y publicables. Del mismo modo, los programas de formación de investigadores podrían incluir talleres prácticos en los que los participantes diseñen proyectos con apoyo de herramientas inteligentes y reciban retroalimentación de especialistas en metodología, de modo que aprendan a combinar la ayuda de la tecnología con el juicio experto. Existe, además, una dimensión ética del diseño metodológico que las herramientas no pueden resolver por sí mismas.

La decisión sobre qué población estudiar, cómo obtener el consentimiento de los participantes, qué riesgos pueden derivarse de la investigación y cómo se protegerá la información involucra

juicios de valor que corresponden a los investigadores y a los comités de ética. Cuando un sistema inteligente sugiere un diseño, puede no considerar aspectos como la vulnerabilidad de ciertos grupos, las relaciones de poder entre investigadores y participantes o las particularidades culturales de las comunidades.

Por ello, la revisión ética de los proyectos debe mantenerse como una instancia independiente, en la que se examinen no solo los procedimientos de recolección de datos, sino también el papel de las herramientas inteligentes en el diseño y en el análisis. Por otra parte, en las universidades ecuatorianas y latinoamericanas, donde la asesoría metodológica especializada es a menudo escasa, los sistemas inteligentes pueden contribuir a mejorar la calidad de los diseños de investigación de estudiantes y docentes.

Para que esta contribución sea positiva, es necesario que los usuarios cuenten con una formación metodológica suficiente para evaluar las sugerencias de las herramientas, que las instituciones promuevan su uso transparente y que los comités de investigación revisen los diseños con criterios explícitos.

Figura 3.2

Diseño metodológico asistido por sistemas inteligentes: selección de métodos, variables e instrumentos de investigación.



Fuente: Elaboración autores

3.3 Revisión sistemática inteligente de literatura científica mediante procesamiento del lenguaje natural

La revisión sistemática de literatura es un método riguroso para identificar, evaluar y sintetizar toda la evidencia disponible sobre una pregunta específica. A diferencia de las revisiones

narrativas, en las que el autor selecciona los trabajos que considera relevantes según su criterio, la revisión sistemática sigue un protocolo explícito y reproducible: define la pregunta, establece criterios de inclusión y exclusión, busca de manera exhaustiva en varias bases de datos, selecciona los estudios mediante procedimientos documentados, evalúa su calidad y sintetiza sus resultados.

Este rigor la convierte en una herramienta fundamental para la toma de decisiones basada en evidencia, pero también la hace extremadamente laboriosa. Una revisión puede requerir la lectura de miles de títulos y resúmenes, y su realización completa puede tomar meses o incluso años. Paralelamente, la declaración PRISMA, actualizada en su versión de 2020, establece los estándares internacionales para informar las revisiones sistemáticas. Page et al. (2021) presentaron esta actualización, que incluye una lista de verificación de veintisiete elementos y diagramas de flujo revisados para documentar el proceso de búsqueda y selección de estudios, y que incorpora orientaciones sobre los avances metodológicos ocurridos desde la versión anterior, entre ellos el uso de herramientas automatizadas.

El propósito de PRISMA es que los lectores puedan comprender qué hicieron los autores, por qué lo hicieron y qué encontraron, de modo que puedan evaluar la confiabilidad de la revisión y, eventualmente, reproducirla. Cualquier uso de inteligencia artificial en una revisión sistemática debe, por tanto, documentarse con el mismo nivel de detalle que los demás procedimientos.

El procesamiento del lenguaje natural ofrece herramientas para agilizar varias fases de la revisión. En la fase de selección de estudios, que suele ser la más laboriosa, los sistemas de aprendizaje activo han demostrado ser especialmente útiles. Van de Schoot et al. (2021) desarrollaron un marco de código abierto que aprende de las decisiones del revisor sobre los primeros documentos evaluados y prioriza después aquellos con mayor probabilidad de ser relevantes, de modo que los estudios pertinentes aparecen al principio de la cola de revisión.

Los autores mostraron que esta estrategia permite identificar la gran mayoría de los estudios relevantes revisando solo una fracción del total de documentos, con un ahorro considerable de tiempo, y subrayaron la importancia de que estas herramientas sean transparentes y de código abierto para que su funcionamiento pueda ser examinado.

En otras fases, los modelos de lenguaje pueden ayudar a construir las cadenas de búsqueda, a extraer datos de los estudios incluidos o a elaborar borradores de síntesis. No obstante, estas

posibilidades deben equilibrarse con los riesgos conocidos. Los modelos de lenguaje generativos pueden producir síntesis que omiten estudios relevantes, interpretan erróneamente los resultados o atribuyen hallazgos a fuentes equivocadas.

Walters y Wilder (2023) encontraron que una proporción importante de las referencias bibliográficas generadas por estos sistemas eran inventadas, y que muchas de las referencias reales contenían errores sustanciales, lo que muestra que no pueden utilizarse como fuente de citas sin verificación. En una revisión sistemática, donde la exhaustividad y la exactitud son los valores centrales, estos errores resultan inaceptables. Por ello, la inteligencia artificial puede apoyar la revisión, pero cada estudio incluido debe verificarse en su fuente original y cada dato extraído debe contrastarse con el texto completo.

Un procedimiento razonable para una revisión sistemática inteligente podría combinar las herramientas automatizadas con controles humanos en cada fase. En la búsqueda, el investigador puede utilizar modelos de lenguaje para sugerir términos y sinónimos, pero debe construir y probar las cadenas de búsqueda en las bases de datos especializadas y documentarlas completamente. En la selección, puede emplear herramientas de aprendizaje activo para priorizar la revisión, manteniendo la evaluación por al menos dos revisores independientes y estableciendo un criterio explícito para detener la revisión manual.

En la extracción de datos, puede utilizar sistemas automatizados para obtener una primera versión, que después se verifica sistemáticamente. Y en la síntesis, puede apoyarse en herramientas para organizar los resultados, pero la interpretación y la evaluación de la certeza de la evidencia deben quedar a cargo de los investigadores. Sobre esta base, la cobertura lingüística y geográfica de las búsquedas merece una atención especial en el contexto latinoamericano.

Las principales bases de datos internacionales y los modelos de lenguaje entrenados predominantemente con textos en inglés tienden a subrepresentar la producción científica publicada en español y en portugués, así como la difundida en revistas y repositorios regionales. Una revisión sistemática sobre un tema relevante para la región que se limite a estas fuentes puede omitir una parte significativa de la evidencia disponible.

Por ello, conviene incluir deliberadamente sistemas y bases de datos regionales, como SciELO, Redalyc o Latindex, buscar en varios idiomas y verificar si las herramientas automatizadas tratan adecuadamente los textos en español, ajustando los procedimientos cuando sea necesario.

La aplicación de estas herramientas a temas de interés regional permite apreciar su utilidad. Una revisión sistemática sobre las intervenciones para reducir la deserción escolar en América Latina, por ejemplo, podría implicar la revisión de miles de documentos publicados en distintas bases de datos, en varios idiomas y en formatos diversos, incluidos informes de organismos públicos y tesis de posgrado.

Las herramientas de aprendizaje activo permitirían priorizar la revisión de los documentos más pertinentes, los modelos de lenguaje ayudarían a extraer los datos de los estudios incluidos y los sistemas de traducción facilitarían el trabajo con textos en portugués o en inglés. Sin embargo, el equipo debería verificar cada decisión crítica, documentar el uso de las herramientas siguiendo las recomendaciones de la declaración PRISMA y discutir las limitaciones de la búsqueda.

El resultado sería una síntesis de la evidencia útil para los responsables de las políticas educativas, producida con recursos que una universidad de la región puede movilizar, y con un nivel de rigor comparable al de las revisiones realizadas en centros con mayores recursos. Las revisiones rápidas y las revisiones vivas constituyen dos modalidades que pueden beneficiarse especialmente de estas herramientas.

Las revisiones rápidas buscan sintetizar la evidencia en plazos cortos para apoyar decisiones urgentes, como ocurrió durante la pandemia de COVID-19, y aceptan ciertas simplificaciones metodológicas que deben declararse. Las revisiones vivas se actualizan de manera continua a medida que aparecen nuevos estudios, lo que exige un seguimiento permanente de la literatura. En ambos casos, la automatización de la búsqueda, la selección y la extracción de datos puede reducir considerablemente el esfuerzo necesario. Sin embargo, la rapidez no debe sacrificar la transparencia, ya que estas revisiones deben documentar con claridad sus procedimientos, sus simplificaciones y el papel de las herramientas utilizadas, para que los usuarios puedan valorar adecuadamente la confiabilidad de sus conclusiones.

Desde esta perspectiva, las revisiones sistemáticas inteligentes ofrecen a los investigadores de la región la posibilidad de producir síntesis rigurosas de la evidencia con recursos más modestos de lo que antes se requería. Esto resulta especialmente valioso en campos como la salud pública, la educación o las políticas sociales, donde las decisiones deberían basarse en la mejor evidencia disponible. No obstante, el ahorro de tiempo que proporcionan las herramientas no debe traducirse en una reducción del rigor.

La revisión sistemática conserva su valor precisamente por la transparencia y la reproducibilidad de sus procedimientos, y la incorporación de la inteligencia artificial debe fortalecer esas cualidades, no debilitarlas. Documentar cuidadosamente el uso de las herramientas, verificar sus resultados y declarar sus limitaciones son condiciones indispensables para que una revisión asistida por inteligencia artificial merezca la confianza de la comunidad científica.

Figura 3.3

Revisión sistemática inteligente de literatura científica mediante procesamiento del lenguaje natural.



Fuente: Elaboración autores

3.4 Bibliometría 5.0: análisis de redes científicas, identificación de tendencias y cartografía del conocimiento

La bibliometría estudia cuantitativamente la producción científica a partir de los registros de las publicaciones: quién publica, sobre qué temas, en qué revistas, con quiénes colabora y cuánto es citado. Durante décadas, sus herramientas se utilizaron principalmente para evaluar la productividad y el impacto de investigadores, instituciones y países. Con la digitalización de las bases de datos bibliográficas y el desarrollo de programas de análisis de redes, la bibliometría amplió su alcance y se convirtió también en un instrumento para comprender la estructura y la evolución del conocimiento científico.

La expresión bibliometría 5.0 alude a una nueva etapa en la que la inteligencia artificial, el procesamiento del lenguaje natural y la visualización interactiva permiten analizar la producción científica con mayor profundidad, a mayor escala y con una orientación más clara hacia la

comprensión de los temas y sus transformaciones. De forma complementaria, Donthu et al. (2021), en una guía muy citada sobre cómo realizar análisis bibliométricos, distinguen dos grandes familias de técnicas.

El análisis de desempeño examina las contribuciones de los distintos actores de un campo, como autores, instituciones, países o revistas, mediante indicadores de producción y de citación. El mapeo científico, por su parte, analiza las relaciones entre esos actores y entre los temas, mediante técnicas como el análisis de citas, de cocitación, de acoplamiento bibliográfico, de coocurrencia de palabras y de coautoría.

Los autores proponen, además, un procedimiento en varias etapas que comienza con la definición de los objetivos y el alcance del estudio continúa con la selección de las técnicas y la recolección de los datos, y termina con el análisis y la presentación de los resultados. Esta guía ofrece una base metodológica sólida sobre la que se pueden incorporar las nuevas herramientas inteligentes.

La inteligencia artificial amplía especialmente las posibilidades del mapeo científico. Los modelos de lenguaje permiten analizar no solo las palabras clave o los títulos, sino el contenido completo de los resúmenes y de los textos, e identificar temas a partir del significado y no solo de la coincidencia de términos. Las técnicas de agrupamiento semántico pueden revelar líneas de investigación emergentes antes de que se consoliden en términos específicos, y los análisis temporales pueden mostrar cómo surgen, crecen, convergen o declinan los temas de un campo.

Combinados con el análisis de redes de coautoría y de colaboración institucional, estos métodos permiten elaborar una verdadera cartografía del conocimiento, en la que se visualizan los territorios temáticos, sus fronteras, sus conexiones y los actores que los habitan. Vinculado con lo anterior, estos análisis tienen aplicaciones directas para la planificación de la investigación. Un grupo que desea iniciar una nueva línea de trabajo puede identificar las tendencias emergentes, los temas saturados y los vacíos, así como los grupos internacionales con los que podría colaborar.

Una universidad puede analizar su propia producción para conocer sus fortalezas, sus redes de colaboración y su posición en relación con otras instituciones. Un organismo de financiamiento puede orientar sus convocatorias hacia áreas prioritarias en las que el país muestra potencial. En América Latina, el informe de la Red Iberoamericana de Indicadores de Ciencia y

Tecnología muestra que la producción científica indexada creció en casi todos los países entre 2014 y 2023, con incrementos relativos especialmente notables en el Ecuador y el Perú (RICYT, 2025), lo que ofrece un amplio material para análisis bibliométricos que permitan comprender la dinámica y las orientaciones de ese crecimiento.

Sin embargo, la bibliometría tiene limitaciones conocidas que la inteligencia artificial no elimina y que, en algunos casos, puede amplificar. Las bases de datos internacionales más utilizadas tienen una cobertura desigual de las publicaciones en idiomas distintos del inglés y de las revistas de países con menor producción científica, por lo que los análisis basados exclusivamente en ellas ofrecen una imagen parcial de la ciencia latinoamericana.

Además, los indicadores de citación reflejan prácticas que varían mucho entre disciplinas, y su uso para comparar investigadores o instituciones de campos distintos puede conducir a conclusiones injustas. Los modelos de lenguaje, por su parte, pueden agrupar los temas según patrones que reflejan los sesgos de sus datos de entrenamiento, lo que exige validar los resultados con expertos del área. En concordancia con ello, la reflexión sobre el uso responsable de los indicadores ha cobrado fuerza en los últimos años.

El Acuerdo sobre la Reforma de la Evaluación de la Investigación, impulsado por la Coalition for Advancing Research Assessment [CoARA] (2022) y publicado en julio de 2022, establece diez compromisos, entre los cuales cuatro se consideran fundamentales: reconocer la diversidad de contribuciones y de carreras en la investigación, basar la evaluación principalmente en el juicio cualitativo con apoyo de un uso responsable de los indicadores cuantitativos, abandonar los usos inapropiados de métricas como el factor de impacto de las revistas y evitar el uso de clasificaciones de instituciones en la evaluación de la investigación. Esta orientación es pertinente para la bibliometría 5.0, porque recuerda que la potencia de las herramientas analíticas no debe traducirse en una evaluación mecánica de la ciencia, sino en una mejor comprensión de su dinámica.

Un análisis bibliométrico de la producción científica ecuatoriana sobre un tema específico, como la gestión de riesgos volcánicos, podría ilustrar el potencial de estas herramientas. Combinando los registros de las bases de datos internacionales con los de las revistas y repositorios nacionales, el análisis permitiría identificar a los grupos de investigación más activos, sus redes de colaboración nacionales e internacionales, los temas que han recibido mayor atención y los que permanecen poco estudiados.

Las técnicas de agrupamiento semántico podrían revelar, por ejemplo, que la investigación se concentra en la caracterización de los procesos volcánicos y presta menos atención a los aspectos sociales de la gestión del riesgo, como la percepción de las comunidades o la eficacia de los sistemas de alerta. Este tipo de hallazgos podría orientar las prioridades de investigación y las convocatorias de financiamiento.

Para que estas conclusiones sean confiables, el análisis debería validarse con los especialistas del área, documentar sus fuentes y sus procedimientos, y reconocer las limitaciones de cobertura de las bases de datos utilizadas. La formación en bibliometría constituye, por otra parte, una necesidad creciente para los investigadores y para el personal de gestión de la investigación. Comprender cómo se construyen los indicadores, qué miden y qué no miden, cuáles son sus limitaciones y cómo se interpretan adecuadamente permite utilizarlos con criterio y evitar conclusiones erróneas.

Las bibliotecas universitarias y las oficinas de investigación pueden ofrecer esta formación, así como servicios de análisis bibliométrico para los grupos y las unidades académicas. La incorporación de herramientas inteligentes a estos servicios puede ampliar sus capacidades, pero también exige que el personal comprenda los métodos que utilizan las herramientas, para poder explicar sus resultados y advertir sobre sus limitaciones a quienes los utilizan en la toma de decisiones. Para las universidades ecuatorianas, en particular, la bibliometría 5.0 puede convertirse en una herramienta valiosa de autoconocimiento y planificación, siempre que se utilice con criterios adecuados.

Los análisis deberían combinar las bases de datos internacionales con las regionales y con los repositorios institucionales, para capturar el conjunto de la producción científica; interpretar los indicadores en el contexto de cada disciplina; y complementar los resultados cuantitativos con el juicio de los investigadores. Utilizada de este modo, la cartografía del conocimiento permite identificar oportunidades de colaboración, fortalecer las líneas de investigación con mayor potencial y orientar los esfuerzos hacia los problemas que más importan a la sociedad, en lugar de limitarse a perseguir indicadores de citación.

Figura 3.4

Bibliometría 5.0: análisis de redes científicas, identificación de tendencias y cartografía del conocimiento.



Fuente: Elaboración autores

3.5 Aprendizaje automático y modelos predictivos aplicados al descubrimiento de patrones científicos

El aprendizaje automático es una rama de la inteligencia artificial que desarrolla algoritmos capaces de aprender patrones a partir de los datos y de utilizarlos para hacer predicciones o tomar decisiones sin ser programados explícitamente para cada caso. En el aprendizaje supervisado, el algoritmo aprende a partir de ejemplos en los que se conoce la respuesta correcta, como imágenes de tejidos clasificados por especialistas o registros de pacientes con su diagnóstico; en el no supervisado, busca estructuras ocultas en datos sin etiquetas, como grupos de casos similares o dimensiones subyacentes; y en el aprendizaje por refuerzo, aprende mediante la interacción con un entorno, recibiendo recompensas o penalizaciones según sus acciones.

Estas familias de técnicas se han convertido en herramientas de uso cotidiano en numerosas disciplinas científicas, donde contribuyen a descubrir patrones que serían imposibles de detectar mediante el análisis manual. A modo de ilustración, el ejemplo más emblemático de este potencial es la predicción de la estructura de las proteínas. Jumper et al. (2021) presentaron un sistema basado en aprendizaje profundo que predice la estructura tridimensional de las proteínas a partir de su secuencia de aminoácidos con una precisión comparable a la de los métodos experimentales en una gran proporción de los casos.

Este avance resolvió en buena medida un problema que había ocupado a la biología durante medio siglo y abrió nuevas posibilidades para la investigación en biología molecular, el diseño de fármacos y la comprensión de las enfermedades. H. Wang et al. (2023) documentan muchos otros ejemplos en los que el aprendizaje automático ha permitido descubrir patrones en datos de física de partículas, astronomía, química de materiales o ciencias del clima, y destacan el papel de los métodos que incorporan la estructura propia de los datos científicos, como las simetrías o las relaciones geométricas, para mejorar la precisión y la eficiencia de los modelos.

El uso del aprendizaje automático para el descubrimiento científico plantea, sin embargo, exigencias metodológicas específicas. La primera se refiere a la diferencia entre predecir y explicar. Un modelo puede predecir con gran exactitud un fenómeno sin que los investigadores comprendan por qué, lo que limita su contribución al conocimiento científico.

Las técnicas de aprendizaje automático interpretable permiten abordar parcialmente este problema, al identificar qué variables influyen en las predicciones, cómo cambian los resultados al modificar los datos de entrada o qué casos son más representativos del comportamiento del modelo (Molnar, 2022). Estas técnicas no convierten un modelo predictivo en una explicación causal, pero ayudan a los investigadores a formular hipótesis sobre los mecanismos subyacentes, que después pueden contrastarse mediante otros métodos.

Asimismo, la segunda exigencia se refiere a la validez de las predicciones. Kapoor y Narayanan (2023) documentaron que la filtración de datos, es decir, el uso inadvertido de información del conjunto de evaluación durante el entrenamiento, afectaba a cientos de estudios en diecisiete campos científicos y producía estimaciones exageradas del desempeño de los modelos.

Los autores identificaron ocho tipos de filtración, desde errores básicos, como la falta de separación entre los datos de entrenamiento y de prueba, hasta problemas más sutiles, como el uso de variables que no estarían disponibles en el momento de la predicción o la dependencia entre observaciones. Estos hallazgos muestran que el descubrimiento de patrones mediante aprendizaje automático requiere tanto rigor metodológico como el de cualquier otro método científico, y que la sofisticación de los algoritmos no compensa los errores en el diseño del estudio.

Una tercera exigencia se relaciona con la calidad y la representatividad de los datos. Los patrones que descubre un algoritmo reflejan los datos con los que fue entrenado, y si esos datos son incompletos, sesgados o poco representativos de la población de interés, los patrones también

lo serán. Mehrabi et al. (2021), en una revisión exhaustiva sobre el sesgo y la equidad en el aprendizaje automático, identificaron numerosas fuentes de sesgo, desde la subrepresentación de ciertos grupos en los datos hasta los errores de medición que afectan de manera desigual a distintas poblaciones.

En la investigación científica, estos sesgos pueden conducir a conclusiones que no se generalizan, por ejemplo, cuando un modelo de diagnóstico entrenado con pacientes de un país se aplica a poblaciones con características genéticas, ambientales o sociales diferentes. Además, para la investigación en América Latina, el aprendizaje automático ofrece oportunidades considerables en campos donde la región dispone de datos abundantes y de problemas relevantes: el monitoreo de la biodiversidad y de los ecosistemas, la predicción de fenómenos climáticos y de desastres, el análisis de datos de salud pública, la agricultura de precisión o el estudio de la desigualdad mediante registros administrativos.

Para aprovechar estas oportunidades, los grupos de investigación necesitan formación en estas técnicas, acceso a capacidades de cómputo y, sobre todo, datos de calidad, documentados y accesibles. También necesitan adoptar prácticas metodológicas rigurosas, como la separación estricta de los datos, la comparación con modelos más sencillos, la evaluación del desempeño en distintos subgrupos de la población y la documentación completa de los procedimientos.

Algunas recomendaciones prácticas pueden orientar a los equipos que se inician en el uso del aprendizaje automático para el descubrimiento de patrones. Conviene comenzar siempre por un análisis exploratorio de los datos, que permita conocer su estructura, detectar errores y valores atípicos, y comprender las relaciones básicas entre las variables.

Es recomendable también comparar los modelos complejos con modelos sencillos, como las regresiones, porque un modelo sofisticado que no supera a uno sencillo no aporta valor y puede ocultar problemas. La separación de los datos en conjuntos de entrenamiento, validación y prueba debe definirse antes de cualquier análisis, considerando la estructura temporal o jerárquica de los datos cuando exista.

El desempeño de los modelos debe evaluarse en distintos subgrupos de la población, para detectar posibles sesgos, y los resultados deben interpretarse con ayuda de técnicas de explicabilidad y del conocimiento del dominio. Por último, el código, los datos, cuando sea posible, y la descripción completa de los procedimientos deben ponerse a disposición de otros investigadores para que puedan verificar los resultados.

El acceso a las capacidades de cómputo constituye una limitación práctica para muchos grupos de investigación de la región. Entrenar modelos complejos con grandes volúmenes de datos puede requerir equipos especializados que pocas universidades poseen. Sin embargo, no todos los problemas científicos requieren modelos de gran escala; muchos pueden abordarse con técnicas más sencillas, que se ejecutan en computadoras convencionales y que ofrecen resultados comparables cuando los datos son tabulares y de tamaño moderado.

Elegir el modelo adecuado al problema, y no el más sofisticado, es una decisión metodológica y también económica. Para los problemas que sí requieren grandes capacidades, la cooperación entre instituciones y el uso de infraestructuras compartidas o de servicios académicos en la nube pueden ofrecer alternativas viables, siempre que se garantice la protección de los datos sensibles. En esta misma línea, el aprendizaje automático no sustituye al razonamiento científico, sino que lo amplía.

Los patrones que descubre son el punto de partida de la investigación, no su punto de llegada: deben interpretarse a la luz del conocimiento existente, contrastarse con otros datos y métodos, y someterse a la discusión de la comunidad científica. Cuando se utiliza con rigor, esta tecnología permite explorar fenómenos complejos con una profundidad sin precedentes; cuando se utiliza sin cuidado, puede producir hallazgos espectaculares que no resisten el escrutinio.

Figura 3.5

Aprendizaje automático y modelos predictivos aplicados al descubrimiento de patrones científicos.



Fuente: Elaboración autores

3.6 Inteligencia artificial generativa para la simulación de escenarios, construcción de modelos y experimentación virtual

La simulación ha sido una de las grandes herramientas de la ciencia moderna. Cuando un fenómeno es demasiado complejo para ser descrito mediante ecuaciones resolubles, demasiado lento, rápido, grande o pequeño para ser observado directamente, o demasiado costoso o peligroso para ser manipulado experimentalmente, los investigadores construyen modelos computacionales que reproducen su comportamiento y les permiten explorar qué ocurriría bajo distintas condiciones.

Las simulaciones del clima, de la propagación de epidemias, del comportamiento de los mercados o de la evolución de las galaxias son ejemplos conocidos de esta práctica. La inteligencia artificial generativa añade una dimensión nueva a la simulación, porque permite no solo reproducir el comportamiento de sistemas conocidos, sino generar nuevos objetos, escenarios y datos que amplían el espacio de la experimentación. H. Wang et al. (2023) describen cómo los modelos generativos pueden diseñar objetos con propiedades deseadas, como moléculas pequeñas candidatas a fármacos o proteínas con determinadas funciones, a partir del aprendizaje de los patrones presentes en grandes conjuntos de datos.

En lugar de evaluar uno a uno millones de candidatos posibles, los investigadores pueden utilizar estos modelos para generar directamente aquellos que tienen mayor probabilidad de cumplir los requisitos, y concentrar los recursos experimentales en su verificación. Esta forma de experimentación virtual reduce el costo y el tiempo de la búsqueda, y permite explorar regiones del espacio de posibilidades que nunca habrían sido consideradas mediante el razonamiento humano o la búsqueda sistemática tradicional.

Krenn et al. (2022) se refieren a esta función de la inteligencia artificial mediante la metáfora del microscopio computacional, que proporciona información sobre sistemas que no pueden estudiarse experimentalmente mediante la generación de datos o representaciones que los investigadores analizan después.

En el ámbito biomédico, S. Gao et al. (2024) mencionan entre las aplicaciones prometedoras de los agentes de inteligencia artificial la simulación de células virtuales, el control programable de fenotipos y el diseño de circuitos celulares, es decir, la posibilidad de experimentar computacionalmente con sistemas biológicos antes de intervenir en el laboratorio. Estas aplicaciones muestran que la frontera entre la simulación y la experimentación se vuelve cada vez más

permeable, ya que los modelos generativos producen hipótesis concretas que se ponen a prueba experimentalmente, y los resultados de los experimentos alimentan a su vez a los modelos.

Por otra parte, la simulación de escenarios mediante inteligencia artificial generativa tiene aplicaciones también en las ciencias sociales y en la planificación de políticas. Los modelos pueden generar escenarios plausibles sobre la evolución de una variable económica, sobre el impacto de una política pública o sobre el comportamiento de una población ante determinadas condiciones, y permitir a los investigadores y a los responsables de decisiones explorar alternativas antes de comprometer recursos. En estos ámbitos, sin embargo, la validez de las simulaciones resulta más difícil de establecer, porque los sistemas sociales son altamente complejos, cambian con el tiempo y responden a las propias predicciones que se hacen sobre ellos. Una simulación generada por un modelo de lenguaje puede parecer plausible y estar bien redactada sin tener fundamento empírico suficiente.

Esta última observación remite a los riesgos específicos de la experimentación virtual. Messeri y Crockett (2024) advierten que algunos investigadores imaginan a la inteligencia artificial como un sustituto de los participantes humanos en los estudios, por ejemplo, al utilizar modelos de lenguaje para simular las respuestas de personas en encuestas o experimentos. Las autoras señalan que esta visión puede generar ilusiones de comprensión, porque los modelos reproducen patrones presentes en sus datos de entrenamiento, que no necesariamente reflejan la diversidad, la variabilidad ni las particularidades de las poblaciones reales.

En el contexto latinoamericano, donde los datos de entrenamiento de los modelos están dominados por textos de otras regiones, este riesgo es especialmente relevante: una simulación de las opiniones de una comunidad ecuatoriana generada por un modelo puede reflejar más los estereotipos presentes en sus datos que la realidad de esa comunidad. Paralelamente, para utilizar la inteligencia artificial generativa en la simulación y la experimentación virtual de manera rigurosa, conviene observar algunos principios.

Las simulaciones deben validarse contra datos reales siempre que sea posible, comparando sus resultados con observaciones independientes. Los supuestos y las limitaciones de los modelos deben documentarse explícitamente, de modo que los usuarios de los resultados puedan evaluar su alcance. Las predicciones generadas deben tratarse como hipótesis que requieren verificación, no como hallazgos establecidos. Y en las ciencias sociales, las simulaciones basadas en

modelos de lenguaje no deberían sustituir la recolección de datos con personas reales, aunque puedan ser útiles para preparar instrumentos, explorar alternativas o anticipar problemas.

Tom et al. (2024) muestran, en el ámbito de los laboratorios autónomos, que la integración entre la planificación computacional y la experimentación física es precisamente lo que permite que la exploración virtual se traduzca en conocimiento confiable. Existe, además, una cuestión de costos que debe considerarse al planificar la experimentación virtual.

Algunas simulaciones complejas requieren capacidades de cómputo considerables, cuyo acceso puede resultar costoso para las instituciones de la región, mientras que otras pueden ejecutarse con recursos modestos. La elección del nivel de detalle de los modelos debe equilibrar la precisión requerida por la pregunta de investigación con los recursos disponibles, y la colaboración entre instituciones puede facilitar el acceso a infraestructuras compartidas. Del mismo modo, el uso de modelos y conjuntos de datos abiertos, desarrollados y validados por otras comunidades científicas, puede reducir los costos de entrada y permitir que los grupos de la región se concentren en la adaptación de esos modelos a sus propios problemas.

La experimentación virtual puede también desempeñar un papel en la formación de investigadores. Los laboratorios virtuales y las simulaciones permiten a los estudiantes explorar fenómenos y diseñar experimentos sin necesidad de equipos costosos, lo que resulta especialmente valioso en instituciones con infraestructura limitada. Las herramientas de inteligencia artificial generativa pueden enriquecer estas experiencias, por ejemplo, al generar escenarios variados para el análisis, al responder preguntas de los estudiantes sobre los resultados de las simulaciones o al proponer variaciones de los experimentos.

Sin embargo, la formación en experimentación virtual debe incluir siempre la reflexión sobre los límites de los modelos y la importancia de contrastar sus resultados con la realidad. Un estudiante que aprende a diseñar experimentos solo en entornos simulados puede subestimar las dificultades y la variabilidad del mundo real; por ello, la experimentación virtual debería complementarse con experiencias prácticas en laboratorios físicos y en el trabajo de campo, para que los futuros investigadores comprendan la relación entre el modelo y el fenómeno que este pretende representar.

La transparencia sobre el carácter simulado de los resultados resulta indispensable cuando estos se comunican a públicos no especializados o a responsables de decisiones. Un escenario generado por un modelo puede presentarse con gráficos y textos tan convincentes que se confunda

con una predicción segura o con una observación de la realidad. Por ello, los informes basados en simulaciones deberían indicar claramente qué supuestos se utilizaron, qué incertidumbre tienen los resultados y en qué medida han sido validados con datos reales. En el ámbito de las políticas públicas, donde las simulaciones pueden influir en decisiones que afectan a muchas personas, esta transparencia es una exigencia ética y no solo metodológica.

Los investigadores tienen la responsabilidad de evitar que sus modelos se utilicen para dar una apariencia de certeza a decisiones que, en realidad, se toman en condiciones de incertidumbre. Sobre esta base, para los grupos de investigación de la región, la experimentación virtual mediante inteligencia artificial generativa puede representar una oportunidad significativa. En disciplinas como la química, la ciencia de materiales o la biología, donde los equipos experimentales son costosos y los recursos escasos, la posibilidad de explorar computacionalmente un gran número de alternativas y concentrar los experimentos en las más prometedoras puede multiplicar el rendimiento de los recursos disponibles.

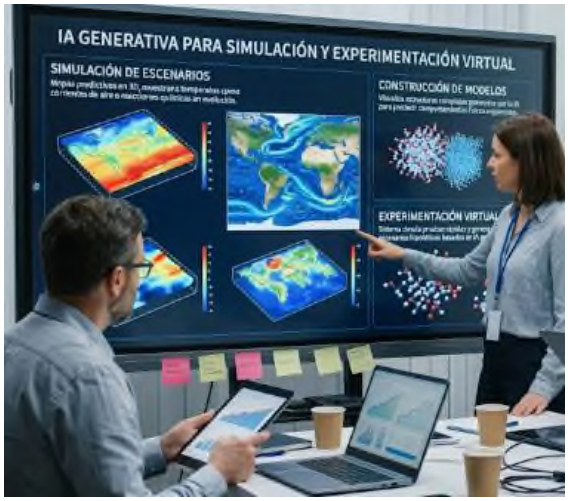
En las ciencias sociales y en la planificación de políticas, las simulaciones de escenarios pueden enriquecer la deliberación pública, siempre que se presenten con transparencia sobre sus supuestos y limitaciones. En todos los casos, la experimentación virtual debe concebirse como un complemento de la investigación empírica y no como su reemplazo, porque el conocimiento científico se valida, en última instancia, por su correspondencia con la realidad.

La experiencia de otras regiones sugiere, finalmente, que la combinación entre la simulación y la experimentación rinde sus mejores frutos cuando ambas actividades se planifican de manera conjunta desde el inicio del proyecto, con ciclos breves en los que los resultados de cada experimento alimentan a los modelos y las predicciones de los modelos orientan los siguientes experimentos. Esta lógica iterativa, propia de los laboratorios autónomos más avanzados, puede adoptarse también a escala modesta en los laboratorios universitarios de la región.

En el Ecuador, campos como la vulcanología, la hidrología andina o la ecología de los bosques tropicales podrían beneficiarse especialmente de esta articulación entre modelos y observaciones, siempre que los grupos de investigación cuenten con datos de calidad y con la formación necesaria para validar sus simulaciones.

Figura 3.6

Inteligencia artificial generativa para la simulación de escenarios, construcción de modelos y experimentación virtual.



Fuente: Elaboración autores

3.7 Automatización de procesos investigativos mediante agentes inteligentes y flujos de trabajo científicos

Una investigación científica se compone de numerosas tareas encadenadas: buscar y organizar literatura, preparar y limpiar datos, ejecutar análisis, generar tablas y gráficos, redactar informes, gestionar referencias y coordinar el trabajo de un equipo. Muchas de estas tareas son repetitivas y consumen una parte considerable del tiempo de los investigadores, tiempo que podría dedicarse a la reflexión, la interpretación y la creación.

Los flujos de trabajo científicos, entendidos como secuencias documentadas y automatizadas de pasos que transforman los datos en resultados, han permitido desde hace tiempo reducir esta carga en disciplinas con un alto componente computacional. La novedad del momento actual es la aparición de agentes inteligentes capaces de planificar y ejecutar esas secuencias de manera cada vez más autónoma.

L. Wang et al. (2024), en una revisión sistemática sobre los agentes autónomos basados en modelos de lenguaje de gran escala, describen su arquitectura mediante cuatro módulos. El módulo de perfil define el rol y las características del agente; el de memoria almacena la información de interacciones anteriores y le permite acumular experiencia; el de planificación descompone los objetivos en tareas y decide el orden en que deben realizarse; y el de acción traduce las

decisiones en operaciones concretas, como consultar una base de datos, ejecutar un programa o utilizar otra herramienta.

Los autores revisan también las aplicaciones de estos agentes en las ciencias naturales, las ciencias sociales y la ingeniería, así como los métodos para evaluarlos y los desafíos pendientes. Esta arquitectura permite comprender cómo un agente puede, por ejemplo, recibir el encargo de analizar un conjunto de datos, decidir qué pasos seguir, ejecutar los análisis, revisar los resultados y presentar un informe.

Los ejemplos más avanzados muestran que estos agentes pueden ya realizar tareas científicas complejas. Boiko et al. (2023) presentaron un sistema basado en un modelo de lenguaje que diseñaba, planificaba y ejecutaba experimentos químicos de manera semiautónoma, utilizando herramientas de búsqueda, ejecución de código y control de equipos automatizados.

Szymanski et al. (2023) describieron, por su parte, un laboratorio autónomo dedicado a la síntesis de nuevos materiales inorgánicos que, durante diecisiete días de funcionamiento continuo, informó haber sintetizado decenas de compuestos a partir de un conjunto de objetivos propuestos mediante cálculos computacionales y del análisis de la literatura, combinando robótica, aprendizaje automático y conocimiento químico, aunque la novedad de algunos de esos compuestos fue cuestionada después por otros investigadores, lo que recuerda la importancia de la verificación independiente también en la ciencia automatizada. S. Gao et al. (2024), a su vez, imaginan agentes que colaboran con las personas en el descubrimiento biomédico, planifican flujos de trabajo y se autoevalúan para identificar y reducir sus lagunas de conocimiento.

Para la mayoría de los investigadores, sin embargo, la automatización mediante agentes adoptará formas más modestas, pero no menos útiles. Un agente puede encargarse de buscar periódicamente nuevas publicaciones sobre un tema y resumirlas, de organizar y verificar la base de referencias de un proyecto, de ejecutar análisis estadísticos rutinarios y generar informes preliminares, o de convertir los resultados de un análisis en tablas y gráficos con un formato estandarizado. Estas aplicaciones pueden liberar tiempo para las tareas que requieren juicio humano y reducir los errores asociados a la repetición manual de procedimientos.

Además, cuando los flujos de trabajo están bien documentados, facilitan la reproducibilidad de la investigación, porque permiten reconstruir exactamente qué pasos se siguieron para obtener cada resultado.

La automatización de procesos investigativos plantea también riesgos que deben gestionarse con cuidado.

Los agentes basados en modelos de lenguaje pueden cometer errores que se propagan a lo largo del flujo de trabajo, generar información inexacta presentada con seguridad o realizar acciones no previstas cuando interpretan mal una instrucción. L. Wang et al. (2024) identifican, entre los desafíos pendientes de estos sistemas, la fiabilidad de su comportamiento, la alineación con los objetivos de las personas y la evaluación de su desempeño en entornos reales.

En la investigación científica, donde la exactitud y la trazabilidad son esenciales, estos riesgos exigen mecanismos de supervisión: registros completos de las acciones del agente, puntos de control en los que una persona revisa los resultados intermedios, límites claros a las acciones que puede ejecutar sin aprobación y procedimientos para detenerlo cuando sea necesario. Con todo, un principio útil para organizar esta supervisión es graduar la autonomía del agente según el riesgo de cada tarea.

Las tareas de bajo riesgo y fácilmente reversibles, como la búsqueda de literatura o la generación de borradores de gráficos, pueden automatizarse con una revisión posterior. Las de riesgo moderado, como la ejecución de análisis estadísticos, requieren puntos de verificación intermedios. Y las de alto riesgo, como la modificación de datos originales, la interacción con participantes o la ejecución de experimentos con materiales peligrosos, deberían mantenerse bajo control humano directo. El Marco de Gestión de Riesgos de Inteligencia Artificial del National Institute of Standards and Technology [NIST] (2023) propone, en un sentido semejante, identificar el contexto y los riesgos de cada sistema, medirlos y gestionarlos de manera proporcional.

La automatización de procesos investigativos tiene también implicaciones para la gestión de la investigación en las universidades. Las oficinas de investigación pueden utilizar herramientas inteligentes para monitorear convocatorias de financiamiento, apoyar la preparación de propuestas, gestionar la información sobre proyectos y publicaciones, y elaborar informes institucionales.

Estas aplicaciones pueden liberar tiempo del personal administrativo y de los investigadores, y mejorar la calidad de la información disponible para la toma de decisiones. Sin embargo, la automatización de la gestión de la investigación debe respetar los mismos principios de supervisión y transparencia que la automatización de los procesos científicos. Las decisiones sobre la asignación de recursos, la evaluación de proyectos o la promoción de investigadores no

deberían delegarse en sistemas automáticos, porque involucran juicios de valor y afectan los derechos de las personas.

Las herramientas pueden apoyar estas decisiones con información, pero la responsabilidad debe permanecer en los órganos colegiados y en las autoridades competentes, que deben rendir cuentas por ellas. La adopción de agentes en la investigación plantea también preguntas sobre la formación de los futuros investigadores. Si las tareas que antes realizaban los estudiantes de posgrado y los asistentes, como la búsqueda de literatura, la limpieza de datos o la ejecución de análisis rutinarios, se delegan en agentes, los estudiantes podrían perder oportunidades de aprendizaje que tradicionalmente les permitían comprender en profundidad los procesos de investigación. Para evitarlo, los programas de formación deberían asegurar que los estudiantes realicen estas tareas manualmente al menos en algunas ocasiones, de modo que comprendan lo que hacen los agentes y puedan detectar sus errores.

La automatización resulta más segura cuando quienes la supervisan saben realizar por sí mismos las tareas que delegan. Vinculado con lo anterior, en las universidades y centros de investigación de América Latina, la automatización mediante agentes puede contribuir a compensar la escasez de personal de apoyo técnico que caracteriza a muchos grupos de investigación. Un investigador que trabaja con pocos asistentes puede delegar en agentes tareas que antes ocupaban buena parte de su tiempo y concentrarse en la dirección intelectual de sus proyectos.

Para que esta posibilidad se materialice de manera segura, es necesario formar a los investigadores en el diseño de flujos de trabajo, en la evaluación de los resultados de los agentes y en las prácticas de documentación y supervisión. La automatización bien gestionada no reduce el papel del investigador, sino que lo desplaza hacia funciones de mayor valor: definir los objetivos, diseñar los procesos, supervisar su ejecución e interpretar los resultados.

Figura 3.7

Automatización de procesos investigativos mediante agentes inteligentes y flujos de trabajo científicos.



Fuente: Elaboración autores

3.8 Validación, explicabilidad algorítmica, reproducibilidad y control de sesgos en investigaciones asistidas por inteligencia artificial

La confiabilidad del conocimiento científico descansa en un conjunto de garantías que la comunidad ha construido a lo largo del tiempo. Los resultados deben poder validarse mediante procedimientos independientes; los métodos deben ser comprensibles para que otros puedan evaluarlos; los estudios deben poder reproducirse para confirmar sus hallazgos; y los procedimientos deben controlar los sesgos que podrían distorsionar las conclusiones.

La incorporación de la inteligencia artificial a la investigación no elimina estas exigencias, sino que las hace más necesarias y, en algunos aspectos, más difíciles de cumplir. Los modelos complejos pueden ser opacos, sus resultados pueden depender de detalles de implementación difíciles de documentar y sus sesgos pueden permanecer ocultos tras una apariencia de objetividad.

En concordancia con ello, la validación de los resultados obtenidos mediante inteligencia artificial requiere, en primer término, una evaluación adecuada del desempeño de los modelos. Esto implica utilizar datos que el modelo no ha visto durante su entrenamiento, emplear métricas apropiadas para el problema y comparar los resultados con métodos más sencillos que sirvan de referencia.

Como se ha visto en apartados anteriores, Kapoor y Narayanan (2023) mostraron que la omisión de estas precauciones, en particular la filtración de información entre los datos de entrenamiento y de evaluación, ha afectado a cientos de estudios en diecisiete campos científicos, generando

estimaciones exageradas del desempeño de los modelos. Los autores propusieron fichas de información de los modelos que los investigadores pueden completar para verificar que sus análisis estén libres de los distintos tipos de filtración, una herramienta sencilla que podría incorporarse a los procesos de revisión de proyectos y de publicaciones.

La explicabilidad algorítmica constituye la segunda garantía. Molnar (2022), en una obra de referencia sobre el aprendizaje automático interpretable, distingue entre los modelos intrínsecamente interpretables, como las regresiones o los árboles de decisión sencillos, y las técnicas que permiten explicar el comportamiento de modelos complejos después de entrenados. Entre estas últimas se encuentran los métodos que estiman la importancia de cada variable en las predicciones, los que muestran cómo cambia el resultado al modificar una variable y los que explican predicciones individuales.

Estas técnicas permiten a los investigadores verificar si los modelos se basan en patrones con sentido científico o en artefactos de los datos, detectar errores y comunicar sus resultados de manera comprensible. No obstante, las explicaciones que ofrecen son aproximaciones al comportamiento del modelo, no descripciones de los mecanismos causales del fenómeno estudiado, por lo que deben interpretarse con cautela. A ello se suma que la reproducibilidad es la tercera garantía y una de las más afectadas por la incorporación de la inteligencia artificial.

Para que un estudio basado en aprendizaje automático pueda reproducirse, es necesario disponer de los datos, del código, de la configuración exacta de los modelos y de la descripción completa de los procedimientos. Los modelos de lenguaje comerciales plantean un desafío adicional, porque se actualizan con frecuencia y su comportamiento puede cambiar sin previo aviso, de modo que un análisis realizado con una versión puede no reproducirse con la siguiente.

Por ello, los investigadores que utilizan estas herramientas deberían registrar la versión exacta empleada, las instrucciones utilizadas, la fecha de uso y los parámetros de configuración, y conservar los resultados obtenidos. La apertura de los datos y del código, promovida por la Recomendación de la UNESCO sobre la ciencia abierta (UNESCO, 2021a), contribuye decisivamente a la reproducibilidad.

El control de sesgos es la cuarta garantía y quizá la más compleja. Mehrabi et al. (2021), en su revisión sobre el sesgo y la equidad en el aprendizaje automático, describen múltiples fuentes de sesgo a lo largo del ciclo de vida de los sistemas: sesgos de representación, cuando ciertos

grupos están subrepresentados en los datos; sesgos de medición, cuando las variables se miden con distinta calidad para diferentes grupos; sesgos históricos, cuando los datos reflejan desigualdades sociales preexistentes; y sesgos derivados de las decisiones de diseño de los algoritmos o de su interacción con los usuarios.

En la investigación científica, estos sesgos pueden conducir a conclusiones que no se generalizan a ciertas poblaciones o que reproducen desigualdades. Para controlarlos, conviene evaluar el desempeño de los modelos de manera desagregada para distintos grupos, examinar la composición de los datos de entrenamiento y aplicar técnicas de mitigación cuando sea necesario. Ahora bien, estas cuatro garantías pueden integrarse en un marco de gestión de riesgos aplicable a las investigaciones asistidas por inteligencia artificial.

El Marco de Gestión de Riesgos de Inteligencia Artificial del NIST (2023) propone organizar esta gestión en cuatro funciones: gobernar, mediante una cultura organizacional que valore la gestión de riesgos; mapear, identificando el contexto y los riesgos de cada sistema; medir, evaluando y monitoreando esos riesgos; y gestionar, priorizando y atendiendo los riesgos identificados. Trasladado a un proyecto de investigación, este marco sugiere que los equipos definan desde el inicio cómo validarán sus modelos, qué técnicas de explicabilidad aplicarán, cómo garantizarán la reproducibilidad y cómo evaluarán los sesgos, y que documenten todas estas decisiones en sus informes.

Para que estas garantías se apliquen de manera sistemática, conviene incorporarlas en los distintos momentos del ciclo de la investigación. En la formulación del proyecto, los investigadores pueden describir cómo validarán sus modelos, qué técnicas de explicabilidad aplicarán y cómo evaluarán los sesgos. Durante la ejecución, pueden mantener registros detallados de las versiones de las herramientas, de los datos y del código utilizados, y realizar evaluaciones de los modelos en distintos subgrupos.

En la publicación, pueden describir todos estos procedimientos, compartir los materiales necesarios para la reproducción y reconocer las limitaciones de sus resultados. Y después de la publicación, pueden responder a las preguntas y críticas de otros investigadores y corregir los errores que se detecten. Las revistas, los comités de ética y los organismos de financiamiento pueden promover estas prácticas al exigirlas en sus convocatorias y en sus procesos de revisión.

De este modo, la validación, la explicabilidad, la reproducibilidad y el control de sesgos dejan de ser aspiraciones abstractas y se convierten en componentes concretos de la cultura científica.

En el plano institucional, las universidades pueden reforzar estas garantías mediante servicios de apoyo a la reproducibilidad. Algunas instituciones han creado unidades que ayudan a los investigadores a organizar sus datos y su código, a documentar sus procedimientos y a depositar sus materiales en repositorios, e incluso que verifican la reproducibilidad de los análisis antes de su publicación.

Este tipo de servicios, que pueden apoyarse en herramientas automatizadas, contribuye a elevar la calidad de la investigación institucional y a reducir el riesgo de errores que dañen la reputación de los investigadores y de la institución. En el contexto ecuatoriano, podrían articularse con los repositorios institucionales y con las oficinas de investigación, y desarrollarse de manera gradual, comenzando por los proyectos financiados con fondos públicos.

Figura 3.8

Validación, explicabilidad algorítmica, reproducibilidad y control de sesgos en investigaciones asistidas por inteligencia artificial.



Fuente: Elaboración autores

Muchos de los modelos y herramientas disponibles han sido entrenados con datos de otras poblaciones y contextos, y su aplicación a problemas latinoamericanos puede producir resultados sesgados o poco válidos sin que los usuarios lo adviertan. Validar los modelos con datos locales, evaluar su desempeño en las poblaciones de interés y documentar las limitaciones de su aplicación son, por ello, prácticas especialmente importantes.

Messeri y Crockett (2024) advierten que la abundancia de resultados producidos con ayuda de la inteligencia artificial puede generar la ilusión de un conocimiento más sólido del que realmente se tiene. Las garantías de validación, explicabilidad, reproducibilidad y control de sesgos son, precisamente, el antídoto frente a esa ilusión y la condición para que la investigación asistida por inteligencia artificial contribuya verdaderamente al avance del conocimiento.

EDITORIAL ANDES COGNITIO

CAPÍTULO IV

PRODUCCIÓN CIENTÍFICA 5.0: REDACCIÓN INTELIGENTE, PUBLICACIÓN ACADÉMICA Y VISIBILIDAD DEL CONOCIMIENTO



CAPÍTULO IV

PRODUCCIÓN CIENTÍFICA 5.0: REDACCIÓN INTELIGENTE, PU BLICACIÓN ACADÉMICA Y VISIBILIDAD DEL CONOCIMIENTO

4.1 Transformación de la escritura científica: de la redacción convencional a la producción académica asistida por inteligencia artificial

La escritura científica es mucho más que la comunicación de resultados ya obtenidos. Al redactar, los investigadores ordenan su pensamiento, descubren lagunas en sus argumentos, precisan conceptos y deciden cómo situar su trabajo en relación con el conocimiento existente. Por ello, la escritura ha sido tradicionalmente considerada una parte integral del proceso de investigación y no un trámite posterior a ella.

Durante generaciones, esta tarea dependió casi por completo de las capacidades del autor, apoyadas en diccionarios, manuales de estilo, la revisión de colegas y, en tiempos más recientes, los correctores ortográficos y gramaticales. La llegada de los modelos de lenguaje capaces de redactar textos completos a partir de instrucciones breves ha transformado radicalmente este panorama y ha abierto un debate intenso sobre los usos legítimos de estas herramientas en la producción académica.

Además, la capacidad de estos modelos para producir textos científicos verosímiles quedó demostrada muy pronto. C. A. Gao et al. (2023) pidieron a un modelo de lenguaje que redactara resúmenes de investigaciones médicas a partir de los títulos de artículos publicados en revistas de alto impacto, y los sometieron a la evaluación de revisores humanos que no conocían su origen. Los revisores identificaron correctamente como generados el 68 % de los resúmenes producidos por la máquina, pero también clasificaron erróneamente como generados el 14 % de los resúmenes originales.

Un detector automático de textos generados obtuvo, en cambio, un desempeño elevado, y los resúmenes generados presentaron puntuaciones bajas en los programas de detección de plagio, porque no copiaban textos existentes. Estos resultados mostraron que los textos producidos por los modelos podían pasar inadvertidos para lectores expertos y que la detección del plagio tradicional no era suficiente para identificarlos.

Ante esta situación, la comunidad académica ha reaccionado con una combinación de entusiasmo y preocupación. Dwivedi et al. (2023), en un trabajo que reunió las perspectivas de numerosos especialistas, reconocieron que la inteligencia artificial conversacional puede mejorar la productividad, ayudar a los autores que escriben en una lengua distinta de la materna y facilitar la revisión de textos, pero advirtieron sobre los riesgos de inexactitud, de pérdida de originalidad, de dependencia y de vulneración de la integridad académica.

Lund et al. (2023), al analizar las implicaciones éticas de estas herramientas para la publicación académica, subrayaron los problemas de transparencia y de atribución, y la necesidad de normas claras sobre su empleo. La transformación de la escritura científica no es, por tanto, solo técnica, sino también ética y cultural.

En esta misma línea, las organizaciones de ética editorial han establecido criterios que orientan esta transformación. El Committee on Publication Ethics determinó que las herramientas de inteligencia artificial no pueden figurar como autoras, que los autores deben declarar de manera transparente el uso que hicieron de ellas, indicando qué herramienta utilizaron y para qué, y que son plenamente responsables de todo el contenido de su manuscrito, incluidas las partes producidas con ayuda de la herramienta (COPE, 2023).

Thorp (2023), editor de Science, estableció que los textos generados por estas herramientas no pueden utilizarse en los trabajos publicados en sus revistas sin autorización de los editores y que un programa no puede ser autor. Las recomendaciones del International Committee of Medical Journal Editors [ICMJE] (2023), de amplia influencia más allá de las ciencias de la salud, coinciden en que los programas de inteligencia artificial no pueden figurar como autores, porque no pueden responder por la exactitud ni por la integridad del trabajo, y en que su uso debe declararse en el manuscrito.

Las directrices de la Comisión Europea (2024) sobre el uso responsable de la inteligencia artificial generativa en la investigación insisten, en la misma línea, en que los investigadores siguen siendo responsables de los resultados científicos y deben utilizar estas herramientas de manera transparente.

A partir de estos criterios es posible distinguir entre distintos tipos de uso de la inteligencia artificial en la escritura científica. Existen usos de apoyo lingüístico, como la corrección gramatical, la mejora del estilo o la traducción de textos redactados por el autor, que la mayoría de las editoriales consideran aceptables siempre que se declaren.

Hay usos de apoyo estructural, como la sugerencia de una organización para el artículo o la identificación de partes poco claras, que también suelen admitirse con transparencia. Y existen usos de generación sustantiva, en los que la herramienta produce partes significativas del contenido, como la discusión de resultados o la revisión de la literatura, que plantean mayores problemas de integridad y que algunas editoriales restringen o prohíben.

En todos los casos, el autor debe verificar la exactitud de lo producido, ya que los modelos pueden introducir afirmaciones falsas o referencias inexistentes con total apariencia de verosimilitud. De igual manera, esta transformación tiene implicaciones particulares para los investigadores latinoamericanos. Para muchos de ellos, la necesidad de publicar en inglés en revistas internacionales ha constituido una barrera importante, que exigía costosos servicios de traducción o de corrección.

Las herramientas de inteligencia artificial pueden reducir esta barrera, al ayudar a redactar en una segunda lengua con mayor fluidez y corrección, lo que podría favorecer la visibilidad internacional de la ciencia de la región. Sin embargo, este beneficio solo es legítimo si se utiliza para expresar mejor las ideas propias del autor y si se declara adecuadamente. Utilizar estas herramientas para producir textos que el autor no ha pensado, o presentar como propio un trabajo sustancialmente generado por una máquina sin declararlo, constituye una falta de integridad que puede tener consecuencias graves para la carrera de un investigador y para la credibilidad de su institución.

Una declaración de uso de herramientas de inteligencia artificial puede redactarse de manera sencilla y precisa. Basta con indicar qué herramienta se utilizó, en qué versión o fecha, para qué tareas concretas y cómo se verificaron sus resultados. Por ejemplo, un autor podría señalar que utilizó un determinado modelo de lenguaje para revisar la gramática y la claridad de la versión en inglés de su manuscrito, redactado originalmente por él en español, y que revisó todas las sugerencias antes de aceptarlas; o que empleó una herramienta de búsqueda asistida para identificar literatura, cuyas referencias verificó en las fuentes originales.

Estas declaraciones, que muchas revistas ubican en la sección de métodos o en los agradecimientos, no restan valor al trabajo, sino que lo protegen, porque muestran que el autor actuó con transparencia y que asume la responsabilidad por el contenido. Las universidades podrían ofrecer a sus investigadores y estudiantes modelos de declaración adaptados a los distintos tipos

de trabajos académicos, para facilitar esta práctica y uniformar los criterios dentro de la institución. La formación en escritura científica adquiere, por todo ello, una importancia renovada.

Si las herramientas pueden producir textos correctos con facilidad, el valor de la formación no reside en enseñar a redactar frases gramaticalmente impecables, sino en enseñar a pensar con claridad, a construir argumentos sólidos, a utilizar la evidencia con honestidad y a expresar ideas propias con precisión.

Figura 4.1

Transformación de la escritura científica: de la redacción convencional a la producción académica asistida por inteligencia artificial.



Fuente: Elaboración autores

Los talleres de escritura pueden incorporar el uso crítico de las herramientas, por ejemplo, comparando un texto propio con versiones sugeridas por un modelo y analizando qué se gana y qué se pierde en cada cambio. Este tipo de ejercicios ayuda a los estudiantes a desarrollar su propia voz como autores y a comprender que la escritura científica no es solo una cuestión de estilo, sino una forma de razonamiento que las herramientas no pueden realizar en su lugar. Por otra parte, para las universidades del Ecuador y de la región, la transformación de la escritura científica exige una respuesta institucional.

Resulta necesario adoptar políticas claras sobre el uso de la inteligencia artificial en los trabajos académicos, que definan los usos aceptables y la forma de declararlos; formar a docentes y estudiantes en el uso responsable de estas herramientas; y revisar las prácticas de evaluación,

que en muchos casos se basan en la entrega de textos escritos que ahora pueden generarse con facilidad.

Miao y Holmes (2023), en la guía de la UNESCO sobre inteligencia artificial generativa en la educación y la investigación, recomiendan precisamente que las instituciones desarrollen criterios propios y que la adopción de estas herramientas se acompañe de formación y de reflexión ética. La escritura científica conserva su valor como forma de pensamiento, y las herramientas pueden enriquecerla, siempre que no sustituyan el trabajo intelectual que le da sentido.

4.2 Arquitectura inteligente de artículos científicos: coherencia argumentativa, estructura IMRyD y comunicación de resultados

El artículo científico es el formato central de la comunicación académica. Su estructura más difundida, conocida como IMRyD por las iniciales de introducción, métodos, resultados y discusión, se consolidó durante el siglo XX como un estándar que facilita la lectura, la evaluación y la comparación de los trabajos. Cada sección cumple una función específica. La introducción presenta el problema, revisa el conocimiento existente y justifica la necesidad del estudio; los métodos describen con precisión cómo se realizó la investigación para que otros puedan evaluarla y reproducirla; los resultados presentan los hallazgos de manera objetiva; y la discusión los interpreta, los compara con estudios anteriores, reconoce las limitaciones y señala las implicaciones.

Detrás de esta estructura formal existe, sin embargo, una arquitectura argumentativa más profunda, que es la que da coherencia y fuerza persuasiva a un artículo. Paralelamente, la coherencia argumentativa de un artículo depende de que todas sus partes respondan a una misma lógica. La pregunta formulada en la introducción debe ser la que efectivamente se responde en los resultados; los métodos deben ser apropiados para esa pregunta; los resultados presentados deben ser los pertinentes, no todos los obtenidos; y la discusión debe derivarse de los resultados, sin afirmar más de lo que estos permiten sostener.

Muchos artículos rechazados por las revistas no fallan por la calidad de los datos, sino por la debilidad de esta arquitectura: preguntas vagas, métodos mal justificados, resultados desordenados o discusiones que se apartan de lo encontrado. La construcción de una buena arquitectura argumentativa requiere una comprensión profunda del propio trabajo y de su lugar en el campo, y por ello constituye una de las tareas más formativas de la escritura científica.

Las herramientas de inteligencia artificial pueden apoyar la construcción de esta arquitectura de diversas maneras. Pueden ayudar a elaborar un esquema del artículo a partir de las ideas principales del autor, señalar incoherencias entre la pregunta planteada y los resultados presentados, identificar afirmaciones de la discusión que no están respaldadas por los datos o sugerir una organización más clara para secciones extensas.

Liang et al. (2024) analizaron la capacidad de un modelo de lenguaje para proporcionar comentarios sobre artículos científicos y encontraron que una parte de los comentarios del sistema coincidía con los formulados por revisores humanos, en una proporción comparable a la coincidencia entre dos revisores humanos, y que la mayoría de los investigadores que participaron en un estudio con usuarios consideró útiles los comentarios recibidos. Estos resultados sugieren que los modelos pueden funcionar como un primer lector crítico que ayude a los autores a detectar debilidades antes de enviar su trabajo.

El apoyo de estas herramientas tiene, con todo, límites que conviene conocer. Los mismos autores observaron que el modelo tendía a insistir en ciertos aspectos de la retroalimentación, como la conveniencia de añadir experimentos con más conjuntos de datos, y que con frecuencia tenía dificultades para ofrecer una crítica profunda del diseño metodológico. Por otra parte, Bender et al. (2021) recordaron que los modelos producen textos fluidos sin comprender su significado como lo hacen las personas, lo que puede llevar a que una sugerencia bien redactada parezca más fundada de lo que es. En la construcción de la arquitectura argumentativa, el autor debe evaluar cada sugerencia a la luz de su conocimiento del tema y decidir si mejora o no la lógica de su trabajo.

La comunicación de los resultados merece una atención particular. Los resultados deben presentarse de manera precisa, completa y honesta, incluyendo los hallazgos que no confirman las hipótesis y reconociendo la incertidumbre de las estimaciones. Las herramientas de inteligencia artificial pueden ayudar a redactar descripciones claras de tablas y gráficos, a verificar la consistencia entre las cifras del texto y las de las tablas, o a sugerir formas más efectivas de visualizar los datos. Sin embargo, la interpretación de los resultados debe permanecer bajo el control del autor, porque es en ella donde se juega la integridad del trabajo.

Un modelo de lenguaje puede, por ejemplo, exagerar la importancia de un hallazgo, presentar una correlación como si fuera una relación causal o generalizar más allá de lo que permite la muestra, errores que un lector experto identificará y que pueden comprometer la credibilidad

del artículo. Sobre esta base, la enseñanza de la escritura científica puede beneficiarse de estas herramientas si se utilizan con propósitos formativos.

Giray (2023) sostiene que los autores pueden aprovechar los modelos de lenguaje para mejorar su escritura siempre que dominen las técnicas para formular instrucciones adecuadas y conozcan sus limitaciones. Un ejercicio útil consiste en que los estudiantes redacten su propio esquema argumentativo antes de consultar a una herramienta, que comparen después su propuesta con la sugerida por el modelo y que justifiquen las diferencias. Otro consiste en pedir a la herramienta que identifique las debilidades de un borrador y que el estudiante evalúe críticamente si esas observaciones son pertinentes. Estos ejercicios fortalecen la capacidad de los estudiantes para pensar la arquitectura de sus textos, en lugar de delegarla en la máquina.

La estructura IMRyD no es, por otra parte, la única forma válida de organizar un trabajo científico. Las revisiones de literatura, los ensayos teóricos, los estudios de caso o los artículos de las humanidades y de algunas ciencias sociales siguen otras estructuras, más adecuadas a su naturaleza. En todos los casos, sin embargo, se mantiene la exigencia de una arquitectura argumentativa coherente, en la que cada parte contribuya al propósito general del texto.

Las herramientas de inteligencia artificial tienden a reproducir las estructuras más frecuentes en sus datos de entrenamiento, por lo que pueden sugerir organizaciones estandarizadas que no siempre son las más adecuadas para un trabajo determinado. Un ensayo teórico, por ejemplo, puede perder fuerza si se fuerza a encajar en el molde de un artículo empírico. Por ello, el autor debe decidir conscientemente la estructura que mejor sirve a su argumento, utilizando las sugerencias de las herramientas como alternativas a considerar y no como plantillas obligatorias.

El resumen y el título merecen una atención particular en la arquitectura de un artículo, porque son las partes que más lectores consultan y las que determinan, en muchos casos, si el trabajo será leído completo. Un buen resumen sintetiza el problema, los métodos, los resultados principales y las conclusiones en pocas líneas, sin exagerar los hallazgos ni omitir las limitaciones relevantes. Las herramientas de inteligencia artificial pueden ayudar a redactar versiones preliminares de estos elementos, pero existe el riesgo de que produzcan textos atractivos que sobrevaloren los resultados.

El autor debe verificar que el resumen refleje con fidelidad el contenido del artículo y que el título sea preciso, informativo y coherente con lo efectivamente estudiado. Estas partes breves condensan la integridad del trabajo y merecen el mismo cuidado que las secciones más extensas.

Desde esta perspectiva, para los investigadores de la región, dominar la arquitectura de los artículos científicos es una condición para participar en la conversación científica internacional. Las revistas de mayor visibilidad reciben muchos más manuscritos de los que pueden publicar, y la claridad argumentativa es uno de los criterios decisivos en la selección. Las herramientas de inteligencia artificial pueden ayudar a los autores latinoamericanos a mejorar la presentación de sus trabajos, especialmente cuando escriben en una segunda lengua, pero no pueden sustituir la solidez de la investigación ni la claridad del pensamiento que la sustenta.

La arquitectura inteligente de un artículo científico no es la que produce una máquina, sino la que construye un autor que comprende su trabajo y sabe utilizar las herramientas disponibles para comunicarlo de la mejor manera posible, declarando siempre su uso.

Figura 4.2

Arquitectura inteligente de artículos científicos: coherencia argumentativa, estructura IMRyD y comunicación de resultados.



Fuente: Elaboración autores

4.3 Gestión avanzada de referencias bibliográficas, identificación de fuentes y verificación automatizada de citas

Las referencias bibliográficas cumplen funciones esenciales en la comunicación científica. Reconocen el trabajo de otros investigadores, permiten a los lectores verificar las afirmaciones y profundizar en los temas, sitúan el trabajo en relación con el conocimiento existente y constituyen la base de los sistemas de evaluación de la ciencia basados en citas. Una referencia incorrecta, incompleta o inventada no es un error menor: compromete la confiabilidad del trabajo, puede atribuir ideas a quienes no las formularon y, en los casos más graves, constituye una falta de integridad académica.

La gestión de las referencias ha sido siempre una tarea laboriosa, que los programas de gestión bibliográfica facilitaron considerablemente al automatizar la captura de los datos de las publicaciones y la generación de las listas en distintos estilos. La inteligencia artificial introduce ahora nuevas posibilidades, pero también riesgos inéditos. De forma complementaria, entre las posibilidades, destaca la capacidad de las herramientas inteligentes para ayudar a identificar fuentes pertinentes.

Los motores de búsqueda académica que utilizan procesamiento del lenguaje natural pueden encontrar trabajos relacionados por su contenido y no solo por la coincidencia de palabras clave, sugerir publicaciones relevantes a partir de las que el investigador ya ha leído y resumir el contenido de los artículos para facilitar su selección. Los sistemas de aprendizaje activo, como el desarrollado por van de Schoot et al. (2021) para las revisiones sistemáticas, permiten priorizar la lectura de los trabajos con mayor probabilidad de ser relevantes. Estas herramientas pueden ahorrar mucho tiempo en la búsqueda bibliográfica y ayudar a los investigadores a descubrir trabajos que habrían pasado inadvertidos.

A la búsqueda puntual se suma la vigilancia continua de la literatura. Los sistemas inteligentes pueden configurarse para monitorear de manera periódica las bases de datos internacionales y los sistemas regionales de acceso abierto, como SciELO, Redalyc o Latindex, y enviar alertas sobre nuevas publicaciones, informes técnicos o patentes relacionados con una línea de investigación.

Esta vigilancia tecnológica, acompañada de una curaduría cuidadosa de los contenidos, permite a los grupos mantenerse actualizados en sus áreas de trabajo, anticipar tendencias y preparar

con mejores fundamentos sus propuestas para convocatorias competitivas. En el Ecuador, donde muchos centros de investigación trabajan en áreas prioritarias como la biotecnología, la gestión del agua o la salud pública con equipos reducidos, este tipo de servicios, ofrecidos por las bibliotecas o las oficinas de investigación, puede marcar una diferencia apreciable. La curaduría exige, sin embargo, una auditoría de las fuentes, porque las herramientas sugieren trabajos por su similitud temática y no por la calidad de las revistas en que se publicaron; corresponde al equipo comprobar que los estudios seleccionados procedan de publicaciones arbitradas y con prácticas editoriales reconocidas, y no de revistas depredadoras.

Entre los riesgos, el más grave es la fabricación de referencias por parte de los modelos de lenguaje generativos. Walters y Wilder (2023) analizaron las referencias bibliográficas incluidas en textos generados por dos versiones de un conocido asistente conversacional y encontraron que el 55 % de las referencias producidas por la versión más antigua y el 18 % de las producidas por la más reciente eran inventadas, es decir, correspondían a trabajos inexistentes.

Además, entre las referencias que correspondían a trabajos reales, el 43 % y el 24 %, respectivamente, contenían errores sustanciales, como autores, títulos, años o revistas incorrectos. Estos resultados muestran que los modelos de lenguaje no pueden utilizarse como fuente de referencias sin una verificación exhaustiva, y que la mejora de las versiones más recientes no elimina el problema. Vinculado con lo anterior, la fabricación de referencias es especialmente peligrosa porque las citas inventadas suelen ser verosímiles.

Los modelos generan títulos plausibles, atribuidos a autores que trabajan efectivamente en el tema y publicados en revistas reales, de modo que una lectura superficial no permite detectarlas. Un investigador que incorpora estas referencias a su trabajo sin verificarlas no solo comete un error, sino que propaga información falsa que otros podrían reproducir. Por ello, la verificación de las referencias debe convertirse en una práctica sistemática, que consiste en comprobar que cada trabajo citado existe, que sus datos bibliográficos son correctos y, sobre todo, que efectivamente contiene la información que se le atribuye en el texto.

Esta última comprobación es la más importante y la más difícil de automatizar. Incluso cuando una referencia existe y sus datos son correctos, puede ocurrir que el trabajo citado no diga lo que el autor afirma, o que lo diga con matices que la cita omite. Las herramientas de inteligencia artificial pueden ayudar a esta verificación, por ejemplo, al localizar en el texto de un artículo

los pasajes relacionados con una afirmación determinada, pero la evaluación final de si la cita es fiel requiere la lectura del investigador.

La verificación automatizada de citas, en su forma más útil, combina la comprobación automática de la existencia y los datos de las referencias, mediante la consulta de bases de datos y de identificadores persistentes como el DOI, con la revisión humana del contenido. En concordancia con ello, una gestión avanzada de referencias en la era de la inteligencia artificial podría organizarse según algunos principios prácticos.

Toda referencia debe obtenerse de una fuente verificable, como una base de datos académica, el sitio de la revista o un repositorio, y nunca directamente de un texto generado por un modelo de lenguaje. Los datos bibliográficos deben capturarse mediante programas de gestión de referencias a partir de los identificadores persistentes de las publicaciones. Cada cita debe contrastarse con el texto original del trabajo citado antes de incorporarse al manuscrito. Y cuando se utilicen herramientas de inteligencia artificial para buscar o resumir literatura, este uso debe documentarse y sus resultados verificarse. Estas prácticas, que pueden parecer exigentes, son la mejor protección contra los errores que comprometen la credibilidad de un trabajo.

Los programas de formación pueden incorporar ejercicios específicos para desarrollar estas competencias. Una actividad útil consiste en entregar a los estudiantes un texto que contiene referencias reales y referencias fabricadas por un modelo de lenguaje, y pedirles que identifiquen cuáles son falsas y que corrijan los errores de las verdaderas. Otro ejercicio consiste en verificar si un conjunto de citas incluidas en un texto corresponde efectivamente al contenido de los trabajos citados.

Estas actividades muestran de manera vivencial la magnitud del problema y enseñan procedimientos de verificación que los estudiantes podrán aplicar a lo largo de su carrera. Las bibliotecas universitarias, que tradicionalmente han apoyado la formación en búsqueda y gestión de información, pueden desempeñar un papel central en estos programas, ofreciendo talleres sobre el uso responsable de las herramientas de búsqueda inteligente y de los gestores de referencias.

En las universidades ecuatorianas, fortalecer este papel de las bibliotecas sería una inversión modesta con un impacto significativo en la calidad de la producción académica. Las revistas latinoamericanas pueden contribuir de manera significativa a la integridad de las referencias mediante prácticas editoriales sencillas. Exigir que todas las referencias incluyan su

identificador persistente cuando exista, verificar automáticamente su existencia durante la recepción de los manuscritos y solicitar a los revisores que comprueben al menos una muestra de las citas son medidas que pueden aplicarse con recursos limitados.

Además, la publicación de las listas de referencias con enlaces activos facilita que los lectores verifiquen las fuentes y que los sistemas de indexación registren adecuadamente las citas. Estas prácticas fortalecen la credibilidad de las revistas y contribuyen a que la producción científica regional se integre correctamente en las redes de citación internacionales. La relevancia de estas prácticas se extiende, en definitiva, más allá de los investigadores individuales.

Las revistas científicas pueden incorporar verificaciones automáticas de las referencias en sus procesos editoriales, para detectar citas inexistentes o con errores antes de la publicación; las universidades pueden incluir la verificación de referencias en la formación de sus estudiantes y en la revisión de las tesis; y los programas de gestión bibliográfica pueden integrar funciones de verificación. En el contexto latinoamericano, donde muchas revistas cuentan con equipos editoriales pequeños, la adopción de herramientas de verificación automática podría contribuir a mejorar la calidad de las publicaciones. La gestión de las referencias, a menudo considerada una tarea secundaria, se revela así como un componente fundamental de la integridad científica en la era de la inteligencia artificial.

Figura 4.3

Gestión avanzada de referencias bibliográficas, identificación de fuentes y verificación automatizada de citas.



Fuente: Elaboración autores

4.4 Inteligencia artificial aplicada a la edición académica, corrección científica y evaluación preliminar de manuscritos

El proceso editorial de una revista científica comprende varias etapas entre la recepción de un manuscrito y su publicación. Primero, el equipo editorial realiza una evaluación preliminar para verificar que el trabajo corresponde al alcance de la revista, cumple los requisitos formales y tiene una calidad mínima que justifique su envío a revisión. Luego, el manuscrito se somete a la revisión por pares, en la que especialistas del campo evalúan su originalidad, rigor y relevancia, y recomiendan su aceptación, su modificación o su rechazo.

Finalmente, los trabajos aceptados pasan por la corrección de estilo, la diagramación y la publicación. Cada una de estas etapas exige un trabajo considerable, y el crecimiento constante del número de manuscritos ha generado una presión creciente sobre los editores y, sobre todo, sobre los revisores, cuya disponibilidad es limitada. Asimismo, la inteligencia artificial puede contribuir a aliviar esta presión en varias tareas.

En la evaluación preliminar, las herramientas automáticas pueden verificar el cumplimiento de los requisitos formales, detectar posibles problemas de plagio o de manipulación de imágenes, comprobar la existencia de las referencias y sugerir revisores potenciales a partir del contenido del manuscrito. En la corrección de estilo, pueden identificar errores gramaticales, inconsistencias terminológicas o problemas de claridad, y proponer correcciones que el equipo editorial revisa. Estas aplicaciones pueden mejorar la eficiencia del proceso editorial y permitir que los editores concentren su atención en las decisiones que requieren juicio experto.

El control de la integridad editorial se ha vuelto, además, más complejo. Como mostraron C. A. Gao et al. (2023), los textos producidos por modelos de lenguaje no reproducen literalmente fragmentos existentes y pueden eludir los programas convencionales de detección de similitud, de modo que las editoriales han comenzado a combinar estos programas con sistemas que analizan patrones estadísticos del lenguaje, detectan la duplicación o la manipulación de imágenes y rastrean redes anómalas de citación o la actividad de las llamadas fábricas de artículos (paper mills).

Estas herramientas cumplen una función de filtro inicial que permite señalar casos sospechosos, pero sus resultados son indicios y no pruebas: pueden producir falsos positivos y nunca deberían conducir por sí solos al rechazo de un manuscrito o a la imputación de una falta. La decisión

sobre la solidez científica y la integridad de un trabajo corresponde, en última instancia, al juicio informado de editores y revisores.

La aplicación más debatida es el uso de modelos de lenguaje en la revisión por pares. Liang et al. (2024) realizaron un análisis a gran escala de la capacidad de un modelo de lenguaje para generar comentarios sobre artículos científicos. Compararon los comentarios del modelo con los de revisores humanos en miles de manuscritos de revistas de la familia Nature y de una conferencia de aprendizaje automático, y encontraron que la coincidencia entre los comentarios del modelo y los de los revisores humanos fue del 30,85 % y del 39,23 %, respectivamente, cifras comparables a la coincidencia entre dos revisores humanos. En un estudio prospectivo con 308 investigadores de 110 instituciones, el 57,4 % consideró que los comentarios generados eran útiles o muy útiles, y el 82,4 % los encontró más provechosos que los de al menos algunos revisores humanos.

Los autores concluyeron que estos sistemas pueden ser útiles para que los autores obtengan retroalimentación temprana, especialmente quienes tienen menos acceso a ella, pero advirtieron que no reemplazan la revisión humana experta. A modo de ilustración, Hosseini y Horbach (2023) analizaron las consideraciones éticas del uso de modelos de lenguaje en la revisión por pares y señalaron que estas herramientas podrían ayudar a aliviar la fatiga de los revisores, por ejemplo, al mejorar la redacción de los informes, pero también podrían amplificar sesgos, vulnerar la confidencialidad de los manuscritos y diluir la responsabilidad de los evaluadores.

El problema de la confidencialidad es particularmente serio, puesto que los manuscritos en revisión son trabajos inéditos, y cargarlos en plataformas externas de inteligencia artificial puede exponer su contenido a terceros o permitir su uso para entrenar modelos. Por esta razón, las directrices de la Comisión Europea (2024) sobre el uso responsable de la inteligencia artificial generativa en la investigación recomiendan que los investigadores se abstengan de utilizar estas herramientas de manera sustancial en actividades sensibles, como la revisión por pares o la evaluación de propuestas de investigación.

Estas consideraciones permiten delimitar usos aceptables y usos problemáticos de la inteligencia artificial en la edición académica. Entre los usos que suelen considerarse aceptables, con las debidas salvaguardas, se encuentran la verificación automática de requisitos formales, la detección de plagio y de manipulación de imágenes, la comprobación de referencias, la sugerencia de revisores y la corrección de estilo de textos ya aceptados. Entre los usos problemáticos

destacan la delegación de la evaluación sustantiva de los manuscritos en sistemas automáticos, la carga de manuscritos confidenciales en plataformas que no garantizan su protección y la redacción de informes de revisión por parte de modelos sin la evaluación crítica del revisor.

En todos los casos, las revistas deberían establecer políticas explícitas sobre el uso de estas herramientas por parte de editores, revisores y autores, y comunicarlas con claridad. Además, la evaluación preliminar de manuscritos por parte de los propios autores constituye una aplicación menos problemática y potencialmente muy útil. Antes de enviar un trabajo a una revista, el autor puede utilizar herramientas de inteligencia artificial para identificar debilidades en la argumentación, inconsistencias entre secciones, errores de redacción o problemas en la presentación de los resultados, siempre que utilice herramientas que respeten la confidencialidad de su trabajo.

El estudio de Liang et al. (2024) sugiere que este tipo de retroalimentación puede resultar especialmente valiosa para los investigadores que no cuentan con colegas expertos que revisen sus borradores, situación frecuente en instituciones pequeñas o en países con comunidades científicas reducidas. Esta retroalimentación automatizada no sustituye la revisión por pares, pero puede contribuir a que los manuscritos lleguen a las revistas en mejores condiciones.

Para los autores que reciben comentarios de revisores, la inteligencia artificial puede servir también como apoyo en la preparación de las respuestas y en la revisión de los manuscritos. Las herramientas pueden ayudar a organizar los comentarios recibidos, a identificar los cambios necesarios en el texto y a redactar respuestas claras y respetuosas. No obstante, la evaluación de la pertinencia de cada comentario y la decisión sobre cómo responder deben permanecer en manos de los autores, que conocen su trabajo y deben asumir la responsabilidad por las modificaciones.

Del mismo modo, los revisores que deseen utilizar herramientas para mejorar la redacción de sus informes deberían hacerlo solo con herramientas que garanticen la confidencialidad, sin cargar el manuscrito evaluado, y declararlo al editor cuando la revista así lo requiera. Estas prácticas permiten aprovechar los beneficios de la inteligencia artificial en el proceso editorial sin comprometer los valores de confidencialidad, independencia y responsabilidad que sustentan la revisión por pares y que constituyen la base de la confianza en la literatura científica.

La formación de revisores es otro ámbito en el que las universidades y las revistas de la región pueden actuar. Muchos investigadores asumen la tarea de revisar manuscritos sin haber recibido orientación sobre cómo hacerlo, y la aparición de las herramientas de inteligencia artificial añade nuevas preguntas sobre los usos permitidos. Programas de formación que expliquen los criterios de una buena revisión, las normas éticas aplicables, los riesgos del uso de herramientas automatizadas y la manera de redactar informes constructivos contribuirían a mejorar la calidad de la revisión por pares en la región.

Estos programas podrían organizarse de manera colaborativa entre varias revistas o universidades, y reconocer la labor de revisión como una contribución académica valiosa en los sistemas de evaluación de los investigadores. En esta misma línea, para las revistas científicas latinoamericanas, muchas de las cuales funcionan con equipos editoriales reducidos y con escasos recursos, la inteligencia artificial puede representar una ayuda significativa en las tareas de verificación y corrección.

La edición académica asistida por inteligencia artificial puede mejorar la eficiencia y la calidad de las publicaciones, siempre que preserve los valores que dan sentido a la revisión por pares: el juicio experto, la independencia, la confidencialidad y la responsabilidad de quienes evalúan el trabajo científico.

Figura 4.4

Inteligencia artificial aplicada a la edición académica, corrección científica y evaluación preliminar de manuscritos.



Fuente: Elaboración autores

4.5 Publicación científica inteligente: selección de revistas, criterios de indexación y evaluación de calidad editorial

Elegir la revista adecuada para publicar un trabajo es una decisión estratégica que influye en la visibilidad, en el impacto y en la valoración académica de la investigación. Una buena elección considera la correspondencia entre el tema del trabajo y el alcance de la revista, el público al que se dirige, la calidad de su proceso editorial, su indexación en bases de datos reconocidas, sus tiempos de respuesta, sus políticas de acceso y sus costos de publicación. Una mala elección puede conducir a rechazos sucesivos que retrasan la difusión de los resultados o, en el peor de los casos, a la publicación en revistas de baja calidad o fraudulentas que dañan la reputación del autor.

La inteligencia artificial ofrece herramientas que pueden facilitar esta decisión, pero también exige comprender los criterios que definen la calidad editorial. De igual manera, las herramientas inteligentes de selección de revistas analizan el título, el resumen o el texto completo de un manuscrito y sugieren las revistas cuyo contenido publicado se asemeja más al del trabajo.

Muchas grandes editoriales ofrecen este tipo de herramientas para sus propias revistas, y existen también servicios independientes que abarcan publicaciones de distintas editoriales. Estas herramientas pueden ayudar a los investigadores a identificar revistas que no conocían y a evitar envíos a publicaciones cuyo alcance no corresponde a su trabajo. Sin embargo, sus sugerencias se basan principalmente en la similitud temática y no evalúan por sí solas la calidad editorial, por lo que deben complementarse con un análisis de los demás criterios.

Los criterios de indexación constituyen una referencia importante para evaluar la calidad de una revista. Las bases de datos y los sistemas de indexación, tanto internacionales como regionales, aplican criterios de selección que incluyen aspectos como la existencia de un proceso de revisión por pares, la composición del comité editorial, la regularidad de la publicación, la calidad de los contenidos, la ética editorial y la difusión internacional.

En América Latina, los sistemas regionales de información y de indexación han desempeñado un papel decisivo en la mejora de la calidad de las revistas de la región y en la visibilidad de la ciencia publicada en español y en portugués. No obstante, la indexación no es una garantía absoluta de calidad, y los investigadores deben aprender a evaluar críticamente las revistas más

allá de su presencia en una base de datos. Por otra parte, el fenómeno de las revistas depredadoras hace especialmente necesaria esta evaluación crítica.

La InterAcademy Partnership [IAP] (2022), una red mundial de academias de ciencias, publicó un informe sobre la lucha contra las revistas y conferencias académicas depredadoras en el que sostiene que estas prácticas constituyen una amenaza creciente para la integridad de la investigación y que deben entenderse como un espectro de comportamientos, que va desde las revistas abiertamente fraudulentas hasta publicaciones con prácticas editoriales de baja calidad.

Este tipo de revistas suele ofrecer una publicación rápida a cambio de un pago, sin un proceso real de revisión por pares, y sus artículos pueden contaminar la literatura científica con trabajos no evaluados. El informe recomienda acciones coordinadas de investigadores, instituciones, financiadores y editoriales para prevenir este fenómeno, entre ellas la formación de los investigadores para reconocer estas prácticas.

La inteligencia artificial puede contribuir a esta evaluación, por ejemplo, mediante herramientas que analizan las características de una revista, como la coherencia de su alcance, la composición de su comité editorial, los tiempos de revisión o la procedencia de sus artículos, para identificar señales de alerta. Sin embargo, la generalización de los modelos de lenguaje también facilita la producción masiva de manuscritos de baja calidad y la creación de revistas fraudulentas con apariencia profesional, lo que hace más difícil distinguir entre publicaciones legítimas y depredadoras. Los investigadores deben, por ello, desarrollar criterios propios de evaluación y consultar las fuentes confiables disponibles, como los sistemas de indexación reconocidos y las orientaciones de sus instituciones.

Paralelamente, la evaluación de la calidad editorial se relaciona también con el debate sobre la evaluación de la investigación. El Acuerdo sobre la Reforma de la Evaluación de la Investigación impulsado por CoARA (2022) propone abandonar los usos inapropiados de las métricas basadas en las revistas, como el factor de impacto, en la evaluación de los investigadores, y basar esa evaluación principalmente en el juicio cualitativo de la calidad y el impacto de su trabajo.

Esta orientación tiene implicaciones para la selección de revistas: si la evaluación se centra en la calidad intrínseca de los trabajos y no en el prestigio de la revista donde se publican, los investigadores pueden elegir con mayor libertad las publicaciones más adecuadas para su

público y su tema, incluidas las revistas regionales de calidad y las de acceso abierto sin costos para los autores.

Algunas preguntas sencillas pueden ayudar a los investigadores a evaluar una revista antes de enviar un manuscrito. Conviene preguntarse si la revista tiene un alcance claramente definido y coherente con su contenido publicado; si su comité editorial está integrado por especialistas reconocidos y verificables; si describe con claridad su proceso de revisión por pares y sus tiempos; si informa de manera transparente sobre sus costos de publicación; si está indexada en sistemas reconocidos y si esa indexación puede verificarse en las fuentes oficiales; y si los artículos que publica tienen una calidad acorde con lo que la revista declara. También resulta útil consultar a colegas con experiencia en el campo y revisar si otros investigadores reconocidos publican en ella.

Las respuestas a estas preguntas permiten distinguir con bastante seguridad entre las revistas serias y las que presentan señales de prácticas depredadoras, y constituyen una base más confiable para la decisión que las sugerencias automáticas basadas únicamente en la similitud temática. Los costos de publicación constituyen un aspecto adicional que los investigadores de la región deben considerar. Muchas revistas internacionales de acceso abierto cobran cargos por procesamiento de artículos que pueden resultar prohibitivos para investigadores sin financiamiento específico, lo que genera desigualdades en el acceso a la publicación.

Algunas editoriales ofrecen exenciones o descuentos para autores de países de ingresos bajos y medios, pero no siempre incluyen a todos los países latinoamericanos. Frente a esta situación, las revistas regionales de acceso abierto sin costos para los autores constituyen una alternativa valiosa, cuya calidad y visibilidad conviene fortalecer. Las universidades pueden, además, negociar acuerdos con editoriales o crear fondos institucionales que apoyen la publicación de sus investigadores en revistas de calidad. Sobre esta base, para los investigadores del Ecuador y de la región, la publicación científica inteligente implica combinar el uso de herramientas que facilitan la búsqueda y la evaluación de revistas con un conocimiento sólido de los criterios de calidad editorial y de las políticas de evaluación de sus instituciones.

Las universidades pueden apoyar este proceso mediante servicios de asesoría editorial, listas orientativas de revistas recomendadas, formación sobre las prácticas depredadoras y políticas de evaluación que valoren la calidad de los trabajos más que el lugar de publicación. Elegir bien dónde publicar no es solo una decisión individual, sino una contribución a la salud del

ecosistema científico, porque fortalece a las revistas que mantienen prácticas editoriales rigurosas y debilita a las que explotan la presión por publicar.

Figura 4.5

Publicación científica inteligente: selección de revistas, criterios de indexación y evaluación de calidad editorial.



Fuente: Elaboración autores

4.6 Ciencia abierta 5.0: repositorios inteligentes, datos FAIR y democratización del conocimiento científico

La ciencia abierta es un movimiento que busca hacer el conocimiento científico más accesible, transparente y colaborativo. Comprende el acceso abierto a las publicaciones, la apertura de los datos y del código de investigación, el uso de infraestructuras compartidas, la participación de la sociedad en los procesos científicos y el diálogo con otros sistemas de conocimiento. Sus defensores sostienen que una ciencia más abierta es también una ciencia de mayor calidad, porque facilita la verificación de los resultados, acelera la circulación de las ideas, evita la duplicación de esfuerzos y permite que el conocimiento financiado con recursos públicos beneficie al conjunto de la sociedad.

La incorporación de la inteligencia artificial abre una nueva etapa de este movimiento, a la que puede denominarse ciencia abierta 5.0, en la que los repositorios, los datos y las herramientas inteligentes se combinan para ampliar el acceso y la reutilización del conocimiento. Desde esta perspectiva, la Recomendación de la UNESCO sobre la ciencia abierta, adoptada por la Conferencia General en noviembre de 2021, constituye el primer marco normativo internacional en esta materia (UNESCO, 2021a).

El documento establece una definición común de la ciencia abierta, identifica sus valores y principios, como la calidad, la integridad, el beneficio colectivo, la equidad y la inclusión, y propone acciones para los Estados miembros en áreas como la promoción de una comprensión común de la ciencia abierta, el desarrollo de políticas, la inversión en infraestructuras y servicios, la formación de capacidades y el fomento de la colaboración internacional. La Recomendación pone especial énfasis en reducir las brechas entre países y regiones en el acceso a la ciencia y en la participación en su producción, lo que resulta particularmente relevante para América Latina.

Los principios FAIR constituyen una referencia fundamental para la gestión de los datos de investigación en la ciencia abierta. La Recomendación de la UNESCO sobre la ciencia abierta los adopta como referencia para los datos de investigación (UNESCO, 2021a). Según estos principios, los datos científicos deberían ser localizables, accesibles, interoperables y reutilizables, es decir, que deberían contar con identificadores persistentes y metadatos ricos que permitan encontrarlos, estar disponibles mediante protocolos estandarizados, utilizar vocabularios y formatos que permitan combinarlos con otros datos, y estar acompañados de información suficiente sobre su origen y sus condiciones de uso para que puedan reutilizarse.

Estos principios se han convertido en el estándar de referencia para la gestión de datos de investigación en todo el mundo. Un rasgo distintivo de estos principios es que están pensados tanto para las personas como para las máquinas, lo que los hace especialmente pertinentes en la era de la inteligencia artificial. De forma complementaria, esta pertinencia se explica porque la inteligencia artificial depende de los datos, y los datos gestionados según los principios FAIR son mucho más fáciles de utilizar para entrenar y evaluar modelos. H. Wang et al. (2023) señalan que la calidad deficiente de los datos y su gestión inadecuada constituyen uno de los principales obstáculos para el uso de la inteligencia artificial en la ciencia.

Los repositorios inteligentes, que incorporan herramientas de procesamiento del lenguaje natural y de aprendizaje automático, pueden contribuir a superar este obstáculo al facilitar la descripción automática de los datos, la detección de errores e inconsistencias, la vinculación entre conjuntos de datos relacionados y la recomendación de datos pertinentes para cada investigación. Del mismo modo, los motores de búsqueda inteligentes pueden mejorar la localización de publicaciones y datos en repositorios institucionales y regionales.

La ciencia abierta 5.0 plantea también desafíos específicos. La apertura de los datos debe equilibrarse con la protección de la privacidad de las personas y con los derechos de las comunidades sobre la información que les concierne. En el Ecuador, la Ley Orgánica de Protección de Datos Personales establece las condiciones en que pueden tratarse los datos personales, incluidos los utilizados con fines de investigación (Asamblea Nacional del Ecuador, 2021). Por otra parte, la disponibilidad de grandes volúmenes de datos y publicaciones abiertas facilita su uso para entrenar modelos comerciales de inteligencia artificial, lo que plantea preguntas sobre quién se beneficia del conocimiento producido con recursos públicos.

La Recomendación de la UNESCO (2021a) subraya, en este sentido, la importancia de que la ciencia abierta beneficie de manera equitativa a todos los países y comunidades. Vinculado con lo anterior, para América Latina, la ciencia abierta tiene una tradición propia y valiosa. La región desarrolló tempranamente sistemas de revistas de acceso abierto sin costos para los autores ni para los lectores, así como redes de repositorios institucionales, que han permitido una amplia circulación de la producción científica regional.

Este modelo, sostenido mayoritariamente por universidades y organismos públicos, contrasta con el de las grandes editoriales comerciales que cobran a los autores por publicar en acceso abierto. Fortalecer y modernizar estas infraestructuras regionales, incorporando herramientas inteligentes que mejoren su interoperabilidad y su visibilidad, constituye una estrategia coherente con los principios de la ciencia abierta y con los intereses de la región.

Esta tradición adquiere un valor especial en el contexto actual de la publicación científica. Durante décadas predominó un modelo de suscripción en el que las instituciones pagaban tarifas elevadas para acceder a la literatura, incluida la producida por sus propios investigadores. La expansión del acceso abierto corrigió en parte esa situación, pero dio lugar también a la difusión de un modelo comercial basado en cargos por procesamiento de artículos, que traslada el costo de la publicación a los autores y que puede excluir a quienes no disponen de financiamiento específico.

Frente a ese modelo, el acceso abierto sin costos para lectores ni para autores, que en la literatura internacional suele denominarse acceso abierto diamante, encuentra en plataformas regionales como SciELO y Redalyc algunas de sus expresiones más consolidadas. La inteligencia artificial puede contribuir a la sostenibilidad de estas revistas, por ejemplo, al reducir los costos de la

corrección, la traducción, la generación de metadatos o el marcado de los textos en formatos estándar de intercambio, siempre que su uso se supervise y no comprometa la calidad

Un plan de gestión de datos constituye la herramienta práctica que permite aplicar estos principios en cada proyecto de investigación. Se trata de un documento que describe qué datos se producirán, en qué formatos, cómo se documentarán, dónde se almacenarán durante el proyecto, cómo se protegerá la información personal o sensible, qué datos se compartirán al finalizar, en qué repositorio y bajo qué licencia.

Cada vez más organismos de financiamiento exigen este tipo de planes, y su elaboración obliga a los investigadores a pensar desde el inicio en la calidad y la reutilización de sus datos. Las herramientas de inteligencia artificial pueden facilitar su redacción y su seguimiento, pero las decisiones que contienen, especialmente las relativas a la protección de las personas y a las condiciones de apertura, requieren el juicio de los investigadores y, cuando corresponde, de los comités de ética.

Las universidades pueden apoyar a sus investigadores con plantillas, asesoría especializada y repositorios institucionales que cumplan los principios de localización, accesibilidad, interoperabilidad y reutilización. La apertura de los datos plantea, por otra parte, cuestiones específicas cuando se trata de información sobre pueblos indígenas o comunidades locales. Estos grupos tienen derechos sobre los datos que les conciernen, incluidos los relativos a sus territorios, sus conocimientos tradicionales y sus recursos genéticos, y su uso sin consentimiento puede reproducir relaciones históricas de despojo.

La Recomendación de la UNESCO sobre la ciencia abierta reconoce la necesidad de respetar estos derechos y de dialogar con otros sistemas de conocimiento (UNESCO, 2021a). En un país plurinacional como el Ecuador, los investigadores que trabajan con comunidades indígenas deberían acordar con ellas las condiciones de recolección, uso y apertura de los datos, de modo que la ciencia abierta no se convierta en una forma de apropiación de conocimientos ajenos. En concordancia con ello, las universidades ecuatorianas pueden contribuir a la ciencia abierta 5.0 mediante varias acciones.

Entre ellas se encuentran la adopción de políticas institucionales de acceso abierto y de gestión de datos, la creación o el fortalecimiento de repositorios que cumplan los principios FAIR, la formación de los investigadores en la elaboración de planes de gestión de datos y en el uso de

licencias abiertas, y la participación en redes regionales que compartan infraestructuras y servicios. La democratización del conocimiento científico no se logra solo abriendo el acceso a las publicaciones, sino también creando las condiciones para que más personas e instituciones puedan participar en la producción, la reutilización y el aprovechamiento de ese conocimiento.

Figura 4.6

Ciencia abierta 5.0: repositorios inteligentes, datos FAIR y democratización del conocimiento científico.



Fuente: Elaboración autores

4.7 Visibilidad e impacto científico en ecosistemas digitales: bibliometría, altmetría y estrategias de difusión académica

La publicación de un artículo no garantiza que sea leído, utilizado o citado. En un contexto en el que se publican millones de trabajos científicos cada año, la visibilidad se ha convertido en un desafío para los investigadores, especialmente para quienes trabajan en países con menor presencia en la ciencia internacional o publican en idiomas distintos del inglés. La visibilidad depende de factores como la indexación de las revistas en bases de datos reconocidas, el acceso abierto a los trabajos, la calidad de los metadatos que permiten encontrarlos, la participación de los autores en redes académicas y la difusión de los resultados en espacios digitales.

El impacto, por su parte, alude a la influencia que un trabajo ejerce sobre la investigación posterior, la práctica profesional, las políticas públicas o la sociedad en general. A ello se suma que la bibliometría ofrece las herramientas tradicionales para medir la visibilidad y el impacto académico. Como se expuso en el capítulo 3, Donthu et al. (2021) describen el análisis de

desempeño, que examina las contribuciones de autores, instituciones, países y revistas mediante indicadores de producción y de citación, y el mapeo científico, que analiza las relaciones entre ellos mediante técnicas como la cocitación, el acoplamiento bibliográfico, la coocurrencia de palabras y la coautoría.

Estas técnicas permiten a los investigadores conocer cómo es citado su trabajo, quiénes lo utilizan y en qué temas se inserta, información útil para orientar sus estrategias de difusión. Sin embargo, los indicadores de citación tardan años en acumularse, varían mucho entre disciplinas y reflejan solo una parte del impacto de la investigación, la que se produce dentro de la propia comunidad académica.

La altmetría surgió para complementar estas limitaciones. Se trata de un conjunto de indicadores que miden la atención que reciben los trabajos científicos en espacios digitales distintos de las citas académicas: menciones en redes sociales, en blogs, en medios de comunicación, en documentos de política pública, en enciclopedias en línea o en gestores de referencias. Estos indicadores tienen la ventaja de acumularse rápidamente después de la publicación y de captar formas de impacto que la bibliometría tradicional ignora, como la difusión de un trabajo entre profesionales, periodistas o responsables de políticas. Sin embargo, la atención en redes sociales no equivale necesariamente a calidad ni a influencia real, ya que puede reflejar la controversia o la novedad de un tema más que el valor de la investigación, y puede manipularse con relativa facilidad.

Asimismo, el uso responsable de todos estos indicadores constituye una preocupación creciente en la comunidad científica. El Acuerdo sobre la Reforma de la Evaluación de la Investigación promovido por CoARA (2022) propone basar la evaluación principalmente en el juicio cualitativo, con la revisión por pares como elemento central, y utilizar los indicadores cuantitativos de manera responsable, como apoyo y no como sustituto de ese juicio. El acuerdo plantea también reconocer la diversidad de contribuciones a la investigación, incluidas aquellas que no se reflejan en publicaciones o citas, como la formación de investigadores, el desarrollo de datos y programas, la ciencia abierta o la vinculación con la sociedad.

La advertencia alcanza también a la propia inteligencia artificial: las herramientas pueden ayudar a reunir de manera transparente evidencia diversa sobre las contribuciones de un investigador, como publicaciones, datos abiertos, programas informáticos o actividades de divulgación, pero no deberían sustituir el juicio de los comités de evaluación. Esta orientación invita a los

investigadores a pensar la visibilidad y el impacto de manera más amplia, sin limitarse a la búsqueda de citas.

La inteligencia artificial ofrece nuevas posibilidades para las estrategias de difusión académica. Las herramientas de procesamiento del lenguaje pueden ayudar a redactar resúmenes divulgativos de los trabajos para públicos no especializados, a adaptar los contenidos para distintos formatos y plataformas, a traducir los resultados a otros idiomas y a identificar los públicos y los espacios más pertinentes para cada investigación.

Los sistemas de análisis de datos pueden mostrar a los investigadores dónde se discute su trabajo y quiénes lo utilizan, lo que les permite establecer diálogos con esos públicos. Estas posibilidades deben utilizarse, no obstante, con los mismos criterios de integridad que el resto de la actividad científica: los resúmenes divulgativos deben ser fieles a los resultados, sin exagerar su alcance, y el uso de las herramientas debe declararse cuando corresponda. No obstante, para la ciencia latinoamericana, la visibilidad presenta desafíos y oportunidades específicos. Según la RICYT (2025), la producción científica indexada creció en casi todos los países de la región entre 2014 y 2023, con incrementos relativos destacados en el Ecuador.

Este crecimiento ofrece una base para ampliar la visibilidad de la ciencia regional, pero exige estrategias que aprovechen las fortalezas propias, como la tradición de acceso abierto de las revistas y los repositorios latinoamericanos, y que aborden las debilidades, como la menor presencia en las bases de datos internacionales o la escasa difusión de los resultados fuera del ámbito académico. Las herramientas de inteligencia artificial pueden contribuir a superar barreras lingüísticas y a llegar a nuevos públicos, siempre que se utilicen para comunicar mejor una investigación sólida y no para sustituir la calidad por la visibilidad.

Los identificadores persistentes desempeñan un papel discreto pero decisivo en la visibilidad de la investigación. El identificador digital de objetos permite localizar de manera estable cada publicación o conjunto de datos, mientras que los identificadores de autor permiten distinguir a investigadores con nombres similares y reunir en un solo perfil toda su producción, un aspecto especialmente importante en la región, donde los apellidos compuestos y las variaciones en la forma de escribir los nombres dificultan la correcta atribución de los trabajos.

Del mismo modo, los metadatos completos, en varios idiomas, mejoran la probabilidad de que los motores de búsqueda académica y las herramientas de inteligencia artificial encuentren y recomienden los trabajos. Las universidades pueden promover que todos sus investigadores

cuenten con identificadores de autor actualizados y que sus repositorios asignen identificadores persistentes a las publicaciones y a los datos. Estas prácticas, de bajo costo, contribuyen a que la producción científica de la institución sea visible, se atribuya correctamente y pueda ser analizada mediante las herramientas bibliométricas.

La visibilidad de la investigación tiene también una dimensión ética que conviene no olvidar. La presión por aumentar los indicadores de impacto puede conducir a prácticas cuestionables, como la autocitación excesiva, los acuerdos de citación recíproca entre grupos o la fragmentación de los resultados en múltiples publicaciones para multiplicar su número. Estas prácticas distorsionan los indicadores y dañan la credibilidad de la ciencia.

Las herramientas de inteligencia artificial podrían facilitarlas, por ejemplo, al producir rápidamente variaciones de un mismo trabajo. Por ello, la búsqueda de visibilidad debe guiarse por la integridad, es decir, por el deseo de que el conocimiento llegue a quienes pueden utilizarlo, y no por la manipulación de las métricas. Las instituciones contribuyen a este objetivo cuando evalúan a sus investigadores con criterios cualitativos y no premian el crecimiento artificial de los indicadores. Además, una estrategia de difusión académica coherente con la Investigación 5.0 podría articular varios elementos.

Figura 4.7

Visibilidad e impacto científico en ecosistemas digitales: bibliometría, altmetría y estrategias de difusión académica.



Fuente: Elaboración autores

Entre ellos se cuentan la publicación en acceso abierto y el depósito de los trabajos en repositorios institucionales, la elaboración de metadatos completos y de identificadores persistentes para autores y publicaciones, la difusión de resúmenes divulgativos en espacios digitales pertinentes, el diálogo con los públicos interesados en los resultados y el seguimiento de indicadores bibliométricos y altmétricos como información complementaria, no como fin en sí mismos.

Las universidades pueden apoyar esta estrategia mediante oficinas de comunicación científica, formación en difusión académica y políticas de evaluación que reconozcan el impacto social de la investigación. La visibilidad, entendida de este modo, no es una competencia por la atención, sino una forma de asegurar que el conocimiento producido llegue a quienes pueden utilizarlo.

4.8 Nuevos formatos de comunicación científica: artículos interactivos, visualización dinámica de resultados y divulgación multimodal

El artículo científico impreso, con su texto lineal, sus tablas y sus figuras estáticas, ha sido durante siglos el formato principal de la comunicación científica. Aunque la mayoría de las revistas se publica hoy en formato digital, muchas de ellas conservan las características esenciales del artículo impreso, como si la pantalla fuera simplemente una página de papel. Sin embargo, las tecnologías digitales y la inteligencia artificial permiten concebir formatos que aprovechan mejor las posibilidades del medio digital, como artículos que integran datos y código ejecutable, visualizaciones que el lector puede explorar, contenidos adaptados a distintos públicos y formatos multimodales que combinan texto, imagen, audio y video.

Estos nuevos formatos pueden mejorar la comprensión, la transparencia y el alcance de la comunicación científica. En esta misma línea, los artículos interactivos constituyen una de las innovaciones más prometedoras. En lugar de presentar los resultados como un conjunto fijo de tablas y figuras, estos artículos permiten al lector explorar los datos, modificar los parámetros de los análisis y observar cómo cambian los resultados, o ejecutar el código que produjo cada figura. Esta interactividad tiene un doble valor.

Por un lado, facilita la comprensión, porque el lector puede examinar los resultados desde distintas perspectivas; por otro, refuerza la transparencia y la reproducibilidad, porque los datos y los procedimientos quedan expuestos al escrutinio. Esta orientación es coherente con la Recomendación de la UNESCO sobre la ciencia abierta, que promueve la apertura de los datos, del código y de los procesos de investigación como medio para mejorar la calidad y la confiabilidad de la ciencia (UNESCO, 2021a).

La visualización dinámica de resultados amplía estas posibilidades. Los gráficos interactivos permiten mostrar datos complejos de manera más comprensible, por ejemplo, mediante mapas que el lector puede ampliar para observar regiones específicas, series temporales que pueden filtrarse por categorías o redes que pueden explorarse nodo por nodo.

Las herramientas de inteligencia artificial pueden facilitar la creación de estas visualizaciones, al sugerir los tipos de gráficos más adecuados para cada conjunto de datos o al generar automáticamente versiones interactivas a partir de los datos de una investigación. No obstante, la visualización también puede inducir a error cuando se eligen escalas, colores o formas que exageran o minimizan las diferencias, por lo que su diseño exige los mismos criterios de honestidad que la presentación de cualquier otro resultado. Un mismo trabajo puede dar lugar a un artículo técnico para especialistas, un resumen en lenguaje sencillo para el público general, una infografía para redes sociales, un video breve que explique los hallazgos principales o un podcast en el que los autores discutan su investigación.

Las herramientas de inteligencia artificial generativa pueden facilitar la producción de estos contenidos, al ayudar a redactar resúmenes en distintos niveles de complejidad, a traducirlos a otros idiomas o a generar borradores de guiones e infografías. Miao y Holmes (2023), en la guía de la UNESCO sobre la inteligencia artificial generativa, reconocen el potencial de estas herramientas para apoyar la creación de contenidos, pero advierten sobre la necesidad de verificar su exactitud y de mantener un enfoque centrado en las personas.

Estos nuevos formatos plantean, sin embargo, desafíos que conviene considerar. Uno de ellos es la preservación: un artículo interactivo depende de programas y plataformas que pueden dejar de funcionar con el tiempo, mientras que un texto impreso puede leerse siglos después de su publicación. Para que los nuevos formatos sean sostenibles, es necesario que los datos y el código se depositen en repositorios estables, con identificadores persistentes y documentación suficiente, siguiendo los principios de gestión de datos localizables, accesibles, interoperables y reutilizables, conocidos como principios FAIR.

Otro desafío es la evaluación, porque los sistemas de evaluación académica siguen valorando principalmente los artículos tradicionales, de modo que los investigadores tienen pocos incentivos para invertir tiempo en formatos innovadores o en actividades de divulgación. Con todo, la divulgación asistida por inteligencia artificial plantea, además, un riesgo de distorsión. Cuando se pide a un modelo de lenguaje que resuma un trabajo para el público general, puede

simplificar en exceso, omitir las limitaciones o presentar como establecidos resultados que son preliminares. La experiencia muestra que estos modelos pueden producir textos convincentes y bien redactados que contienen afirmaciones inexactas (Walters y Wilder, 2023), y en la divulgación estas inexactitudes pueden llegar a un público amplio que no tiene medios para detectarlas. Por ello, los contenidos divulgativos generados con ayuda de estas herramientas deben ser revisados cuidadosamente por los autores de la investigación, que son quienes conocen sus alcances y limitaciones.

Algunas experiencias recientes muestran cómo estos formatos pueden enriquecer la comunicación científica en la región. Las revistas y repositorios latinoamericanos han comenzado a publicar datos asociados a los artículos, resúmenes en varios idiomas y contenidos complementarios en formatos multimedia, y algunas universidades han desarrollado programas de divulgación que transforman los resultados de sus investigaciones en podcasts, videos o exposiciones.

La inteligencia artificial puede facilitar la expansión de estas iniciativas, por ejemplo, al generar subtítulos y traducciones, al adaptar los textos a distintos niveles de lectura o al producir borradores de guiones que los investigadores revisan y completan. En un país diverso como el Ecuador, estas herramientas podrían incluso apoyar la comunicación de resultados en lenguas indígenas, en colaboración con hablantes y organizaciones de esas comunidades, lo que contribuiría a una ciencia más inclusiva.

Para que estas iniciativas sean sostenibles, conviene que las instituciones las reconozcan en sus sistemas de evaluación y las doten de recursos estables. Los contenidos multimodales pueden facilitar el acceso al conocimiento de personas con distintas capacidades, por ejemplo, mediante audios para personas con discapacidad visual, subtítulos para personas sordas o textos en lectura fácil para personas con dificultades de comprensión lectora. Las universidades podrían adoptar criterios de accesibilidad para sus publicaciones y contenidos de divulgación, de modo que el conocimiento que producen llegue efectivamente a toda la sociedad, en coherencia con los principios de equidad e inclusión que orientan la ciencia abierta.

Por otra parte, para las universidades y los investigadores de América Latina, los nuevos formatos de comunicación científica ofrecen oportunidades significativas. Pueden contribuir a superar las barreras lingüísticas que limitan la visibilidad internacional de la ciencia regional, a acercar la investigación a las comunidades que podrían beneficiarse de ella y a fortalecer la confianza pública en la ciencia. Para aprovechar estas oportunidades, las instituciones podrían

apoyar la creación de contenidos multimodales mediante unidades especializadas en comunicación científica que reúnan a investigadores, periodistas y diseñadores, formar a los investigadores en el uso responsable de las herramientas de creación de contenidos y reconocer las actividades de divulgación en sus sistemas de evaluación.

Figura 4.8

Nuevos formatos de comunicación científica: artículos interactivos, visualización dinámica de resultados y divulgación multimodal.



Fuente: Elaboración autores

EDITORIAL ANDES COGNITIO

CAPÍTULO V

ÉTICA, GOBERNANZA Y FUTURO DE LA INVESTIGACIÓN 5.0: HACIA UNA CIENCIA RESPONSABLE, AUTÓNOMA Y SOSTENIBLE



CAPÍTULO V

ÉTICA, GOBERNANZA Y FUTURO DE LA INVESTIGACIÓN 5.0: HACIA UNA CIENCIA RESPONSABLE, AUTÓNOMA Y SOSTENIBLE

5.1 Ética científica 5.0: integridad académica, transparencia y responsabilidad en la utilización de inteligencia artificial

La ética científica se ha construido históricamente sobre un conjunto de valores que la comunidad considera indispensables para que la ciencia cumpla su función: la honestidad en la obtención y presentación de los datos, el rigor en la aplicación de los métodos, la transparencia sobre los procedimientos y los conflictos de interés, el respeto por las personas que participan en la investigación, el reconocimiento adecuado del trabajo de otros y la responsabilidad por las consecuencias del conocimiento producido. Las faltas más graves a esta ética, como la fabricación de datos, la falsificación de resultados y el plagio, han sido objeto de normas institucionales y de sanciones.

La incorporación de la inteligencia artificial a la investigación no altera estos valores, pero plantea nuevas formas de cumplirlos y de vulnerarlos, lo que justifica hablar de una ética científica 5.0 que los actualiza para el nuevo contexto. Paralelamente, la integridad académica constituye el primer pilar de esta ética. Lund et al. (2023), al analizar las implicaciones éticas de los modelos de lenguaje en la publicación académica, señalaron que su uso plantea problemas de transparencia, de atribución y de integridad que requieren normas claras. Los riesgos son diversos.

Un investigador puede presentar como propio un texto sustancialmente generado por una máquina, utilizar herramientas que fabrican referencias o datos, recurrir a estos sistemas para producir revisiones de literatura sin leer las fuentes, o emplearlos para evadir los mecanismos de detección de plagio. Como se vio en el capítulo 4, C. A. Gao et al. (2023) mostraron que los resúmenes científicos generados por un modelo de lenguaje obtenían puntuaciones bajas en los programas de detección de plagio y que los revisores humanos no siempre lograban identificarlos, lo que evidencia que los mecanismos tradicionales de control resultan insuficientes y que la integridad depende, más que nunca, del compromiso ético de los propios investigadores.

La transparencia constituye el segundo pilar y, probablemente, el principio más consensuado en las normas que han surgido en los últimos años. El Committee on Publication Ethics estableció que los autores que utilicen herramientas de inteligencia artificial en la redacción, en la producción de imágenes o en la recopilación y el análisis de datos deben declararlo de forma transparente, indicando qué herramienta utilizaron y cómo (COPE, 2023).

Las directrices de la Comisión Europea (2024) sobre el uso responsable de la inteligencia artificial generativa en la investigación insisten igualmente en que los investigadores deben utilizar estas herramientas de manera transparente y detallar su uso cuando resulte sustancial. La transparencia permite a los lectores, a los evaluadores y a la comunidad científica valorar adecuadamente un trabajo, y protege a los propios investigadores frente a sospechas de mala conducta. Sobre esta base, la responsabilidad constituye el tercer pilar.

Todas las normas recientes coinciden en que la responsabilidad por el contenido de un trabajo científico recae exclusivamente en las personas que lo firman, aunque hayan utilizado herramientas de inteligencia artificial en su elaboración. Las directrices de la Comisión Europea (2024) establecen que los investigadores siguen siendo los responsables últimos de los resultados científicos, y el COPE (2023) señala que los autores son plenamente responsables del contenido de sus manuscritos, incluidas las partes producidas por la herramienta.

Este principio tiene una consecuencia práctica importante, porque obliga a verificar todo lo que se incorpora a un trabajo, ya que el error de una máquina se convierte en el error del autor que lo publica. La Recomendación de la UNESCO sobre la ética de la inteligencia artificial establece, en un plano más general, que la responsabilidad y la rendición de cuentas por las decisiones y acciones basadas en sistemas de inteligencia artificial deben atribuirse siempre a personas físicas o jurídicas (UNESCO, 2021b).

A estos tres pilares se suman otros principios relevantes. El respeto por la privacidad de los participantes exige no introducir datos personales en herramientas que no garanticen su protección, conforme a la normativa vigente, como la Ley Orgánica de Protección de Datos Personales en el Ecuador (Asamblea Nacional del Ecuador, 2021). La confidencialidad obliga a no cargar manuscritos en revisión, propuestas de investigación o datos inéditos en plataformas externas.

La equidad exige considerar cómo los sesgos de las herramientas pueden afectar a ciertos grupos o perspectivas. Y la proporcionalidad invita a utilizar estas herramientas solo cuando aportan un beneficio real, evaluando sus costos y riesgos. Miao y Holmes (2023), en la guía de la

UNESCO sobre la inteligencia artificial generativa en la educación y la investigación, proponen precisamente un enfoque centrado en las personas, en el que la adopción de estas herramientas se evalúa a la luz de sus efectos sobre los derechos y el bienestar de quienes participan.

Desde esta perspectiva, la ética científica 5.0 no puede depender únicamente de la conciencia individual de los investigadores; requiere también un marco institucional que la sostenga. Las universidades y los centros de investigación deberían adoptar políticas explícitas sobre el uso de la inteligencia artificial en la investigación, que definan los usos aceptables, las formas de declararlos y los procedimientos ante posibles faltas.

Los comités de ética de la investigación deberían incorporar en sus evaluaciones preguntas sobre el uso de estas herramientas, especialmente cuando involucran datos de personas. Y los programas de formación deberían incluir la reflexión ética como un componente central, no como un añadido. En las instituciones ecuatorianas, estas políticas pueden articularse con las normas que regulan la investigación en la educación superior y con la normativa de protección de datos.

La ética científica 5.0 puede concretarse en un conjunto de preguntas que cada investigador debería formularse antes de utilizar una herramienta de inteligencia artificial en su trabajo. Ante todo, cabe preguntarse si el uso de la herramienta es compatible con las normas de la institución, de la revista o del organismo de financiamiento. Es necesario establecer también si la información que se introducirá en la herramienta incluye datos personales, confidenciales o inéditos y, en caso afirmativo, si la herramienta ofrece garantías adecuadas para protegerlos.

Otra cuestión es si se podrá verificar la exactitud de lo que la herramienta produzca antes de incorporarlo al trabajo. Hay que considerar además si el uso de la herramienta podría introducir sesgos que afecten los resultados o a determinados grupos. Y, por último, cabe preguntarse cómo se declarará este uso en la publicación o en el informe. Responder a estas preguntas no requiere conocimientos técnicos avanzados, sino una actitud reflexiva que puede cultivarse en la formación y en la práctica cotidiana de la investigación.

Las instituciones pueden facilitar esta reflexión mediante guías breves, ejemplos de buenas prácticas y espacios de consulta para los investigadores que enfrentan situaciones dudosas. La ética científica 5.0 debe considerar, asimismo, la relación de poder entre docentes y estudiantes en el uso de estas herramientas. Cuando los estudiantes perciben que se les exige una

producción académica que solo pueden alcanzar con ayuda de la inteligencia artificial, o cuando las normas sobre su uso son ambiguas o se aplican de manera arbitraria, se generan situaciones de incertidumbre que pueden conducir a faltas de integridad.

Por ello, las normas deben ser claras, conocidas por todos y aplicadas de manera consistente, y los docentes deben dar ejemplo de un uso transparente de las herramientas en su propio trabajo. Una cultura de integridad no se construye solo con sanciones, sino también con confianza, diálogo y coherencia entre lo que se exige y lo que se practica. La ética científica 5.0 ofrece, en último término, una oportunidad para renovar el compromiso de la comunidad científica con sus propios valores.

La facilidad con que las herramientas de inteligencia artificial permiten producir textos, datos e imágenes convincentes hace más visible algo que siempre fue cierto: la confianza en la ciencia no se basa en la apariencia de los resultados, sino en la integridad de los procesos que los producen. Investigar con integridad, declarar con transparencia el uso de las herramientas y asumir plenamente la responsabilidad por lo que se publica son, en la era de la inteligencia artificial, las condiciones para que la ciencia conserve la confianza de la sociedad.

Figura 5.1

Ética científica 5.0: integridad académica, transparencia y responsabilidad en la utilización de inteligencia artificial.



Fuente: Elaboración autores

5.2 Autoría, propiedad intelectual y reconocimiento de contribuciones humanas en investigaciones asistidas por sistemas inteligentes

La autoría de un trabajo científico cumple funciones que van más allá de la simple identificación de quienes lo escribieron. Reconoce el mérito intelectual de quienes concibieron la investigación, la ejecutaron e interpretaron sus resultados; asigna la responsabilidad por la exactitud y la integridad del trabajo; y constituye la base de los sistemas de evaluación académica, que determinan contrataciones, promociones y financiamiento. Por esta razón, las normas sobre autoría han sido objeto de una atención cuidadosa por parte de las organizaciones de ética editorial, que han establecido criterios para determinar quién merece figurar como autor y cómo deben reconocerse otras contribuciones.

La participación de sistemas inteligentes en la investigación obliga a revisar estos criterios a la luz de una situación inédita, en la que una parte del trabajo puede ser realizada por herramientas que no son personas. Vinculado con lo anterior, la respuesta de la comunidad científica a la pregunta de si una herramienta de inteligencia artificial puede ser autora ha sido negativa y consistente. Como se expuso en los capítulos 2 y 4, el Committee on Publication Ethics estableció que estas herramientas no pueden figurar como autoras porque no pueden asumir la responsabilidad por el trabajo enviado, y porque, al no ser entidades jurídicas, no pueden declarar conflictos de interés ni gestionar los derechos de autor y las licencias (COPE, 2023).

Thorp (2023), editor de Science, expresó una posición coincidente al señalar que un programa no puede ser autor de un trabajo científico. Lund et al. (2023), al analizar las implicaciones éticas de los modelos de lenguaje para la publicación académica, coincidieron en que la autoría implica responsabilidad y capacidad de rendir cuentas, atributos que estas herramientas no poseen.

Este consenso no resuelve, sin embargo, todas las cuestiones relacionadas con el reconocimiento de las contribuciones. Si una herramienta no puede ser autora, su participación debe declararse de alguna otra manera, por lo general en la sección de métodos o en los agradecimientos, indicando qué herramienta se utilizó y para qué tareas (COPE, 2023). Esta declaración permite a los lectores evaluar el trabajo con conocimiento de causa y protege la integridad del proceso.

Al mismo tiempo, la automatización de ciertas tareas puede invisibilizar las contribuciones de personas que antes recibían reconocimiento, como los asistentes de investigación, los técnicos de laboratorio, los analistas de datos o los traductores. Una ética del reconocimiento en la era de la inteligencia artificial debería cuidar que la incorporación de herramientas no desplace el reconocimiento debido a las personas que siguen contribuyendo al trabajo científico.

En concordancia con ello, el Acuerdo sobre la Reforma de la Evaluación de la Investigación aporta una perspectiva relevante para esta cuestión. CoARA (2022) propone reconocer la diversidad de contribuciones a la investigación y de las trayectorias académicas, incluidas aquellas que no se reflejan en la autoría de publicaciones, como el desarrollo de datos, de programas informáticos, de infraestructuras o de metodologías, la formación de investigadores y la vinculación con la sociedad. En un contexto en el que las herramientas automatizan parte de la producción de textos, el reconocimiento de estas otras contribuciones adquiere mayor importancia, porque permite valorar el trabajo intelectual y técnico que sostiene la investigación más allá de la redacción de artículos.

La propiedad intelectual constituye el otro gran ámbito de esta discusión. En el Ecuador, como en la mayoría de los países, la legislación sobre derechos de autor, propiedad industrial y otras formas de protección de las creaciones intelectuales se elaboró sobre la premisa de que las obras protegidas son creaciones humanas, por lo que la protección de los resultados generados con ayuda de sistemas de inteligencia artificial plantea preguntas que la norma no resuelve explícitamente.

Entre ellas se cuentan quién es el titular de los derechos sobre un texto, una imagen o un diseño producido con ayuda de una herramienta generativa, en qué medida la intervención humana es suficiente para que el resultado se considere una obra protegida y si el uso de obras protegidas para entrenar los modelos es compatible con los derechos de sus autores. A ello se suma que estas preguntas tienen consecuencias prácticas para la investigación universitaria. Los resultados de la investigación pueden dar lugar a patentes, a programas informáticos, a obras publicadas o a otros productos susceptibles de protección, cuya titularidad suele regularse en las normas internas de las universidades y en los contratos con los financiadores.

Cuando en la generación de esos resultados han intervenido herramientas de inteligencia artificial, conviene documentar con precisión la contribución humana, que es la que fundamenta la protección, y revisar las condiciones de uso de las herramientas, porque algunas plataformas

establecen cláusulas sobre los derechos de los contenidos generados o sobre el uso de la información introducida por los usuarios. Las universidades deberían actualizar sus normas de propiedad intelectual para abordar estas situaciones y orientar a sus investigadores.

En la práctica, las universidades pueden adoptar algunas medidas sencillas para proteger la autoría y el reconocimiento en las investigaciones asistidas por inteligencia artificial. Una de ellas consiste en incluir en los acuerdos de los equipos de investigación criterios explícitos de autoría, que definan desde el inicio qué contribuciones justifican figurar como autor y cómo se reconocerán las demás. Otra consiste en exigir, en las tesis y trabajos de titulación, una declaración sobre el uso de herramientas de inteligencia artificial, firmada por el estudiante y validada por el director. Una tercera medida es la adopción de taxonomías de contribuciones que permiten describir con precisión el papel de cada participante en un trabajo, como la conceptualización, la metodología, el análisis de datos, la redacción o la supervisión.

Estas medidas contribuyen a que la autoría refleje con fidelidad el trabajo realizado y a que la participación de las herramientas quede registrada sin desplazar el reconocimiento debido a las personas, lo cual resulta especialmente importante en la formación de los jóvenes investigadores. La cuestión de los datos utilizados para entrenar los modelos generativos merece, por otra parte, una reflexión específica desde la perspectiva de los investigadores. Muchos de estos modelos se han entrenado con textos y publicaciones científicas, incluidos trabajos protegidos por derechos de autor, sin el consentimiento explícito de sus autores.

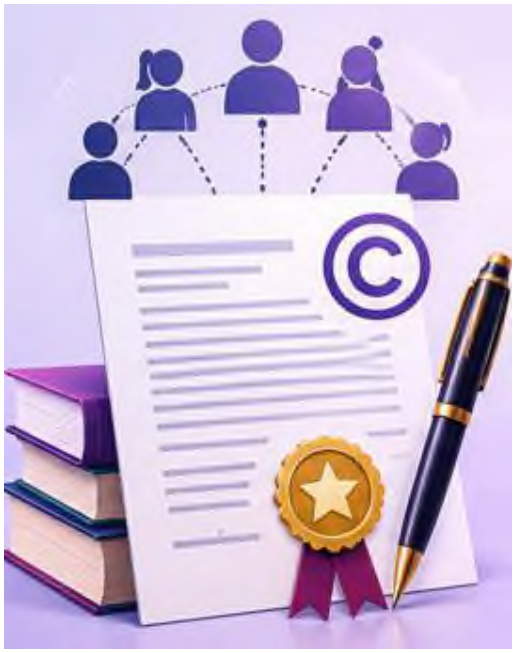
Esta situación ha generado debates y litigios en distintos países sobre si este uso es compatible con los derechos de los creadores. Para los investigadores, plantea la pregunta de en qué condiciones están dispuestos a que sus publicaciones y sus datos se utilicen para entrenar modelos comerciales. Las licencias abiertas que se aplican a las publicaciones y los datos pueden especificar estas condiciones, y las universidades podrían orientar a sus investigadores sobre las implicaciones de cada tipo de licencia en este nuevo contexto.

Asimismo, el reconocimiento de las contribuciones humanas constituye, al fin y al cabo, una cuestión de justicia y de integridad. En la era de la inteligencia artificial, la autoría sigue correspondiendo a las personas que conciben, dirigen, interpretan y asumen la responsabilidad por una investigación, y la propiedad intelectual sigue protegiendo la creatividad humana. Declarar con transparencia la participación de las herramientas, reconocer adecuadamente el trabajo de todas las personas que contribuyen y documentar la contribución humana a los

resultados son prácticas que permiten preservar estos principios. Para las universidades latinoamericanas, adoptar normas claras sobre estos aspectos es una forma de proteger tanto a sus investigadores como la credibilidad de la ciencia que producen.

Figura 5.2

Autoría, propiedad intelectual y reconocimiento de contribuciones humanas en investigaciones asistidas por sistemas inteligentes.



Fuente: Elaboración autores

5.3 Sesgos algorítmicos, fabricación de información y riesgos de desinformación en la producción científica

La ciencia ha desarrollado a lo largo de su historia mecanismos para protegerse de los errores y de las distorsiones: la revisión por pares, la replicación de los estudios, la crítica pública, las normas de integridad y los controles institucionales. Estos mecanismos nunca han sido perfectos, como lo muestran los casos de fraude o los estudios que no han podido replicarse, pero han permitido que la ciencia corrija sus errores con el tiempo. La incorporación de la inteligencia artificial introduce nuevas fuentes de error y de distorsión que ponen a prueba estos mecanismos.

Entre ellas destacan los sesgos algorítmicos, que pueden distorsionar los resultados de los análisis; la fabricación de información por parte de los modelos generativos, que puede introducir datos o referencias falsas en los trabajos; y la producción masiva de contenidos de apariencia

científica, que puede contribuir a la desinformación. Además, los sesgos algorítmicos se originan en múltiples fuentes. Mehrabi et al. (2021), en una revisión exhaustiva sobre el sesgo y la equidad en el aprendizaje automático, distinguen entre sesgos que provienen de los datos, como la subrepresentación de ciertos grupos o la medición desigual de las variables; sesgos que provienen de los algoritmos y de las decisiones de diseño; y sesgos que surgen de la interacción entre los sistemas y los usuarios.

En la investigación científica, estos sesgos pueden conducir a resultados que no se generalizan a ciertas poblaciones, a la invisibilización de determinados problemas o a la reproducción de desigualdades existentes. Un modelo de diagnóstico entrenado principalmente con datos de pacientes de un grupo poblacional puede tener un desempeño inferior en otros grupos, y un sistema de búsqueda bibliográfica que privilegia las publicaciones en inglés puede ignorar la investigación producida en otras lenguas.

Bender et al. (2021) advirtieron sobre los riesgos específicos de los modelos de lenguaje de gran escala, entrenados con enormes volúmenes de textos de internet. Señalaron que estos datos reflejan de manera desproporcionada las perspectivas de los grupos con mayor presencia en internet, que pueden contener sesgos y estereotipos, y que el tamaño de los conjuntos de datos dificulta su documentación y su revisión.

Los autores advirtieron también que la fluidez de los textos generados puede llevar a los usuarios a atribuir a estos sistemas una comprensión que no poseen, lo que aumenta el riesgo de que sus errores pasen inadvertidos. En la producción científica, esto significa que los textos generados pueden reproducir sesgos de manera sutil, por ejemplo, al presentar ciertas perspectivas teóricas como dominantes o al ignorar los aportes de determinadas regiones. Ahora bien, la fabricación de información constituye un riesgo particularmente grave.

Los modelos generativos pueden producir afirmaciones falsas con total apariencia de verosimilitud, un fenómeno que suele denominarse alucinación. En el ámbito científico, la forma más documentada de este fenómeno es la fabricación de referencias bibliográficas. Walters y Wilder (2023) encontraron que más de la mitad de las referencias generadas por una versión de un asistente conversacional y casi una de cada cinco de las generadas por una versión más reciente correspondían a trabajos inexistentes, y que una proporción importante de las referencias reales contenía errores sustanciales.

Más allá de las referencias, los modelos pueden fabricar datos, resultados de estudios, citas textuales o descripciones de métodos, y presentarlos de manera convincente. Un investigador que no verifica cuidadosamente lo que producen estas herramientas puede incorporar a su trabajo información falsa sin saberlo.

La capacidad de producir contenidos de apariencia científica a gran escala plantea, además, riesgos para el conjunto del sistema de comunicación científica. C. A. Gao et al. (2023) mostraron que los resúmenes científicos generados por un modelo de lenguaje podían engañar a revisores expertos en una proporción considerable de los casos. Si estas herramientas se utilizan para producir masivamente manuscritos fraudulentos, por ejemplo, en las llamadas fábricas de artículos que venden autorías, o para alimentar revistas depredadoras, la literatura científica podría contaminarse con trabajos falsos difíciles de detectar.

Del mismo modo, los contenidos pseudocientíficos generados automáticamente pueden difundirse en redes sociales y contribuir a la desinformación sobre temas de salud, ambiente o tecnología, con consecuencias para la confianza pública en la ciencia. No obstante, frente a estos riesgos, la comunidad científica dispone de varias líneas de respuesta. En el plano individual, la verificación sistemática de toda información generada por herramientas de inteligencia artificial, la evaluación del desempeño de los modelos en distintos grupos de la población y la declaración transparente de su uso constituyen las primeras salvaguardas.

En el plano metodológico, las prácticas que favorecen la reproducibilidad, como la publicación de los datos y del código, y las que previenen errores, como las fichas de información de las modelos propuestas por Kapoor y Narayanan (2023), reducen la probabilidad de que los resultados sesgados o erróneos pasen inadvertidos. En el plano editorial, las revistas pueden incorporar verificaciones de las referencias y de la integridad de los datos, y exigir declaraciones sobre el uso de herramientas inteligentes. Y en el plano institucional, las universidades pueden formar a sus investigadores y establecer procedimientos para investigar y sancionar las faltas.

Los riesgos de desinformación exigen también una reflexión sobre el papel de los investigadores en el espacio público. Cuando circulan en redes sociales contenidos pseudocientíficos generados automáticamente, los investigadores y las instituciones científicas pueden contribuir a contrarrestarlos mediante la comunicación clara de la evidencia disponible, la explicación de los métodos que permiten distinguir entre afirmaciones fundadas e infundadas y la colaboración con periodistas y verificadores de información. Esta tarea requiere competencias de

comunicación que no siempre se enseñan en la formación científica, pero que resultan cada vez más necesarias.

Al mismo tiempo, los propios investigadores deben evitar contribuir a la desinformación, por ejemplo, al difundir resultados preliminares como si fueran definitivos, al exagerar el alcance de sus hallazgos o al compartir contenidos generados por herramientas sin verificarlos. La integridad científica se extiende así más allá de la publicación académica y alcanza a todas las formas en que los investigadores participan en la circulación social del conocimiento, un ámbito en el que la credibilidad de la ciencia se construye o se pierde cada día. La formación en alfabetización mediática e informacional complementa estas medidas.

Los investigadores y los estudiantes necesitan desarrollar la capacidad de evaluar críticamente la información que encuentran, identificar las señales de contenidos fabricados o manipulados, verificar las fuentes y comprender cómo funcionan los sistemas que generan y distribuyen la información. Estas competencias, que antes podían parecer propias de los periodistas o de los bibliotecarios, se han vuelto indispensables para cualquier persona que produce o utiliza conocimiento científico.

Las universidades pueden integrarlas en sus programas de formación general y en los cursos de metodología, y las bibliotecas pueden ofrecer talleres específicos sobre la verificación de información en la era de la inteligencia artificial generativa. En esta misma línea, para la ciencia latinoamericana, los sesgos algorítmicos tienen una dimensión particular. Los modelos y herramientas disponibles han sido desarrollados predominantemente con datos y textos de otras regiones, por lo que pueden representar de manera insuficiente o distorsionada las realidades, los problemas y los conocimientos de América Latina.

Esta situación exige una vigilancia especial por parte de los investigadores de la región, pero también abre una oportunidad: la producción de datos de calidad sobre la región, su gestión según principios de apertura y su utilización para evaluar y mejorar los modelos pueden contribuir a una inteligencia artificial más equitativa. La lucha contra los sesgos, la fabricación de información y la desinformación no es solo una tarea defensiva, sino también una forma de afirmar el valor de una ciencia rigurosa, diversa y comprometida con la verdad.

Figura 5.3

Sesgos algorítmicos, fabricación de información y riesgos de desinformación en la producción científica.



Fuente: Elaboración autores

5.4 Gobernanza de la inteligencia artificial en universidades, centros de investigación y editoriales académicas

La gobernanza de la inteligencia artificial puede definirse como el conjunto de principios, normas, procesos y estructuras que orientan el desarrollo, la adopción y la supervisión de estos sistemas en una organización o en una sociedad. En el ámbito de la ciencia, la gobernanza resulta necesaria porque las decisiones sobre el uso de la inteligencia artificial no pueden dejarse exclusivamente a la iniciativa individual de los investigadores.

Las universidades, los centros de investigación y las editoriales académicas deben definir qué usos consideran aceptables, cómo deben declararse, qué herramientas cumplen con los requisitos de seguridad y protección de datos, quién supervisa su aplicación y cómo se responde ante los problemas. Sin una gobernanza adecuada, la adopción de estas herramientas puede producirse de manera desordenada, con riesgos para la integridad de la investigación, la privacidad de las personas y la reputación de las instituciones. De igual manera, los marcos internacionales ofrecen referencias valiosas para construir esta gobernanza.

La Recomendación de la UNESCO sobre la ética de la inteligencia artificial, adoptada en noviembre de 2021, establece principios como la proporcionalidad, la seguridad, la equidad y la

no discriminación, la privacidad, la supervisión y la decisión humanas, la transparencia y la explicabilidad, y la responsabilidad y la rendición de cuentas (UNESCO, 2021b).

El Reglamento europeo de inteligencia artificial adoptó un enfoque basado en el riesgo, que prohíbe determinadas prácticas, impone requisitos estrictos a los sistemas de alto riesgo y establece obligaciones de transparencia para otros sistemas; entre los sistemas de alto riesgo incluye los utilizados en la educación y la formación profesional para determinar el acceso o la admisión a instituciones educativas y para evaluar los resultados del aprendizaje (Parlamento Europeo y Consejo de la Unión Europea, 2024). Aunque este reglamento no se aplica directamente en América Latina, constituye una referencia influyente para los debates regionales.

En el plano organizacional, el Marco de Gestión de Riesgos de Inteligencia Artificial del NIST (2023) propone organizar la gobernanza en torno a cuatro funciones. Gobernar implica establecer una cultura organizacional de gestión de riesgos, con políticas, responsabilidades y procesos definidos. Mapear consiste en identificar el contexto en que se utiliza cada sistema y los riesgos asociados. Medir implica evaluar y monitorear esos riesgos mediante métodos cuantitativos y cualitativos. Y gestionar supone priorizar los riesgos y aplicar las medidas necesarias para atenderlos.

Este marco, aunque voluntario, ofrece una estructura práctica que las universidades y los centros de investigación pueden adaptar a sus necesidades. Por otra parte, para el ámbito específico de la investigación, las directrices de la Comisión Europea (2024) sobre el uso responsable de la inteligencia artificial generativa ofrecen recomendaciones diferenciadas para investigadores, organizaciones de investigación y organismos de financiamiento.

A las organizaciones de investigación les recomiendan, entre otras acciones, promover y orientar el uso responsable de estas herramientas, supervisar activamente su desarrollo y utilización, incorporar las orientaciones correspondientes en sus normas de buenas prácticas y ética de la investigación, y facilitar, cuando sea posible, herramientas propias o de confianza que protejan los datos y la confidencialidad. Miao y Holmes (2023), en la guía de la UNESCO, recomiendan igualmente que las instituciones de educación e investigación evalúen las herramientas antes de adoptarlas, protejan la privacidad de los datos y desarrollen capacidades para su uso crítico.

Las universidades pueden traducir estos marcos en una política institucional de inteligencia artificial para la investigación. Una política de este tipo podría incluir, en primer lugar,

principios generales que orienten el uso de estas herramientas, alineados con los valores de la institución y con la normativa nacional. Podría establecer también criterios sobre los usos aceptables en las distintas fases de la investigación y en los distintos tipos de trabajos académicos, desde las tesis de grado hasta los artículos científicos.

Convendría que definiera las formas en que debe declararse el uso de herramientas, procedimientos para evaluar y aprobar las herramientas que pueden utilizarse con datos sensibles, responsabilidades de los distintos actores, como investigadores, directores de tesis, comités de ética y autoridades, y programas de formación. En el Ecuador, esta política debería articularse con el Reglamento de Régimen Académico expedido por el CES (2022) y con la Ley Orgánica de Protección de Datos Personales (Asamblea Nacional del Ecuador, 2021). Paralelamente, las editoriales académicas y las revistas científicas tienen también responsabilidades específicas de gobernanza.

Deben establecer políticas claras sobre el uso de la inteligencia artificial por parte de autores, revisores y editores, siguiendo las orientaciones de organizaciones como el COPE (2023); proteger la confidencialidad de los manuscritos en revisión, evitando que se carguen en plataformas externas; y adoptar herramientas que les permitan detectar problemas de integridad, como la fabricación de referencias o la manipulación de imágenes. Para las revistas latinoamericanas, muchas de ellas editadas por universidades con recursos limitados, la colaboración con redes y sistemas regionales puede facilitar la adopción de políticas y herramientas comunes.

La experiencia de las instituciones que ya han adoptado políticas sobre inteligencia artificial sugiere algunos aprendizajes. Las políticas más eficaces suelen ser breves, claras y orientadas a la práctica, con ejemplos concretos de usos aceptables y no aceptables, en lugar de documentos extensos y abstractos. También resultan más eficaces cuando se acompañan de formación, de herramientas institucionales seguras y de canales de consulta para los casos dudosos, porque una prohibición sin alternativas tiende a ser ignorada.

Es aconsejable, además, que las políticas distingan entre los distintos tipos de actividades, como la docencia, la investigación, la gestión y la evaluación, ya que los riesgos y las oportunidades varían en cada una. Por último, las políticas deben prever mecanismos de revisión periódica, porque las herramientas y las normas externas cambian con rapidez. Las universidades ecuatorianas que inicien este proceso pueden beneficiarse de compartir experiencias con otras

instituciones de la región y de participar en redes que elaboren orientaciones comunes, lo que reduce los costos y aumenta la coherencia del sistema de educación superior.

Los comités de ética de la investigación constituyen una pieza clave de esta gobernanza. Tradicionalmente encargados de proteger a las personas que participan en los estudios, estos comités deben ahora considerar también los riesgos asociados al uso de herramientas inteligentes, como el procesamiento de datos personales en plataformas externas, la posibilidad de identificar a participantes a partir de datos anonimizados o los sesgos de los modelos que podrían afectar a ciertos grupos.

Para cumplir esta función, los comités necesitan formación específica, guías de evaluación actualizadas y, en algunos casos, la participación de especialistas en ciencia de datos. Las universidades ecuatorianas podrían fortalecer sus comités en este sentido y coordinarse con otras instituciones para desarrollar criterios comunes de evaluación de los proyectos que utilizan inteligencia artificial. Sobre esta base, la gobernanza de la inteligencia artificial en la ciencia debe ser, finalmente, dinámica y participativa. Las herramientas cambian con rapidez, y las políticas que hoy resultan adecuadas pueden quedar obsoletas en pocos meses, por lo que es necesario revisarlas periódicamente.

La participación de investigadores, estudiantes, personal técnico y comunidades en la elaboración de estas políticas aumenta su legitimidad y su pertinencia. Y la transparencia sobre las decisiones adoptadas fortalece la confianza de la comunidad académica y de la sociedad. Una buena gobernanza no busca frenar la adopción de la inteligencia artificial, sino orientarla hacia los fines de la ciencia y protegerla de los riesgos que podrían comprometer su integridad.

La gobernanza descrita solo se vuelve efectiva cuando cada actor del ecosistema académico asume su parte. A las autoridades universitarias, desde los rectorados hasta las instancias de investigación, les corresponde liderar la actualización de la normativa institucional, revisar los reglamentos de carrera y de evaluación del personal académico a la luz de los compromisos del Acuerdo sobre la Reforma de la Evaluación de la Investigación (CoARA, 2022), destinar recursos a infraestructuras digitales abiertas y seguras, y sostener programas de formación continua.

Los editores y los comités editoriales cumplen una función de custodia de la calidad y la integridad de la producción académica: deben aplicar políticas transparentes sobre el uso de

herramientas generativas, conforme a las orientaciones del COPE (2023), formar a sus revisores en los nuevos riesgos para la integridad y preservar los modelos de publicación sin costos para los autores.

La sociedad civil, las comunidades locales y los sectores productivos, finalmente, no son simples destinatarios del conocimiento, sino participantes legítimos en la definición de las agendas de investigación, en los espacios de cocreación y en el seguimiento de la pertinencia de lo que la ciencia produce lo que establece que, sin esta articulación entre actores, las políticas institucionales corren el riesgo de quedarse en declaraciones de principios.

Figura 5.4

Gobernanza de la inteligencia artificial en universidades, centros de investigación y editoriales académicas.



Fuente: Elaboración autores

5.5 Soberanía científica y tecnológica: protección de datos, autonomía investigativa y reducción de dependencias digitales

La soberanía científica y tecnológica puede entenderse como la capacidad de un país o de una región para definir sus propias agendas de investigación, producir conocimiento sobre sus problemas, controlar los datos que generan sus instituciones y sus ciudadanos, y decidir de manera autónoma qué tecnologías adopta y en qué condiciones. No se trata de una aspiración autárquica, porque la ciencia es por naturaleza una empresa internacional y ningún país puede producir por sí solo todo el conocimiento y la tecnología que necesita.

Se trata, más bien, de la capacidad de participar en la ciencia y la tecnología globales en condiciones que no impliquen una dependencia excesiva ni la pérdida del control sobre recursos estratégicos. La generalización de la inteligencia artificial ha vuelto esta cuestión especialmente urgente para América Latina. Desde esta perspectiva, la razón de esta urgencia es la concentración de las capacidades necesarias para desarrollar los sistemas de inteligencia artificial más avanzados.

Los grandes modelos de lenguaje requieren enormes volúmenes de datos, capacidades de cómputo muy costosas y equipos de especialistas altamente calificados, recursos que se concentran en un pequeño número de empresas y países. Bender et al. (2021) advirtieron sobre los costos ambientales y económicos del entrenamiento de estos modelos y sobre el hecho de que esos costos y beneficios se distribuyen de manera desigual, en detrimento de las comunidades con menos recursos.

Para los investigadores latinoamericanos, esto significa que buena parte de las herramientas que utilizan son desarrolladas, controladas y actualizadas por actores externos, que definen sus condiciones de uso, sus precios y sus prioridades, y que pueden modificarlas o retirarlas sin consultar a sus usuarios.

Los datos de la región muestran tanto las capacidades existentes como las brechas que deben cerrarse. El Índice Latinoamericano de Inteligencia Artificial ubicó a Chile, Brasil y Uruguay como los países más avanzados de la región, mientras que el Ecuador obtuvo un puntaje de 34,59 y ocupó el undécimo lugar entre diecinueve países, lo que refleja capacidades intermedias en los factores habilitantes, en la investigación, el desarrollo y la adopción, y en la gobernanza de la inteligencia artificial (CENIA, 2024).

La RICYT (2025), por su parte, señala que la inversión regional en investigación y desarrollo se situó en torno al 0,60 % del producto interno bruto en 2023, muy por debajo de la de las economías más desarrolladas. Estas cifras indican que la soberanía científica y tecnológica de la región requiere un esfuerzo sostenido de inversión y de construcción de capacidades. De forma complementaria, la protección de los datos constituye una dimensión central de la soberanía científica. Los datos generados por las instituciones de investigación, los sistemas de salud, las escuelas o los ciudadanos son un recurso estratégico, tanto para la investigación como para el desarrollo de sistemas de inteligencia artificial.

Cuando estos datos se procesan en plataformas externas sin garantías adecuadas, pueden utilizarse para fines distintos de los previstos, incluido el entrenamiento de modelos comerciales, sin beneficio para quienes los generaron. En el Ecuador, la Ley Orgánica de Protección de Datos Personales establece principios como la licitud, la finalidad, la minimización y la confidencialidad, así como reglas sobre la transferencia internacional de datos, que se aplican también a la investigación (Asamblea Nacional del Ecuador, 2021). El cumplimiento de esta normativa no es solo una obligación legal, sino también una forma de ejercer la soberanía sobre los datos.

La autonomía investigativa constituye otra dimensión. Cuando las herramientas que utilizan los investigadores son diseñadas en otros contextos, pueden orientar de manera sutil las preguntas que se formulan, los métodos que se aplican y las perspectivas que se consideran. Los modelos de lenguaje entrenados predominantemente con textos en inglés y de otras regiones pueden privilegiar ciertas tradiciones teóricas, ciertos temas y ciertas formas de argumentar, en detrimento de las propias de la región.

Preservar la autonomía investigativa implica utilizar estas herramientas de manera crítica, mantener la capacidad de definir las agendas de investigación a partir de las necesidades del territorio y fortalecer las tradiciones intelectuales y las redes académicas propias. Vinculado con lo anterior, la reducción de las dependencias digitales puede perseguirse mediante varias estrategias complementarias.

Entre ellas destacan la preferencia por herramientas de código abierto, que pueden examinarse, adaptarse y ejecutarse en infraestructuras propias; el desarrollo de infraestructuras de cómputo y de almacenamiento compartidas por las instituciones de la región; la producción y la gestión de datos de calidad sobre la región, según principios de apertura y de protección; la formación de especialistas capaces de desarrollar y adaptar modelos; y la cooperación regional para negociar en mejores condiciones con los proveedores tecnológicos. La Recomendación de la UNESCO sobre la ciencia abierta promueve, en este sentido, el desarrollo de infraestructuras compartidas y la reducción de las brechas entre países en el acceso a la ciencia y la participación en ella (UNESCO, 2021a).

Algunas iniciativas concretas podrían contribuir a fortalecer la soberanía científica y tecnológica del Ecuador en el ámbito de la inteligencia artificial. La creación de una infraestructura nacional o regional de cómputo para la investigación, compartida por las universidades y los

institutos públicos, permitiría a los investigadores entrenar y ejecutar modelos sin depender exclusivamente de servicios externos.

El desarrollo de conjuntos de datos nacionales de calidad, en ámbitos como la salud, la educación, el ambiente o la lengua, gestionados con garantías de protección y apertura, ofrecería una base para investigaciones pertinentes y para la adaptación de modelos al contexto local. La formación de especialistas en inteligencia artificial mediante programas de posgrado y de intercambio, acompañada de condiciones que favorezcan su permanencia en el país, contribuiría a construir capacidades propias. Y la participación activa en los debates regionales e internacionales sobre la gobernanza de la inteligencia artificial permitiría que los intereses del país estuvieran representados en las decisiones que afectarán el futuro de esta tecnología. La soberanía científica tiene también una dimensión lingüística que merece atención.

Figura 5.5

Soberanía científica y tecnológica: protección de datos, autonomía investigativa y reducción de dependencias digitales.



Fuente: Elaboración autores

Los modelos de lenguaje funcionan mejor en los idiomas con mayor presencia en sus datos de entrenamiento, y el español, aunque es una de las lenguas más habladas del mundo, está menos representado que el inglés en la producción científica y técnica. Las lenguas indígenas de la región, como el kichwa o el shuar en el Ecuador, tienen una presencia todavía menor. Esta

situación puede reforzar la tendencia a investigar y publicar en inglés, en detrimento de la producción en las lenguas propias. El desarrollo de recursos lingüísticos, corpus y modelos para el español y para las lenguas indígenas, en colaboración con sus hablantes, constituye una contribución importante a la soberanía científica y cultural de la región.

En concordancia con ello, la soberanía científica y tecnológica no es un objetivo que pueda alcanzarse de manera inmediata, sino un horizonte que orienta decisiones cotidianas. Cada vez que una universidad elige una herramienta, define una política de datos, invierte en infraestructura o forma a sus investigadores, contribuye a fortalecer o a debilitar la autonomía de la ciencia regional. Para el Ecuador y para América Latina, la Investigación 5.0 ofrece una oportunidad de participar en la transformación de la ciencia desde una posición más activa, siempre que se combine el aprovechamiento de las herramientas globales con la construcción de capacidades propias y con una gobernanza de los datos que proteja los derechos de las personas y los intereses de la región.

5.6 Investigación sostenible e inclusiva: inteligencia artificial aplicada a los desafíos sociales, económicos y ambientales

La ciencia no es un fin en sí misma, sino un medio para comprender el mundo y para mejorar las condiciones de vida de las personas. Esta afirmación, que puede parecer evidente, adquiere un significado particular en un momento en que la humanidad enfrenta desafíos de enorme magnitud: el cambio climático, la pérdida de biodiversidad, la desigualdad, la pobreza, las crisis sanitarias y la transformación del trabajo.

La Investigación 5.0, en coherencia con la orientación de la Industria 5.0 hacia la centralidad del ser humano, la sostenibilidad y la resiliencia (Breque et al., 2021), propone orientar el uso de la inteligencia artificial en la ciencia hacia la búsqueda de soluciones a estos desafíos, y hacerlo de manera inclusiva, es decir, asegurando que sus beneficios lleguen a todas las personas y que todas puedan participar en la producción del conocimiento. A ello se suma que el Informe de la UNESCO sobre la ciencia de 2021, titulado «La carrera contra el tiempo por un desarrollo más inteligente», examinó la situación de la ciencia en el mundo en relación con los objetivos de desarrollo sostenible y con la transición hacia economías digitales y sostenibles (UNESCO, 2021c).

El informe mostró que muchos países han adoptado políticas que vinculan la ciencia con estos objetivos, pero que la inversión en investigación sigue siendo insuficiente en buena parte del

mundo, y que existen brechas importantes entre regiones en las capacidades para producir y utilizar el conocimiento científico. Para América Latina, estas brechas se reflejan en una inversión en investigación y desarrollo que, según la RICYT (2025), se situó en torno al 0,60 % del producto interno bruto regional en 2023, una proporción muy inferior a la de los países más avanzados.

La inteligencia artificial ofrece herramientas poderosas para abordar los desafíos sociales, económicos y ambientales. En el ámbito ambiental, permite procesar imágenes satelitales para monitorear la deforestación, analizar datos climáticos para mejorar las predicciones, identificar especies a partir de fotografías o grabaciones de sonidos, y optimizar el uso de la energía y del agua. En el ámbito de la salud, contribuye al diagnóstico temprano de enfermedades, al análisis de datos epidemiológicos y al descubrimiento de fármacos, como lo muestran los avances en la predicción de estructuras de proteínas (Jumper et al., 2021). En el ámbito social y económico, ayuda a analizar registros administrativos para comprender la pobreza, la desigualdad o el abandono escolar, y a evaluar el impacto de las políticas públicas. H. Wang et al. (2023) documentan cómo estas aplicaciones están transformando numerosas disciplinas científicas.

La sostenibilidad de la propia investigación con inteligencia artificial constituye, sin embargo, una cuestión que no debe ignorarse. Bender et al. (2021) advirtieron que el entrenamiento de los grandes modelos de lenguaje consume cantidades considerables de energía, con un costo ambiental que se distribuye de manera desigual, porque suelen ser las comunidades más vulnerables las que sufren con mayor intensidad las consecuencias del cambio climático, mientras que los beneficios de estas tecnologías se concentran en otros lugares.

Una investigación sostenible debería considerar estos costos, privilegiando el uso de modelos proporcionados a las necesidades de cada problema, evitando cálculos innecesarios y valorando la eficiencia energética de las herramientas que utiliza. En la práctica, esto supone preferir modelos compactos y eficientes cuando resultan suficientes para el problema, reutilizar modelos y código ya disponibles en lugar de repetir procesos de cómputo intensivo, recurrir en lo posible a centros de datos alimentados con energías renovables y tener en cuenta que la infraestructura de cómputo consume no solo electricidad, sino también agua para su refrigeración.

Las universidades pueden incorporar, además, criterios de sostenibilidad en la gestión de sus laboratorios y servidores, en coherencia con el lugar central que la propuesta de Industria 5.0 asigna a la sostenibilidad en la transformación tecnológica (Breque et al., 2021).

La inclusión constituye la otra dimensión de esta propuesta. Una investigación inclusiva es aquella en la que pueden participar personas de distintos orígenes, géneros, regiones y condiciones, y cuyos resultados benefician a toda la sociedad, incluidos los grupos históricamente excluidos.

La inteligencia artificial puede favorecer la inclusión, por ejemplo, al reducir las barreras lingüísticas, al facilitar el acceso a herramientas de análisis antes reservadas a centros con grandes recursos o al permitir que investigadores con discapacidad trabajen con mayor autonomía. Pero también puede reforzar la exclusión, cuando los modelos reproducen sesgos contra determinados grupos (Mehrabi et al., 2021), cuando las herramientas solo están disponibles para quienes pueden pagarlas o cuando los problemas de las comunidades marginadas no forman parte de las agendas de investigación.

Según la RICYT (2025), en países como Argentina, Paraguay, Uruguay y Venezuela las mujeres representan ya más de la mitad de los investigadores, un dato que muestra avances, aunque la situación es desigual entre países y persisten brechas en distintas disciplinas y niveles de la carrera. Además, orientar la investigación con inteligencia artificial hacia la sostenibilidad y la inclusión requiere decisiones conscientes en distintos niveles.

En el nivel de los proyectos, implica formular preguntas pertinentes para los desafíos del territorio, involucrar a las comunidades afectadas en el diseño y la ejecución de la investigación, evaluar los posibles sesgos de las herramientas y considerar el costo ambiental de los análisis. En el nivel institucional, implica definir agendas de investigación alineadas con los objetivos de desarrollo sostenible, asegurar el acceso equitativo a las herramientas y a la formación, y valorar en la evaluación académica el impacto social de la investigación. Y en el nivel de las políticas públicas, implica financiar la investigación orientada a los desafíos nacionales y regionales, y promover la cooperación entre universidades, gobiernos y comunidades.

La inclusión requiere atender también a las brechas que existen dentro de cada país. En el Ecuador, como en buena parte de América Latina, las capacidades de investigación se concentran en las grandes ciudades y en algunas instituciones, mientras que las universidades de provincias y los institutos técnicos cuentan con menos recursos, menos acceso a herramientas y menos oportunidades de formación. Si la adopción de la inteligencia artificial en la investigación se produce solo en los centros mejor dotados, las brechas internas podrían ampliarse.

Para evitarlo, las políticas públicas y las redes interinstitucionales pueden promover el acceso compartido a herramientas e infraestructuras, ofrecer programas de formación abiertos a investigadores de todas las regiones y financiar proyectos colaborativos que involucren a instituciones con distintos niveles de desarrollo. Una investigación verdaderamente inclusiva no es solo aquella que estudia los problemas de los grupos excluidos, sino también aquella que les permite participar como productores de conocimiento, con las herramientas y las capacidades necesarias para hacerlo.

La medición de la contribución de la investigación a los objetivos de desarrollo sostenible plantea desafíos metodológicos. Clasificar las publicaciones según los objetivos a los que contribuyen, por ejemplo, mediante herramientas de procesamiento del lenguaje, puede ofrecer una aproximación, pero no garantiza que la investigación haya tenido un impacto real en esos objetivos. Para evaluar este impacto, es necesario examinar cómo los resultados se utilizan en las políticas, en las prácticas profesionales o en las comunidades, lo que requiere métodos cualitativos y seguimientos de largo plazo.

Las universidades que deseen orientar su investigación hacia la sostenibilidad deberían desarrollar sistemas de seguimiento de su impacto social y ambiental, que complementen los indicadores bibliométricos y permitan aprender de la experiencia. Con todo, para el Ecuador, un país megadiverso, con una gran riqueza cultural y con desafíos importantes en materia de pobreza, desigualdad y vulnerabilidad ante los desastres, la investigación sostenible e inclusiva con inteligencia artificial ofrece oportunidades significativas.

El monitoreo de la biodiversidad amazónica y de las islas Galápagos, la gestión de los riesgos volcánicos y climáticos, la mejora de la producción agrícola en contextos de cambio climático, el análisis de la calidad de los servicios públicos o el fortalecimiento de la educación intercultural son ejemplos de campos en los que la combinación de la inteligencia artificial con el conocimiento local podría producir resultados de gran valor. Aprovechar estas oportunidades exige, que la ciencia se oriente deliberadamente hacia el bien común y que la tecnología se ponga al servicio de las personas, y no a la inversa.

Figura 5.6

Investigación sostenible e inclusiva: inteligencia artificial aplicada a los desafíos sociales, económicos y ambientales.



Fuente: Elaboración autores

5.7 Prospectiva científica: laboratorios autónomos, agentes de investigación y nuevos escenarios de descubrimiento científico

La prospectiva es una disciplina que estudia los futuros posibles con el fin de orientar las decisiones del presente. No pretende predecir con certeza lo que ocurrirá, sino explorar escenarios plausibles, identificar las tendencias que los impulsan y los factores que podrían modificarlos, y preparar a las organizaciones para responder a ellos. Aplicada a la ciencia, la prospectiva permite preguntarse cómo podría transformarse la investigación en las próximas décadas como consecuencia de la inteligencia artificial y de otras tecnologías, y qué decisiones deberían tomar hoy las universidades, los centros de investigación y los gobiernos para aprovechar las oportunidades y mitigar los riesgos de esos futuros.

Dos tendencias parecen especialmente relevantes en este ejercicio: el desarrollo de laboratorios autónomos y la aparición de agentes de investigación capaces de realizar tareas científicas complejas. En esta misma línea, los laboratorios autónomos, también llamados autoconducidos, combinan equipos robóticos, sistemas de planificación basados en inteligencia artificial y bases

de datos para diseñar, ejecutar y analizar experimentos con una intervención humana mínima. Tom et al. (2024), en una amplia revisión sobre estos laboratorios en química y ciencia de materiales, describen las tecnologías que los hacen posibles, sus aplicaciones en el descubrimiento de fármacos, la ciencia de materiales, la genómica y la química, sus distintos niveles de automatización y los desafíos que enfrentan.

Szymanski et al. (2023), cuyo trabajo se comentó en el capítulo 3, presentaron un ejemplo concreto de estos sistemas: un laboratorio autónomo dedicado a la síntesis de nuevos materiales inorgánicos que, durante diecisiete días de funcionamiento continuo, informó haber sintetizado decenas de compuestos a partir de objetivos identificados mediante cálculos computacionales, combinando el conocimiento extraído de la literatura con el aprendizaje activo para planificar los experimentos.

Los agentes de investigación constituyen la segunda tendencia. Se trata de sistemas basados en modelos de lenguaje que pueden planificar y ejecutar secuencias de tareas científicas, utilizando herramientas como la búsqueda de información, la ejecución de código o el control de equipos. L. Wang et al. (2024) describen la arquitectura de estos agentes mediante módulos de perfil, memoria, planificación y acción, y revisan sus aplicaciones en distintos campos científicos.

Boiko et al. (2023) mostraron un agente capaz de diseñar, planificar y ejecutar experimentos químicos de manera semiautónoma. S. Gao et al. (2024), por su parte, imaginan, en el ámbito biomédico, agentes que colaboran con los investigadores, razonan de manera escéptica, planifican flujos de trabajo de descubrimiento y evalúan sus propias limitaciones, y subrayan que las personas deben permanecer en el proceso y que el papel de los agentes es complementar su creatividad y experiencia.

De igual manera, a partir de estas tendencias es posible esbozar varios escenarios para la ciencia de las próximas décadas. En un escenario de aumento, la inteligencia artificial se integra en la investigación como un conjunto de herramientas que amplían las capacidades de los investigadores, aceleran la exploración y liberan tiempo para la reflexión, mientras las personas conservan la dirección intelectual y la responsabilidad por los resultados. En un escenario de automatización, los laboratorios autónomos y los agentes realizan una parte creciente del trabajo científico, incluida la generación de hipótesis y la ejecución de experimentos, y el papel de los investigadores se desplaza hacia la definición de objetivos y la supervisión.

En un escenario de concentración, las capacidades más avanzadas quedan en manos de pocas empresas y países, que dominan la producción de conocimiento en las áreas más dinámicas, mientras el resto del mundo se limita a utilizar las herramientas que ellos desarrollan. Y en un escenario de deterioro, la producción masiva de resultados de baja calidad, la fabricación de información y la pérdida de la diversidad de enfoques debilitan la confiabilidad de la ciencia.

Estos escenarios no son excluyentes y pueden combinarse de distintas maneras en diferentes campos y regiones. Messeri y Crockett (2024) advierten sobre un riesgo que atraviesa varios de ellos: la posibilidad de que la ciencia produzca cada vez más resultados, pero comprenda cada vez menos, si la confianza en las herramientas sustituye la reflexión crítica y si se forman monoculturas científicas en las que ciertos métodos y preguntas desplazan a otros. Si et al. (2025), por su parte, mostraron que las ideas de investigación generadas por modelos de lenguaje pueden ser juzgadas como más novedosas que las de expertos, aunque menos factibles y diversas, lo que sugiere que el futuro de la creatividad científica dependerá de cómo se combinen las capacidades humanas y las artificiales.

Por otra parte, para América Latina, el ejercicio prospectivo tiene una utilidad particular, porque permite anticipar las decisiones necesarias para evitar los escenarios menos favorables. Si la región no invierte en capacidades propias, corre el riesgo de quedar relegada en un escenario de concentración, en el que la producción de conocimiento en las áreas más dinámicas se realiza en otros lugares. Si no fortalece sus mecanismos de integridad y de evaluación, puede verse afectada por el deterioro de la calidad de la ciencia.

En cambio, si combina la inversión en infraestructura y formación con la cooperación regional, la apertura de datos y una gobernanza responsable, puede participar activamente en un escenario de aumento, aprovechando las herramientas para multiplicar el rendimiento de sus recursos y orientar la investigación hacia sus propios desafíos.

Las universidades pueden incorporar la prospectiva en su planificación estratégica mediante ejercicios periódicos que involucren a investigadores, estudiantes, autoridades y actores externos. Estos ejercicios pueden ayudar a identificar las capacidades que la institución necesitará en los próximos años, las áreas de investigación en las que podría desarrollar ventajas propias, las alianzas que conviene construir y los riesgos que deben gestionarse.

Un ejercicio prospectivo sobre el futuro de la investigación en una universidad ecuatoriana, por ejemplo, podría concluir que conviene invertir en formación en ciencia de datos para todos los

programas de posgrado, establecer acuerdos con otras instituciones para compartir infraestructura de cómputo, fortalecer las líneas de investigación en las que el país posee ventajas comparativas, como la biodiversidad, y adoptar una política de inteligencia artificial para la investigación. Más allá de sus conclusiones específicas, estos ejercicios contribuyen a que la comunidad académica comparta una visión del futuro y se prepare colectivamente para él, en lugar de reaccionar de manera improvisada ante los cambios.

Figura 5.7

Prospectiva científica: laboratorios autónomos, agentes de investigación y nuevos escenarios de descubrimiento científico.



Fuente: Elaboración autores

Los escenarios descritos plantean, asimismo, preguntas sobre el futuro de las profesiones científicas. Si los laboratorios autónomos y los agentes asumen una parte creciente del trabajo experimental y analítico, algunas funciones tradicionales, como las de técnicos de laboratorio o asistentes de investigación, podrían transformarse profundamente, mientras que surgirían nuevas funciones vinculadas al diseño, la supervisión y el mantenimiento de estos sistemas. Anticipar estos cambios permitiría a las universidades adaptar sus programas de formación y a los sistemas científicos prever las transiciones laborales.

La prospectiva no debe limitarse a los aspectos tecnológicos, sino considerar también las consecuencias humanas y sociales de la transformación de la ciencia. La prospectiva científica no

es, por tanto, un ejercicio de adivinación, sino una herramienta para la acción. Los laboratorios autónomos y los agentes de investigación no llegarán a todas las universidades al mismo tiempo ni de la misma manera, pero sus efectos sobre la ciencia global afectarán a todos.

Las instituciones que se preparen desde ahora, formando a sus investigadores, construyendo infraestructuras, estableciendo normas y participando en redes de cooperación, estarán en mejores condiciones de influir en el futuro de la ciencia y de beneficiarse de él. Las que no lo hagan corren el riesgo de que ese futuro se decida sin ellas.

5.8 Hacia un modelo de Investigación 5.0 centrado en el ser humano: propuesta de principios, dimensiones e indicadores para su implementación

A lo largo de esta obra se ha examinado cómo la inteligencia artificial está transformando los fundamentos epistemológicos de la ciencia, la generación de ideas y de hipótesis, las metodologías de investigación, la producción y la comunicación del conocimiento, y los marcos éticos y de gobernanza que regulan la actividad científica. Corresponde ahora sintetizar esos análisis en un modelo de Investigación 5.0 centrado en el ser humano, que pueda servir de orientación a las universidades, los centros de investigación y los investigadores que desean incorporar la inteligencia artificial de manera responsable.

El modelo se organiza en tres niveles: principios que expresan los valores que deben orientar la investigación, dimensiones que identifican los ámbitos en los que esos principios deben concretarse, e indicadores que permiten evaluar el grado de implementación del modelo. Sobre esta base, los principios del modelo se derivan de los marcos revisados en los capítulos anteriores. El principio de centralidad humana, inspirado en la propuesta de Industria 5.0 (Breque et al., 2021), establece que la inteligencia artificial debe ampliar las capacidades de los investigadores y no sustituir su juicio, y que las decisiones relevantes y la responsabilidad por los resultados deben permanecer en manos de personas.

El principio de integridad exige que el uso de estas herramientas respete la honestidad, el rigor y la transparencia que caracterizan a la buena ciencia, y que se declare de manera explícita, conforme a las orientaciones del COPE (2023) y de la Comisión Europea (2024). El principio de apertura, alineado con la Recomendación de la UNESCO sobre la ciencia abierta (UNESCO, 2021a), promueve el acceso a las publicaciones, los datos y el código, y la gestión de los datos según los principios FAIR.

El principio de equidad exige atender a los sesgos de las herramientas y asegurar que los beneficios de la investigación lleguen a todas las personas (Mehrabi et al., 2021). Y el principio de pertinencia orienta la investigación hacia los desafíos sociales, económicos y ambientales del territorio.

Las dimensiones del modelo identifican los ámbitos en los que estos principios deben concretarse. Una dimensión de capacidades humanas comprende las competencias de los investigadores en sus disciplinas, en pensamiento crítico y en alfabetización algorítmica, entendida según los cuatro aspectos propuestos por Ng et al. (2021): conocer y comprender la inteligencia artificial, usarla y aplicarla, evaluarla y crear con ella, y reconocer sus implicaciones éticas. La dimensión metodológica abarca las prácticas de validación, explicabilidad, reproducibilidad y control de sesgos en las investigaciones asistidas por inteligencia artificial (Kapoor y Narayanan, 2023; Molnar, 2022).

A ella se suma una dimensión de infraestructura, que incluye el acceso a capacidades de cómputo, a herramientas confiables y a repositorios de datos y publicaciones. La dimensión de comunicación comprende la producción, la publicación y la difusión del conocimiento con integridad y apertura. Y la dimensión de gobernanza abarca las políticas, las normas, las estructuras y los procesos que orientan el uso de la inteligencia artificial en la institución, siguiendo marcos como el del NIST (2023).

Desde esta perspectiva, los indicadores permiten evaluar el avance en cada dimensión y orientar las decisiones de mejora. En la dimensión de capacidades humanas, podrían considerarse la proporción de investigadores y estudiantes que han recibido formación en el uso responsable de la inteligencia artificial y la inclusión de estos contenidos en los programas de grado y posgrado. En la metodológica, la proporción de proyectos que documentan el uso de herramientas inteligentes, aplican procedimientos de validación y publican sus datos y su código.

En la de infraestructura, la disponibilidad de herramientas institucionales que protejan la confidencialidad de los datos y la existencia de repositorios que cumplan los principios FAIR. En la de comunicación, la proporción de publicaciones en acceso abierto que declaran el uso de herramientas inteligentes. Y en la de gobernanza, la existencia de una política institucional de inteligencia artificial para la investigación, su revisión periódica y la participación de la comunidad académica en su elaboración.

Estos indicadores deben interpretarse con prudencia y no convertirse en fines en sí mismos. El Acuerdo sobre la Reforma de la Evaluación de la Investigación advierte sobre los riesgos de los usos inapropiados de los indicadores cuantitativos y propone que la evaluación se base principalmente en el juicio cualitativo, con apoyo de indicadores utilizados de manera responsable (CoARA, 2022). Aplicada al modelo de Investigación 5.0, esta orientación sugiere que los indicadores sirvan para orientar el diálogo y la mejora institucional, y no para clasificar a los investigadores o a las unidades académicas.

Un indicador que muestra una baja proporción de proyectos con datos abiertos, por ejemplo, debería conducir a preguntarse qué obstáculos enfrentan los investigadores y cómo pueden superarse, más que a sancionar a quienes no los publican. De forma complementaria, la implementación del modelo puede seguir una secuencia gradual, adaptada a las condiciones de cada institución. En una primera etapa, la institución puede realizar un diagnóstico de su situación en cada dimensión, adoptar una política inicial de inteligencia artificial para la investigación e iniciar programas de formación.

Posteriormente, puede desarrollar infraestructuras y herramientas, incorporar los principios del modelo en los procesos de evaluación de proyectos y de publicaciones, y establecer mecanismos de seguimiento. En una etapa de consolidación, puede evaluar los resultados, revisar sus políticas y participar en redes nacionales y regionales que compartan experiencias y recursos. En el Ecuador, este proceso puede articularse con el marco normativo de la educación superior (CES, 2022) y con la normativa de protección de datos personales (Asamblea Nacional del Ecuador, 2021).

La aplicación del modelo puede ilustrarse con el caso de una universidad que decide iniciar su transición hacia la Investigación 5.0. En la dimensión de capacidades humanas, la universidad podría incorporar un módulo sobre el uso responsable de la inteligencia artificial en todos sus programas de posgrado y ofrecer talleres a sus docentes investigadores. En la metodológica, podría exigir que los proyectos financiados describan el uso de herramientas inteligentes y sus procedimientos de validación. En la de infraestructura, podría habilitar herramientas institucionales que protejan los datos y fortalecer su repositorio según los principios de apertura y reutilización.

En la de comunicación, podría promover la publicación en acceso abierto y la declaración del uso de herramientas en todas las publicaciones institucionales. Y en la de gobernanza, podría

aprobar una política de inteligencia artificial para la investigación, elaborada de manera participativa y revisada anualmente. El seguimiento de los indicadores asociados a cada dimensión permitiría a la universidad conocer sus avances, identificar los obstáculos y ajustar sus estrategias, en un proceso de aprendizaje institucional continuo.

La participación de la comunidad académica en la adaptación del modelo constituye una condición de su éxito. Un modelo impuesto desde las autoridades, sin el compromiso de los investigadores, los estudiantes y el personal técnico, difícilmente transformará las prácticas cotidianas de la investigación. En cambio, un proceso participativo, en el que los distintos actores discutan los principios, propongan las acciones y definan los indicadores, favorece la apropiación del modelo y su adaptación a las particularidades de cada institución.

Figura 5.8

Hacia un modelo de Investigación 5.0 centrado en el ser humano: propuesta de principios, dimensiones e indicadores para su implementación.



Fuente: Elaboración autores

Las universidades pueden organizar este proceso mediante consultas, talleres y comisiones mixtas, y comunicar periódicamente sus avances, de modo que la transición hacia la Investigación 5.0 sea una construcción colectiva y no un mandato administrativo. Vinculado con lo anterior, el modelo propuesto no pretende ser una receta universal, sino un marco flexible que cada institución puede adaptar a su realidad. Su valor reside en articular, de manera coherente, los principios, las dimensiones y los indicadores que se desprenden del análisis desarrollado en esta obra, y en recordar que la incorporación de la inteligencia artificial a la ciencia no es solo un problema técnico, sino también ético, institucional y político.

La Investigación 5.0 centrada en el ser humano aspira a una ciencia que aproveche las capacidades de las herramientas inteligentes sin renunciar a los valores que le dan sentido: la búsqueda honesta de la verdad, el rigor, la apertura, la equidad y el compromiso con el bienestar de las personas y del planeta.

REFERENCIAS BIBLIOGRÁFICAS

Asamblea Nacional del Ecuador. (2021, 26 de mayo). *Ley Orgánica de Protección de Datos Personales*. Registro Oficial, Quinto Suplemento n.º 459.

Bender, E. M., Gebru, T., McMillan-Major, A., y Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? En *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 610–623). Association for Computing Machinery. https://doi.org/10.1145/3442188.3445922

Boiko, D. A., MacKnight, R., Kline, B., y Gomes, G. (2023). Autonomous chemical research with large language models. *Nature, 624*(7992), 570–578. https://doi.org/10.1038/s41586-023-06792-0

Breque, M., De Nul, L., y Petridis, A. (2021). *Industry 5.0: Towards a sustainable, human-centric and resilient European industry*. Comisión Europea, Dirección General de Investigación e Innovación. https://doi.org/10.2777/308407

Carayannis, E. G., y Morawska-Jancelewicz, J. (2022). The futures of Europe: Society 5.0 and Industry 5.0 as driving forces of future universities. *Journal of the Knowledge Economy, 13*(4), 3445–3471. https://doi.org/10.1007/s13132-021-00854-2

Centro Nacional de Inteligencia Artificial [CENIA]. (2024). *Índice Latinoamericano de Inteligencia Artificial (ILIA) 2024*. CENIA y Comisión Económica para América Latina y el Caribe. https://indicelatam.cl

Coalition for Advancing Research Assessment [CoARA]. (2022). *Agreement on reforming research assessment*. https://coara.eu/agreement/the-agreement-full-text/

Comisión Europea. (2024). *Living guidelines on the responsible use of generative AI in research*. Dirección General de Investigación e Innovación. https://research-and-innovation.ec.europa.eu

Committee on Publication Ethics [COPE]. (2023). *Authorship and AI tools: COPE position statement*. https://publicationethics.org/guidance/cope-position/authorship-and-ai-tools

Consejo de Educación Superior [CES]. (2022). *Reglamento de Régimen Académico* (Resolución RPC-SE-08-No.023-2022). Registro Oficial n.º 124.

Cui, H., y Yasseri, T. (2024). AI-enhanced collective intelligence. *Patterns, 5*(11), Artículo 101074. https://doi.org/10.1016/j.patter.2024.101074

Donthu, N., Kumar, S., Mukherjee, D., Pandey, N., y Lim, W. M. (2021). How to conduct a bibliometric analysis: An overview and guidelines. *Journal of Business Research, 133*, 285–296. https://doi.org/10.1016/j.jbusres.2021.04.070

Doshi, A. R., y Hauser, O. P. (2024). Generative AI enhances individual creativity but reduces the collective diversity of novel content. *Science Advances, 10*(28), Artículo eadn5290. https://doi.org/10.1126/sciadv.adn5290

Duede, E. (2023). Deep learning opacity in scientific discovery. *Philosophy of Science, 90*(5), 1089–1099. https://doi.org/10.1017/psa.2023.8

Dwivedi, Y. K., Kshetri, N., Hughes, L., Slade, E. L., Jeyaraj, A., Kar, A. K., Baabdullah, A. M., Koohang, A., Raghavan, V., Ahuja, M., Albanna, H., Albashrawi, M. A., Al-Busaidi, A. S., Balakrishnan, J., Barlette, Y., Basu, S., Bose, I., Brooks, L., Buhalis, D., … Wright, R. (2023). "So what if ChatGPT wrote it?" Multidisciplinary perspectives on opportunities, challenges and implications of generative conversational AI for research, practice and policy. *International Journal of Information Management, 71*, Artículo 102642. https://doi.org/10.1016/j.ijinfomgt.2023.102642

Gao, C. A., Howard, F. M., Markov, N. S., Dyer, E. C., Ramesh, S., Luo, Y., y Pearson, A. T. (2023). Comparing scientific abstracts generated by ChatGPT to real abstracts with detectors and blinded human reviewers. *npj Digital Medicine, 6*, Artículo 75. https://doi.org/10.1038/s41746-023-00819-6

Gao, S., Fang, A., Huang, Y., Giunchiglia, V., Noori, A., Schwarz, J. R., Ektefaie, Y., Kondic, J., y Zitnik, M. (2024). Empowering biomedical discovery with AI agents. *Cell, 187*(22), 6125–6151. https://doi.org/10.1016/j.cell.2024.09.022

Giray, L. (2023). Prompt engineering with ChatGPT: A guide for academic writers. *Annals of Biomedical Engineering, 51*(12), 2629–2633. https://doi.org/10.1007/s10439-023-03272-4

Hosseini, M., y Horbach, S. P. J. M. (2023). Fighting reviewer fatigue or amplifying bias? Considerations and recommendations for use of ChatGPT and other large language models in scholarly peer review. *Research Integrity and Peer Review, 8*, Artículo 4. https://doi.org/10.1186/s41073-023-00133-5

InterAcademy Partnership [IAP]. (2022). *Combatting predatory academic journals and conferences*. https://www.interacademies.org

International Committee of Medical Journal Editors [ICMJE]. (2023). *Recommendations for the conduct, reporting, editing, and publication of scholarly work in medical journals*. https://www.icmje.org/icmje-recommendations.pdf

Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O., Tunyasuvunakool, K., Bates, R., Žídek, A., Potapenko, A., Bridgland, A., Meyer, C., Kohl, S. A. A., Ballard, A. J., Cowie, A., Romera-Paredes, B., Nikolov, S., Jain, R., Adler, J., … Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature, 596*(7873), 583–589. https://doi.org/10.1038/s41586-021-03819-2

Kapoor, S., y Narayanan, A. (2023). Leakage and the reproducibility crisis in machine-learning-based science. *Patterns, 4*(9), Artículo 100804. https://doi.org/10.1016/j.patter.2023.100804

Koivisto, M., y Grassini, S. (2023). Best humans still outperform artificial intelligence in a creative divergent thinking task. *Scientific Reports, 13*, Artículo 13601. https://doi.org/10.1038/s41598-023-40858-3

Krenn, M., Pollice, R., Guo, S. Y., Aldeghi, M., Cervera-Lierta, A., Friederich, P., dos Passos Gomes, G., Häse, F., Jinich, A., Nigam, A., Yao, Z., y Aspuru-Guzik, A. (2022). On scientific understanding with artificial intelligence. *Nature Reviews Physics, 4*(12), 761–769. https://doi.org/10.1038/s42254-022-00518-3

Liang, W., Zhang, Y., Cao, H., Wang, B., Ding, D. Y., Yang, X., Vodrahalli, K., He, S., Smith, D. S., Yin, Y., McFarland, D. A., y Zou, J. (2024). Can large language models provide useful feedback on research papers? A large-scale empirical analysis. *NEJM AI, 1*(8). https://doi.org/10.1056/AIoa2400196

Liu, P., Yuan, W., Fu, J., Jiang, Z., Hayashi, H., y Neubig, G. (2023). Pre-train, prompt, and predict: A systematic survey of prompting methods in natural language processing. *ACM Computing Surveys, 55*(9), Artículo 195. https://doi.org/10.1145/3560815

Lund, B. D., Wang, T., Mannuru, N. R., Nie, B., Shimray, S., y Wang, Z. (2023). ChatGPT and a new academic reality: Artificial intelligence-written research papers and the ethics of the large language models in scholarly publishing. *Journal of the Association for*

Information Science and Technology, 74(5), 570–581. https://doi.org/10.1002/asi.24750

Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., y Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys, 54*(6), Artículo 115. https://doi.org/10.1145/3457607

Messeri, L., y Crockett, M. J. (2024). Artificial intelligence and illusions of understanding in scientific research. *Nature, 627*(8002), 49–58. https://doi.org/10.1038/s41586-024-07146-0

Miao, F., y Holmes, W. (2023). *Guidance for generative AI in education and research*. UNESCO. https://doi.org/10.54675/EWZM9535

Molnar, C. (2022). *Interpretable machine learning: A guide for making black box models explainable* (2.ª ed.). https://christophm.github.io/interpretable-ml-book/

National Institute of Standards and Technology [NIST]. (2023). *Artificial intelligence risk management framework (AI RMF 1.0)* (NIST AI 100-1). Departamento de Comercio de los Estados Unidos. https://doi.org/10.6028/NIST.AI.100-1

Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., y Qiao, M. S. (2021). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence, 2*, Artículo 100041. https://doi.org/10.1016/j.caeai.2021.100041

Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2021a). *Recomendación de la UNESCO sobre la ciencia abierta*. https://doi.org/10.54677/MNMH8546

Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2021b). *Recomendación sobre la ética de la inteligencia artificial*. Adoptada por la Conferencia General en su 41.ª reunión, 23 de noviembre de 2021.

Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura [UNESCO]. (2021c). *UNESCO science report: The race against time for smarter development*. UNESCO Publishing.

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., … Moher, D. (2021). The PRISMA 2020 statement: An updated

guideline for reporting systematic reviews. *BMJ, 372*, n71. https://doi.org/10.1136/bmj.n71

Parlamento Europeo y Consejo de la Unión Europea. (2024). Reglamento (UE) 2024/1689 por el que se establecen normas armonizadas en materia de inteligencia artificial. *Diario Oficial de la Unión Europea*, L 2024/1689.

Red Iberoamericana de Indicadores de Ciencia y Tecnología [RICYT]. (2025). *El estado de la ciencia 2025: Principales indicadores de ciencia y tecnología iberoamericanos/interamericanos*. RICYT, OEI y UNESCO.

Si, C., Yang, D., y Hashimoto, T. (2025). Can LLMs generate novel research ideas? A large-scale human study with 100+ NLP researchers. En *Proceedings of the Thirteenth International Conference on Learning Representations (ICLR 2025)*.

Szymanski, N. J., Rendy, B., Fei, Y., Kumar, R. E., He, T., Milsted, D., McDermott, M. J., Gallant, M., Cubuk, E. D., Merchant, A., Kim, H., Jain, A., Bartel, C. J., Persson, K., Zeng, Y., y Ceder, G. (2023). An autonomous laboratory for the accelerated synthesis of novel materials. *Nature, 624*(7990), 86–91. https://doi.org/10.1038/s41586-023-06734-w

Thorp, H. H. (2023). ChatGPT is fun, but not an author. *Science, 379*(6630), 313. https://doi.org/10.1126/science.adg7879

Tom, G., Schmid, S. P., Baird, S. G., Cao, Y., Darvish, K., Hao, H., Lo, S., Pablo-García, S., Rajaonson, E. M., Skreta, M., Yoshikawa, N., Corapi, S., Akkoc, G. D., Strieth-Kalthoff, F., Seifrid, M., y Aspuru-Guzik, A. (2024). Self-driving laboratories for chemistry and materials science. *Chemical Reviews, 124*(16), 9633–9732. https://doi.org/10.1021/acs.chemrev.4c00055

van de Schoot, R., de Bruin, J., Schram, R., Zahedi, P., de Boer, J., Weijdema, F., Kramer, B., Huijts, M., Hoogerwerf, M., Ferdinands, G., Harkema, A., Willemsen, J., Ma, Y., Fang, Q., Hindriks, S., Tummers, L., y Oberski, D. L. (2021). An open source machine learning framework for efficient and transparent systematic reviews. *Nature Machine Intelligence, 3*(2), 125–133. https://doi.org/10.1038/s42256-020-00287-7

Walters, W. H., y Wilder, E. I. (2023). Fabrication and errors in the bibliographic citations generated by ChatGPT. *Scientific Reports, 13*, Artículo 14045. https://doi.org/10.1038/s41598-023-41032-5

Wang, H., Fu, T., Du, Y., Gao, W., Huang, K., Liu, Z., Chandak, P., Liu, S., Van Katwyk, P., Deac, A., Anandkumar, A., Bergen, K., Gomes, C. P., Ho, S., Kohli, P., Lasenby, J., Leskovec, J., Liu, T.-Y., Manrai, A., … Zitnik, M. (2023). Scientific discovery in the age of artificial intelligence. *Nature, 620*(7972), 47–60. https://doi.org/10.1038/s41586-023-06221-2

Wang, L., Ma, C., Feng, X., Zhang, Z., Yang, H., Zhang, J., Chen, Z., Tang, J., Chen, X., Lin, Y., Zhao, W. X., Wei, Z., y Wen, J.-R. (2024). A survey on large language model based autonomous agents. *Frontiers of Computer Science, 18*(6), Artículo 186345. https://doi.org/10.1007/s11704-024-40231-1

EDITORIAL ANDES COGNITIO



Rafael Romero Carazas

Investigador Posdoctoral en Sabal University, Florida, Estados Unidos de América; estudiante de segundo Doctorado en Gobernabilidad y Gestión Pública Estratégica en la Universidad Nacional de San Agustín, Arequipa, Perú; Doctorado en Filosofía con enfoque en la complejidad y la investigación transdisciplinaria en Escuela Militar de Ingeniería (EMI) – Cochabamba - Bolivia, graduado con honores "Summa Cum Laude" ; estudiante de segunda maestría en Inteligencia Artificial en la Universidad Autónoma del Perú; Magister en Gerencia Pública en la Universidad Nacional Jorge Basadre Grohmann-Tacna, estudiante de segunda especialidad en Inteligencia Artificial para Educación en la Universidad Los Ángeles de Chimbote; Contador Público en la Universidad Peruana Unión-Lima, Condecoración y Reconocimiento en el "Premio Nacional Profesionales Excelencia del año 2025" por la Cámara Nacional de Comercio del Perú, Integrante de Colegio Oficial Internacional de Doctores, Miembro de la Red de Investigadores Científicos de América Latina y el Caribe (RED ICALC); Reconocimiento de "DOCTOR HONORIS CAUSA" por la Universidad del Norte de Tamaulipas - México; Integrante del Colegio de Contadores Públicos de Arequipa, revisor pares externos en revistas indexadas en Scopus, Web of Science, Scielo, expositor en diversos diplomados en Redacción de Artículos Científicos en Perú y el extranjero, Ponente en congresos de contabilidad, asesor de artículos científicos a jóvenes de pregrado y posgrado en diferentes universidades del Perú; investigador Renacyt por el CONCYTEC (nivel II), editor jefe de la Revista Científica Empresarial DEBE-HABER, integrante de dirección de investigación dirigida por el Colegio de Contadores Públicos de Arequipa.



Julio César Andrade Palacios

Ingeniero, magíster e investigador ecuatoriano especializado en administración, negocios y turismo sostenible. Obtuvo su título de Ingeniero en Empresas y Administración de Negocios en la Universidad Regional Autónoma de los Andes (2013) y el grado de Magíster en Administración de Empresas por la Universidad Israel (2022). Actualmente, se desempeña como docente en la Facultad de Ciencias Administrativas y Económicas de la Universidad Técnica del Norte (UTN) en Ibarra. En su trayectoria académica, destaca su rol como director de tesis, guiando el diseño de manuales administrativos, financieros y de control interno para el fortalecimiento de microempresas y organizaciones regionales. Como investigador del Centro de Universitarios de Investigación Científica y Tecnológica (CUICYT), ha liderado y colaborado en proyectos científicos y ponencias internacionales. Su producción académica abarca estudios sobre riesgos ergonómicos, cambio climático, marketing social y turismo sostenible en el Geoparque Imbabura. Su perfil profesional se complementa con una sólida formación continua en producción científica, herramientas tecnológicas aplicadas a los negocios, metodologías didácticas y gestión de plataformas virtuales.



Juan Carlos Tapia Cueva

Ingeniero Estadístico por la Universidad Central del Ecuador (2010), Magíster en Big Data y Ciencia de Datos (2023) y cuenta con un Diplomado en Econometría Aplicada (2026). Integra una sólida rigurosidad analítica con el dominio de herramientas clave como Python, R Studio, Power BI y Excel para el procesamiento, modelado cuantitativo y visualización de datos. Actualmente se desempeña como docente-investigador en la Facultad de Ciencias Administrativas y Económicas de la Universidad Técnica del Norte. Destaca como director y asesor de tesis en la carrera de Economía, impulsando el desarrollo de investigaciones de alto impacto. Asimismo, lidera la Coordinación de Vinculación con la Sociedad de los programas de Economía presencial y en línea, conectando la academia con la resolución de problemáticas territoriales. Su trayectoria profesional se consolida con la participación en múltiples proyectos de I+D universitarios y una constante actualización en metodologías de investigación científica y tecnologías aplicadas.



José Ricardo Arias

Ingeniero en Contabilidad y Auditoría (CPA) por la Universidad Técnica del Norte, donde ejerce como docente e investigador de la Facultad de Ciencias Administrativas y Económicas. Cuenta con dos maestrías, una en Agroempresas y Agronegocios y otra en Finanzas con mención en Dirección Financiera, además de un diplomado en Fintech. Integra el Grupo de Investigación en Gestión Financiera, Contabilidad y Auditoría (GIFCA). Su trabajo se centra en la educación financiera, las finanzas personales y la gestión empresarial. Ha publicado artículos en revistas del primer cuartil (Q1) y libros sobre educación financiera integral.



Milton Gabriel Del Hierro Mosquera

Ingeniero en Electrónica, Control y Redes Industriales, con Maestría en Redes de Computadoras y once años de experiencia en educación superior. Se desempeña como docente universitario y participa activamente en proyectos de investigación, vinculación. Trabaja en áreas relacionadas con redes de comunicaciones, automatización, matemáticas, y tecnologías educativas.

ISBN: 978-9907-9566-6-5