Contactos, Revista de Educación en Ciencias e Ingeniería

Octubre - Diciembre 2026 ISSN:2683-2607

Número Especial. Área de Optimización e IA

No. 148



ESTUDIO EXPLORATORIO SOBRE LA TRANSFORMACIÓN DE LA NARRATIVA PROFESIONAL DE LA INGENIERÍA ANTE LA EXPANSIÓN DE LA INTELIGENCIA ARTIFICIAL

MÁS ALLÁ DE LA RESPUESTA: INTELIGENCIA ARTIFICIAL Y CONSTRUCCIÓN AUMENTADA DEL CONOCIMIENTO CIENTÍFICO

CONFIANZA CIEGA: LO QUE LA EVIDENCIA DE 2025-2026 DICE SOBRE NUESTRA RELACIÓN CON LA INTELIGENCIA ARTIFICIAL

Imagen creada con IA generativa — OpenAI / ChatGPT

Casa abierta al tiempo | UNIVERSIDAD AUTÓNOMA METROPOLITANA

Revista de las divisiones de CBI y CBS

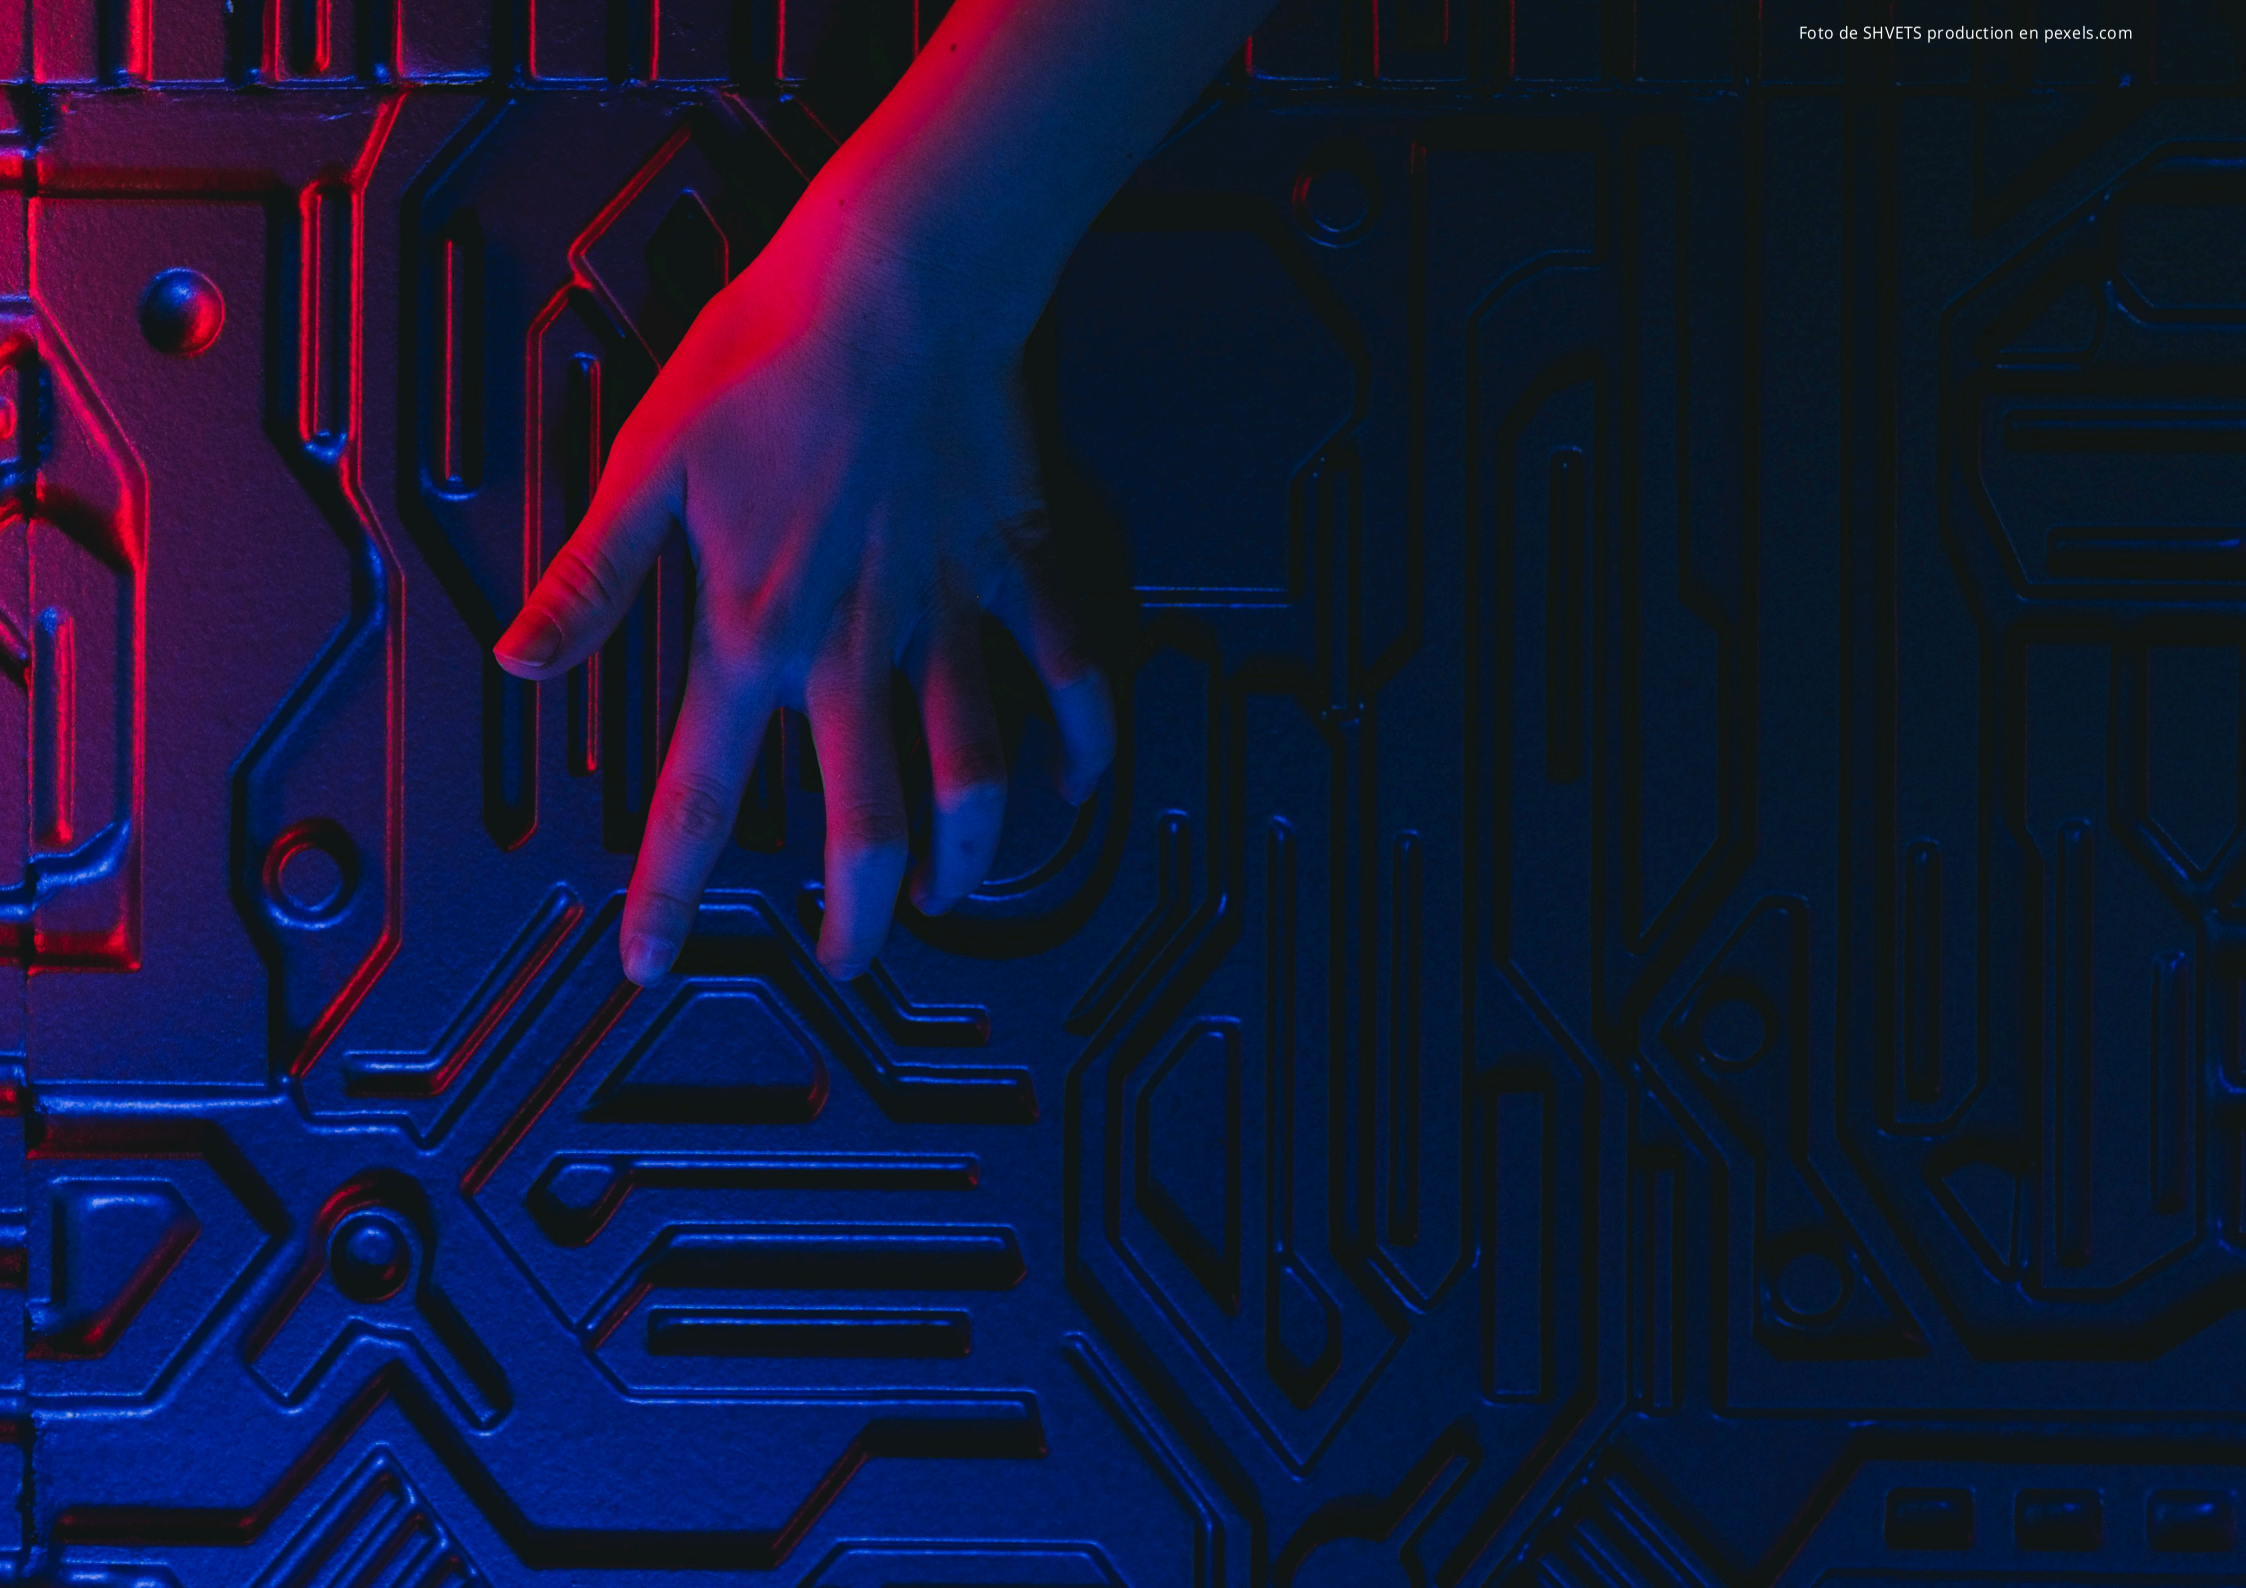

Foto de SHVETS production en pexels.com

Contenido

Contactos, Revista de Educación en Ciencias e Ingeniería

No. 148 Octubre - Diciembre 2026

Editorial 3

Estudio exploratorio sobre la transformación de la narrativa profesional de la ingeniería ante la expansión de la inteligencia artificial 5

Dr. Edwin Montes Orozco
Dr. Roman Anselmo Mora Gutiérrez
Dr. Eric Alfredo Rincón García
Dr. Sergio Gerardo de los Cobos Silva
Dr. Miguel Ángel Gutiérrez Andrade
Dr. Pedro Lara Velázquez
Dra. Fabiola Margarita Martínez Licona
MC Alma Martínez Licona

Más allá de la respuesta: inteligencia artificial y construcción aumentada del conocimiento científico 44

Dr. Roman Anselmo Mora Gutiérrez
Dr. Eric Alfredo Rincón García
Dr. Sergio Gerardo de los Cobos Silva
Dr. Miguel Ángel Gutiérrez Andrade
Dr. Edwin Montes Orozco
Dr. Pedro Lara Velázquez
Dra. Fabiola Margarita Martínez Licona
MC Alma Martínez Licona

Confianza ciega: lo que la evidencia de 2025-2026 dice sobre nuestra relación con la inteligencia artificial 68

Dr. Eric Alfredo Rincón García
Dr. Sergio Gerardo de los Cobos Silva
Dr. Miguel Ángel Gutiérrez Andrade
Dr. Roman Anselmo Mora Gutiérrez
Dr. Edwin Montes Orozco
Dr. Pedro Lara Velázquez
MC Alma Edith Martínez Licona
Dra. Fabiola Margarita Martínez Licona

Entre el mito, la leyenda y la historia: crónicas sobre el desarrollo de la inteligencia artificial 81

Dr. Pedro Lara Velázquez
Dr. Miguel Ángel Gutiérrez Andrade
Dr. Eric Alfredo Rincón García
Dr. Sergio Gerardo de los Cobos Silva
Dr. Roman Anselmo Mora Gutiérrez
Dr. Edwin Montes Orozco
MC Alma Edith Martínez Licona
Dra. Fabiola Margarita Martínez Licona

Evolución del esfuerzo salarial para adquirir una vivienda en México, 2005–2024 99

Dr. Sergio Gerardo de los Cobos Silva
Dr. Miguel Ángel Gutiérrez Andrade
Dr. Eric Alfredo Rincón García
Dr. Roman Anselmo Mora Gutiérrez
Dr. Pedro Lara Velázquez
MC Alma Edith Martínez Licona
Dra. Fabiola Margarita Martínez Licona
Dr. Edwin Montes Orozco

Contactos, Revista de Educación en Ciencias e Ingeniería en la WEB

Lea los artículos publicados en
https://contactos.izt.uam.mx

Casa abierta al tiempo
UNIVERSIDAD AUTÓNOMA METROPOLITANA

CONACYT
ÍNDICE DE REVISTAS MEXICANAS
DE DIVULGACIÓN CIENTÍFICA Y TECNOLÓGICA

Rector General
Dr. Gustavo Pacheco López
Secretaria General
Dra. Esthela Irene Sotelo Núñez

UNIDAD IZTAPALAPA
Rectora
Dra. Edith Ponce Alquicira
Secretario
Dr. Javier Rodríguez Lagunas
Director de la División de Ciencias Básicas e Ingeniería
Dr. Juan Morales Corona
Directora de la División de Ciencias Biológicas y de la Salud
Dra. Edith Arenas Ríos

Contactos, Revista de Educación en Ciencias e Ingeniería:
Consejo Editorial:
Dra. Edith Ponce Alquicira
Dr. Javier Rodríguez Lagunas
Dr. Juan Morales Corona
Dra. Edith Arenas Ríos
UAM- Iztapalapa
Editora en Jefe:
M. C. Alma Edith Martínez Licona
Asistente Editorial:
Ing. Gabriela López Rodríguez
Comité Editorial por CBS:
Dra. Laura Josefina Pérez Flores,
Dr. Pedro Luis Valverde Padilla,
Dra. Herlinda Bonilla Jaime
Por CBI:
Dr. Hugo Ávila Paredes
Por la Universidad Iberoamericana:
Mtro. Adolfo G. Fink Pastrana

CONTACTOS, REVISTA DE EDUCACIÓN EN CIENCIAS E INGENIERÍA.
3ª Época, No. 148, Octubre - Diciembre 2026, es una publicación trimestral de la Universidad Autónoma Metropolitana a través de la Unidad Iztapalapa, División de Ciencias Básicas e Ingeniería y División de Ciencias Biológicas y de la Salud. Av. Prolongación Canal de Miramontes 3855, Col. Rancho los Colorines, Alcaldía Tlalpan, C.P. 14386, México, Ciudad de México y Av. Ferrocarril San Rafael Atlixco 186, Col. Leyes de Reforma 1a Sección, Iztapalapa, Cd. de México. C.P. 09310, Edificio T144, Tel. 5804 – 4600. Ext. 1144. Página electrónica de la revista: https://contactos.izt.uam.mx/ y dirección electrónica: cts@xanum.uam.mx Editora responsable MC Alma E. Martínez Licona. Certificado de Reserva de Derechos al Uso Exclusivo de Título No. 04-2023-061914482700-102, ISSN 2683-2607, ambos otorgados por el Instituto Nacional del Derecho de Autor. Responsable de la última actualización de este número, Mtra. Alma E. Martínez Licona; Unidad Iztapalapa, División de CBI y CBS; fecha de última modificación 31 de Diciembre de 2026. Tamaño del archivo 60 MB.

Las opiniones expresadas por los autores no necesariamente reflejan la postura del editor de la publicación.

Queda estrictamente prohibida la reproducción total o parcial de los contenidos e imágenes de la publicación sin previa autorización de la Universidad Autónoma Metropolitana.

Fecha de Publicación:
Octubre - Diciembre 2026.

Los artículos publicados en **Contactos, Revista de Educación en Ciencias e Ingeniería** son sometidos a arbitraje; para ello se requiere enviar el trabajo en Word a https://contactos.izt.uam.mx/
Revista de Educación en Ciencias e Ingeniería,
UAM – Iztapalapa, T144, Tel. 5804-4600. Ext. 1144
Av. Ferrocarril San Rafael Atlixco 186. C.P. 09310
e-mail cts@xanum.uam.mx

Editorial

Estimados lectores ante todo reciban un cordial saludo del Área de Optimización e Inteligencia Artificial (OIA) del departamento de Ingeniería Eléctrica de la UAM Iztapalapa. Queremos agradecer especialmente a la editora M. en C. Alma E. Martínez Licona y a todas las personas que trabajan en la Revista Contactos. Hemos escrito cinco artículos que esperamos sean de interés puesto que cuatro nos hablan sobre el tema de actualidad y que pensamos que es una moda que llego para quedarse que es la Inteligencia artificial (IA). Se examina lo que la evidencia reciente de 2025-2026 revela sobre la creciente dependencia de la sociedad respecto a la inteligencia artificial. También aborda otros riesgos, como el fraude generado por IA. Se presenta una visión general, tanto cronológica como conceptual, de la evolución de la Inteligencia Artificial (IA), narrada a través de una serie de crónicas interconectadas. Se propone entender la inteligencia artificial no como una fuente autónoma de conocimiento, sino como un elemento potenciador integrado en un proceso iterativo y se comparan los resultados obtenidos por distintos modelos de IA ante preguntas idénticas con el fin de identificar convergencias, divergencias, contradicciones y variaciones derivadas de la herramienta empleada. Se analiza, desde una perspectiva exploratoria respeto a la IA, las características atribuidas al perfil profesional de la ingeniería contemporánea a través de tres enfoques complementarios: (a) la perspectiva académica, (b) la narrativa social y científica, y (c) la perspectiva profesional.

El quinto trabajo nos muestra que el ingreso es inversamente proporcional al tiempo es decir que va disminuyendo en pesos reales, en cambio los precios de la vivienda crecen de manera acelerada con respecto al tiempo en termino de precios reales, este estudio se realizó con información oficial.

Esperamos que la diversidad de estos trabajos resulte de interés para nuestros lectores y contribuya a la reflexión sobre algunos de los principales desafíos científicos, tecnológicos y sociales de la actualidad.

Atentamente
Dr. Sergio Gerardo de los Cobos Silva

Información para autores

Contactos, Revista de Educación en Ciencias e Ingeniería, Revista dirigida a profesores y a estudiantes de estas disciplinas. Está registrada en el índice de revistas de divulgación de Conacyt, así como en Latindex, Sistema Regional de Información en Línea para Revistas Científicas de América Latina, el Caribe, España y Portugal. Para publicar, los trabajos deberán ser originales y accesibles a un público amplio con formación media superior o universitaria pero no especializada; los temas deberán presentarse en forma clara. Cada colaboración debe incluir figuras, diagramas, ilustraciones, fotografías, etc. (otorgando el crédito correspondiente en caso de no ser original), que hagan más accesible la presentación.

Las secciones que la constituyen son:

Artículos que presentan temas científicos con enfoques novedosos y accesibles (15 cuartillas).

1. Divulgación. Artículos que presentan temas científicos con enfoques novedosos y accesibles (15 cuartillas).

2. Educación científica. Enfoques originales en la enseñanza de temas particulares (15 cuartillas).

3. Artículos especializados. Reportes breves de investigación, relacionados con una problemática concreta (15 cuartillas).

4. Crónicas. Enfoques originales en la enseñanza de temas particulares (15 cuartillas).

5. Divertimentos. Juegos y acertijos intelectuales (5 cuartillas).

6. Noticias breves. Información de actualidad en el mundo de la ciencia (4 cuartillas).

7. Los laureles de olivo. Los absurdos de la vida cotidiana y académica (4 cuartillas).

En todos los casos se debe incluir los nombres completos de los autores con su adscripción, dirección, teléfono y dirección de correo electrónico.

Normas

Las colaboraciones a las secciones 1 a 4 deberán ajustarse a las siguientes normas:

1. Resumen escrito en español e inglés.
2. 4 palabras clave en español e inglés.
3. Cuando se incluya una abreviatura debe explicarse por una sola vez en la forma siguiente: Organización de los Estados Americanos (OEA). . .
4. Cuando se utilice un nombre técnico o una palabra característica de una disciplina científica deberá aclararse su significado de la manera más sencilla posible.
5. Las citas textuales deberán ir de acuerdo al siguiente ejemplo: En cuanto a la publicación del placebo se asevera que "el efecto placebo desapareció cuando los comportamientos se estudiaron en esta forma" (Núñez, 1982, p.126).
6. Las referencias (no más de 10) se marcarán de acuerdo al siguiente ejemplo: Sin embargo, ese no es el punto de vista de la Escuela de Copenhague (Heisenberg, 1958), que insiste en...
7. Al final del artículo se citarán las referencias por orden alfabético de autores. Pueden añadirse lecturas recomendadas (no más de 5).
8. Cada referencia a un artículo debe ajustarse al siguiente formato: Szabadváry, F. y Oesper, E., Development of the pH concept, J. Chem. Educ, 41 [2], pp.105 -107, 1964.
9. Cada referencia a un libro se ajustará al siguiente formato: Heisenberg, W., Physics and Philosophy. The Revolution in Modern Science, Harper Torchbook, Nueva York, pp.44-58, 1958.
10. Para páginas electrónicas: dirección (fecha de acceso).
11. Los títulos de reportes, memorias, etcétera, deben ir subrayados o en itálicas.

Envío y características del artículo

El envío del artículo deberá ser en archivo electrónico, en Word, tipo de letra Times New Roman, tamaño 12 con interlineado sencillo y uso de editor de ecuaciones.

En el caso de ilustraciones por computadora (BMP, JPG, TIFF, etc.) envíelos en archivos por separado. El material es recibido en:

Contactos, Revista de Educación en Ciencias e Ingeniería.
UAM – Iztapalapa, T144,
Información: cts@xanum.uam.mx,
Tel. 5804-4600. Ext. 1144.
Av. Ferrocarril San Rafael Atlixco 186.
C.P. 09310

Arbitraje

El Comité utiliza un sistema de arbitraje anónimo que requiere un mes. Se entiende que los autores no han enviado su artículo a otra revista y que dispondrán de un plazo máximo de un mes para incorporar las observaciones de los árbitros. La decisión final de publicar un artículo es responsabilidad exclusiva del Comité Editorial.

Estudio exploratorio sobre la transformación de la narrativa profesional de la ingeniería ante la expansión de la inteligencia artificial



Dr. Edwin Montes Orozco*
Dr. Roman Anselmo Mora Gutiérrez**
Dr. Eric Alfredo Rincón García***
Dr. Sergio Gerardo de los Cobos Silva***
Dr. Miguel Ángel Gutiérrez Andrade***
Dr. Pedro Lara Velázquez ***
Dra. Fabiola Margarita Martínez Licona***
MC Alma Martínez Licona***

* Departamento de Computación, Electrónica y Mecatrónica, Universidad de las Américas Puebla
** Departamento de Sistemas, Universidad Autónoma Metropolitana, Unidad Azcapotzalco
*** Departamento de Ingeniería Eléctrica, Universidad Autónoma Metropolitana, Unidad Iztapalapa

Imagen creada con IA generativa — OpenAI / ChatGPT

Abstract
This study analyzes, from an exploratory perspective, the characteristics attributed to the contemporary engineering professional profile through three complementary perspectives: (a) the academic perspective, constructed from the ways in which higher education institutions conceptualize engineering and define their graduates' profiles; (b) the social and scientific narrative, identified in discourses found in news articles, scientific publications, and social media communications; and (c) the professional perspective, represented by the competencies and characteristics demanded by the labor market.

The documentary corpora were constructed using convenience sampling. Their analysis combined data science techniques, natural language processing, and complex network analysis, supported by generative artificial intelligence tools. This approach made it possible to identify recurrent actions, concepts, competencies, actors, and relationships within each corpus, as well as to recognize similarities and differences among the three perspectives analyzed.

Preliminary results indicate that problem solving, solution design, and the application of scientific, mathematical, and technological knowledge remain central components of the engineering professional profile. However, around this technical core, capabilities related to communication, collaborative work, adaptability, and continuous learning increasingly emerge, together with greater consideration of the economic, social, and environmental dimensions associated with engineering solutions. These findings suggest a broadening of the engineering professional profile in the context of Industry 5.0, in which technical competencies are increasingly articulated with human capabilities and with greater attention to the context in which engineering solutions are designed and implemented.

Keywords: professional profile, professional education, labor market, social narratives, technological change.

Resumen
En el presente trabajo se analizan, desde un enfoque exploratorio, las características atribuidas al perfil contemporáneo del ingeniero a partir de tres perspectivas complementarias: a) la académica, construida a partir de la manera en que las instituciones de educación superior conceptualizan la ingeniería y definen los perfiles de sus egresados; b) la narrativa social y científica, identificada en los discursos presentes en noticias, artículos científicos y comunicaciones en redes; y c) la profesional, integrada por las competencias y características demandadas por el mercado laboral.

Los corpus documentales se conformaron mediante un muestreo por conveniencia. Para su estudio se combinaron técnicas de ciencia de datos, de procesamiento de lenguaje natural y de análisis de redes complejas, apoyadas por herramientas de inteligencia artificial generativa. Este enfoque permitió identificar acciones, conceptos, competencias, actores y relaciones recurrentes en cada corpus, así como reconocer coincidencias y diferencias entre las tres perspectivas analizadas.

Los resultados preliminares muestran que la resolución de problemas, el diseño de soluciones y la aplicación de conocimientos científicos, matemáticos y tecnológicos continúan constituyendo componentes centrales del perfil del

ingeniero. Sin embargo, alrededor de este núcleo técnico adquieren presencia recurrente capacidades relacionadas con la comunicación, el trabajo colaborativo, la adaptación y el aprendizaje continuo, así como la consideración de las dimensiones económicas, sociales y ambientales asociadas a las soluciones de ingeniería. Estos hallazgos sugieren una ampliación del perfil profesional del ingeniero en el contexto de la Industria 5.0, en el que las competencias técnicas se articulan cada vez más con capacidades humanas y con una mayor atención al contexto en el que se diseñan e implementan las soluciones.

Palabras clave: perfil profesional, formación profesional, mercado laboral, narrativa social y cambios tecnológicos.

1. Introducción:

El lenguaje no constituye un sistema estático. Cambia, se adapta y adquiere nuevos significados a medida que se modifican las prácticas, los actores y los contextos sociales en los que se utiliza. Al mismo tiempo que permite describir la realidad, también participa en su construcción, pues las palabras no solo nombran objetos o fenómenos, sino que organizan formas de comprenderlos y relacionarse con ellos. Rivera-Ramírez (2017) plantea esta dinámica mediante la metáfora de un sistema de engranajes, en el que cada elemento depende de otros, los moviliza y, a su vez, es transformado por ellos.

Desde esta perspectiva, la idea de ingeniería es un constructo social cuyo significado se desplaza entre distintos ámbitos. En el ámbito científico, suele asociarse con conocimientos, métodos y procedimientos orientados a la formulación y resolución de problemas complejos (Lerch & de Vedia (2013)). En los discursos gubernamentales se vincula con infraestructura, innovación, desarrollo tecnológico, bienestar social un agente de trasformación social (Secretaría de Infraestructura, Comunicaciones y Transportes [SICT], 2026). En el ámbito educativo, se relaciona con procesos de formación técnica, profesional y de posgrado, (Asociación Nacional de Universidades e Instituciones de Educación Superior [ANUIES], s. f.) con ello se busca la formación de profesionales capaces de integrar competencias y conocimientos especializados que les permitan incorporarse al mercado laboral y desempeñarse en él. Paralelamente, en el ámbito cotidiano, la idea y el concepto de ingeniería circulan a través de experiencias individuales, series televisivas, películas, memes, chistes, ceremonias, estereotipos ocupacionales y relatos familiares. En estos espacios, la ingeniería se asocia no solo con atributos como el prestigio profesional, la dificultad de la formación académica, la estabilidad económica o la posibilidad de movilidad social, sino también con determinadas formas de vestir, comportamientos, capacidades, responsabilidades y expectativas acerca de lo que un ingeniero es y debe hacer. Estas ideas no deben entenderse como definiciones independientes ni necesariamente contradictorias. Por el contrario, las coincidencias, desplazamientos y tensiones entre los distintos discursos constituyen un espacio relevante para analizar cómo se construye socialmente la figura del ingeniero.

Lo anterior pone de manifiesto el carácter polisémico de la ingeniería, cuyo significado no se limita a una definición estática, sino que se ha construido históricamente y continúa transformándose mediante la

interacción entre discursos académicos, científicos, industriales, institucionales, laborales, culturales y cotidianos, entre otros. En este proceso intervienen diversos actores que producen, reproducen, modifican y disputan los significados asociados con la ingeniería. Como resultado de estas interacciones se configura una representación social más amplia de qué es la ingeniería, qué actividades comprende, qué conocimientos y capacidades se le atribuyen, qué responsabilidades se esperan de quienes la ejercen y qué características se asocian socialmente con la figura del ingeniero.

Aunado a lo anterior, a partir de 2022 la masificación de herramientas de inteligencia artificial generativa (McKinsey & Company. (2024) e IBM (2024)), denotada como IAG, ha contribuido a reconfigurar distintos ámbitos de la actividad profesional y tecnológica. Esta inflexión no se limita a la incorporación de nuevas herramientas de cálculo, diseño o automatización, sino que también modifica la distribución de tareas, competencias y responsabilidades en diversas profesiones. En el ámbito de la ingeniería, los modelos de inteligencia artificial generativa pueden apoyar actividades como el diagnóstico de fallas, la generación de alternativas de diseño, la redacción de reportes técnicos o la producción de código para resolver determinados problemas.

Lo anterior conduce a una pregunta central: ¿qué actividades propias de la ingeniería no pueden ser realizadas en su totalidad por una máquina y, en consecuencia, qué elementos continúan definiendo el quehacer del ingeniero? Resultaría simplista plantear una competencia directa entre personas y máquinas o sistemas de inteligencia artificial. Más que sustituir de manera lineal el quehacer humano, estas tecnologías pueden redistribuir tareas, automatizar actividades repetitivas y apoyar procesos analíticos, creativos y de toma de decisiones. Desde esta perspectiva, el interés no radica únicamente en determinar qué actividades puede realizar una máquina, sino en examinar de qué manera la inteligencia artificial puede ampliar, complementar o transformar el conjunto de conocimientos, capacidades, herramientas y responsabilidades asociadas con una profesión. En otras palabras, si una inteligencia artificial puede generar código, proponer alternativas de diseño, identificar patrones o asistir en el diagnóstico de fallas, adquieren mayor relevancia funciones como la formulación de problemas, la interpretación de contextos, la valoración de restricciones, la toma de decisiones bajo incertidumbre, la integración de conocimientos provenientes de diferentes campos y la responsabilidad sobre las consecuencias técnicas, sociales, económicas y ambientales de las soluciones desarrolladas.

El objetivo del presente trabajo es analizar la narrativa social contemporánea en torno a la ingeniería a partir de tres planos complementarios. El primero corresponde al discurso institucional y académico, orientado a identificar cómo se concibe a las personas formadas en ingeniería, qué conocimientos, capacidades, competencias y responsabilidades se espera que desarrollen y qué características se consideran propias de su formación profesional. El segundo plano corresponde al contexto social y cultural, en el que la figura del ingeniero se construye mediante distintas formas de representación y relación social,

como la autopercepción profesional, los memes, chistes, noticias, discursos gubernamentales y artículos científicos. En este nivel interesa analizar cómo se percibe socialmente al ingeniero, con qué atributos, comportamientos, capacidades, responsabilidades y estereotipos se le relaciona y qué elementos participan en la construcción de su identidad profesional. Finalmente, el tercer plano corresponde al mercado laboral, desde el cual se examinan las funciones, competencias, conocimientos y capacidades que actualmente se demandan a quienes ejercen la ingeniería.

El modelo conceptual empleado en el presente trabajo se basa en Csikszentmihalyi & Wolfe, (2015), Mora-Gutiérrez *et al.* (2014) Mora-Gutierrez (2013), implica que las personas aprenden de su experiencia e intercambian información dentro de una red social dinámica, configurando con ello el conocimiento individual, local y social. En esta idealización se establecen tres escalas: a) micro, interpretación individual del ambiente; b) meso, modificación e intercambio mediante discursos y artefactos; y c) macro, posible estabilización de patrones recurrentes como narrativas sociales o convenciones culturales, que retroalimentan el ambiente. Lo anetiror se esquematiza en la Figura 1



Figura 1: Modelo conceptual de la ingeniería como constructo social. Nota. Figura generada con apoyo de OpenAI a partir de Csikszentmihalyi & Wolfe, (2015), Mora-Gutiérrez *et al.* (2014) Mora-Gutierrez (2013)

Los planos analizados en relación con la ingeniería corresponden a la escala meso del modelo conceptual. Para avanzar hacia la caracterización de la escala macro, el estudio se orienta mediante la siguiente pregunta: ¿qué coincidencias, diferencias y tensiones emergen entre la concepción institucional de la ingeniería, las representaciones sociales asociadas con la figura del ingeniero y las expectativas que el mercado laboral establece sobre su ejercicio profesional?

El trabajo tiene un carácter exploratorio y no pretende construir una representación única ni generalizable de la ingeniería en México. Tampoco se circunscribe a una rama específica de la profesión. Su propósito es identificar patrones discursivos, núcleos semánticos y elementos compartidos que permitan comprender cómo se construyen actualmente las nociones de ingeniería y de quienes la ejercen en los ámbitos académico, institucional, social y laboral.

El presente trabajo se divide de la siguiente manera, en la sección 2 se presenta un breve estado del arte del concepto de ingeniería, además se caracteriza la formación en áreas de ingeniería en México. En la sección tres se exhibe la metodología a que se usó en el presente la cual va desde la colecta y limpieza de información su análisis e identificación de patrones. La sección siguiente es de análisis de resultados y finalmente la sección seis es de conclusiones y trabajos futuros.

2. Estado del arte

a. Concepto de ingeniera

Ramírez *et al.* (2011) examinan las transformaciones que ha experimentado el concepto de ingeniería a lo largo del tiempo. Para ilustrar este proceso, pueden contrastarse definiciones formuladas en diferentes momentos históricos. En 1947, el Engineers' Council for Professional Development (ECPD) definió la ingeniería como la aplicación creativa de principios científicos al diseño, desarrollo, construcción y operación de estructuras, máquinas, dispositivos y procesos, así como a la predicción de su comportamiento bajo condiciones específicas. Esta actividad debía considerar la función prevista, la economía de operación y la seguridad de las personas y los bienes (ECPD, 1947; Encyclopaedia Britannica, s. f.; Koehn, 2011). La definición se concentra en el diseño y la operación de soluciones técnicas, pero también incorpora la previsión de su comportamiento, la funcionalidad, la eficiencia y la seguridad.

En una formulación contemporánea, Protecnium (2025) describe la ingeniería como la combinación de ciencia, tecnología y creatividad para diseñar, construir y mantener estructuras, máquinas, sistemas y procesos destinados a responder a necesidades humanas o industriales. Desde esta perspectiva, la ingeniería no se limita a los objetos que se diseñan o construyen, sino que comprende la identificación de problemas y la articulación de procesos racionales, tecnológicos y creativos mediante los cuales las necesidades se transforman en soluciones funcionales.

La Figura 2 presenta una comparación entre ambas definiciones. De manera preliminar, el contraste permite identificar un núcleo conceptual compartido: la aplicación e integración del conocimiento científico, la creatividad y la intervención deliberada para alcanzar un propósito dentro

de un contexto determinado. Las diferencias observadas sugieren que la concepción de la ingeniería no permanece invariable, sino que puede responder a las condiciones históricas, sociales, económicas y tecnológicas en las que se formula. Esta comparación tiene una finalidad ilustrativa, pues las dos definiciones proceden de instituciones con naturaleza, autoridad y propósitos distintos.

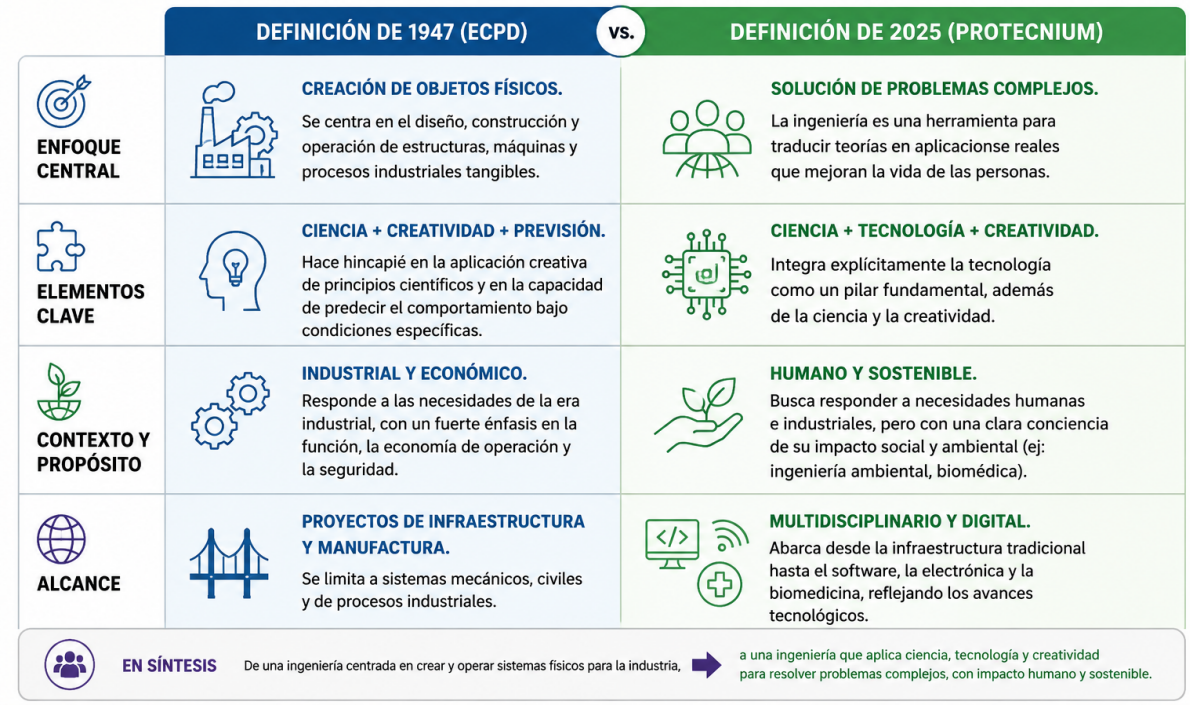

Figura 2: Comparación de la concepción de la ingeniería en dos momentos históricos. Nota. Figura generada con apoyo de OpenAI a partir de las definiciones previamente citadas, analizadas y contextualizadas por los autores.

A partir de este planteamiento surge una segunda pregunta: cuando se mantiene relativamente constante el periodo histórico y el contexto general, ¿las instituciones, los organismos y los actores que integran un mismo sistema comparten una concepción común de la ingeniería o coexisten interpretaciones diferentes? Esta pregunta permite examinar si el núcleo conceptual de la ingeniería permanece estable entre los distintos componentes del sistema y si las variaciones se concentran en los conocimientos, atributos, propósitos, responsabilidades y formas de actuación que cada actor considera relevantes.

Para explorar esta cuestión, se analiza inicialmente la concepción de la ingeniería en los ámbitos académico e institucional. Con este propósito, se examinan doce definiciones procedentes de universidades, institutos y organismos relacionados con la formación, regulación o acreditación de la ingeniería.

El análisis busca identificar los componentes compartidos, las diferencias entre las formulaciones y las relaciones semánticas establecidas entre sus actores, acciones y conceptos.

En la Tabla 1 se presentan las instituciones seleccionadas, los fragmentos textuales utilizados como evidencia y, cuando corresponde, su traducción al español. Debe señalarse que estas formulaciones no poseen necesariamente el mismo alcance. Mientras algunas expresan atributos generales asociados a la formación en ingeniería, otras corresponden a perfiles de egreso, resultados de aprendizaje, objetivos educativos o descripciones de programas particulares. Por ello, se consideran aquí como figuraciones institucionales de la ingeniería, es decir, representaciones que permiten aproximarse a la manera en que distintas entidades académicas conciben al ingeniero, su actuación, los conocimientos que moviliza, los problemas sobre los que interviene y las responsabilidades asociadas a su práctica.

Institución u organismo	Evidencia institucional	Traducción al español
Consejo de Acreditación de la Enseñanza de la Ingeniería (CACEI)	“Diseña soluciones creativas a problemas de ingeniería complejos y diseña sistemas, componentes o procesos para satisfacer las necesidades identificadas” (CACEI, 2024).	No aplica: la fuente original está en español.
Harvard John A. Paulson School of Engineering and Applied Sciences	“Apply engineering design to produce solutions that meet specified needs with consideration of public health, safety, and welfare” (Harvard SEAS, s. f.).	Aplicar el diseño de ingeniería para producir soluciones que satisfagan necesidades específicas, considerando la salud, la seguridad y el bienestar públicos.
University of Oxford	“The course involves the application of creative reasoning, science, mathematics (and, of course, experience and common sense) to real problems” (University of Oxford, 2026).	El programa implica aplicar el razonamiento creativo, la ciencia, las matemáticas, la experiencia y el sentido común a problemas reales.
Massachusetts Institute of Technology (MIT)	“Recognize ethical and professional responsibilities in engineering situations and make informed judgments” (MIT, s. f.).	Reconocer las responsabilidades éticas y profesionales en situaciones de ingeniería y emitir juicios informados.
Stanford University	“An ability to communicate effectively and to work in diverse and interdisciplinary teams to accomplish objectives” (Stanford University, 2026).	Capacidad para comunicarse eficazmente y trabajar en equipos diversos e interdisciplinarios con el fin de alcanzar objetivos.
University of Cambridge	“Develop an awareness of the responsibilities of engineers in economic, social and environmental matters” (University of Cambridge, s. f.).	Desarrollar conciencia sobre las responsabilidades de los ingenieros en asuntos económicos, sociales y ambientales.
Imperial College London	“Explain the importance of ethical standards. Explain the principles of sustainability and methods for applying them in practical situations” (Imperial College London, 2026).	Explicar la importancia de las normas éticas, los principios de sostenibilidad y los métodos para aplicarlos en situaciones prácticas.
ETH Zürich	“Apply mathematical models and scientific knowledge to design technical systems; critically analyse arguments and assumptions” (ETH Zürich, 2024).	Aplicar modelos matemáticos y conocimientos científicos para diseñar sistemas técnicos, así como analizar críticamente argumentos y supuestos.
Universidad Nacional Autónoma de México, Facultad de Ingeniería	“Poseerá aptitudes y habilidades que le permitirán actuar con responsabilidad y con vocación de servicio a la sociedad e integrar grupos interdisciplinarios” (UNAM, s. f.).	No aplica: la fuente original está en español.
Universidad Autónoma Metropolitana, Unidad Azcapotzalco	“Ejercer su profesión en un contexto de compromiso social, sustentabilidad, responsabilidad y ética profesional” (UAM Azcapotzalco, s. f.).	No aplica: la fuente original está en español.
Instituto Politécnico Nacional	“Sustentado en valores éticos y de responsabilidad, con un enfoque sistémico y con actitud crítica y de liderazgo” (IPN, s. f.).	No aplica: la fuente original está en español.
University of California, Berkeley	“An ability to communicate effectively with a range of audiences” (UC Berkeley, s. f.).	Capacidad para comunicarse eficazmente con audiencias diversas.

Tabla 1: Concepciones académicas de Ingeniería.

La información anterior muestra que, incluso entre agentes situados en un mismo contexto y periodo, coexisten distintas figuraciones de la ingeniería. No obstante, estas comparten un núcleo conceptual, cuya configuración se representa en la Figura 3.

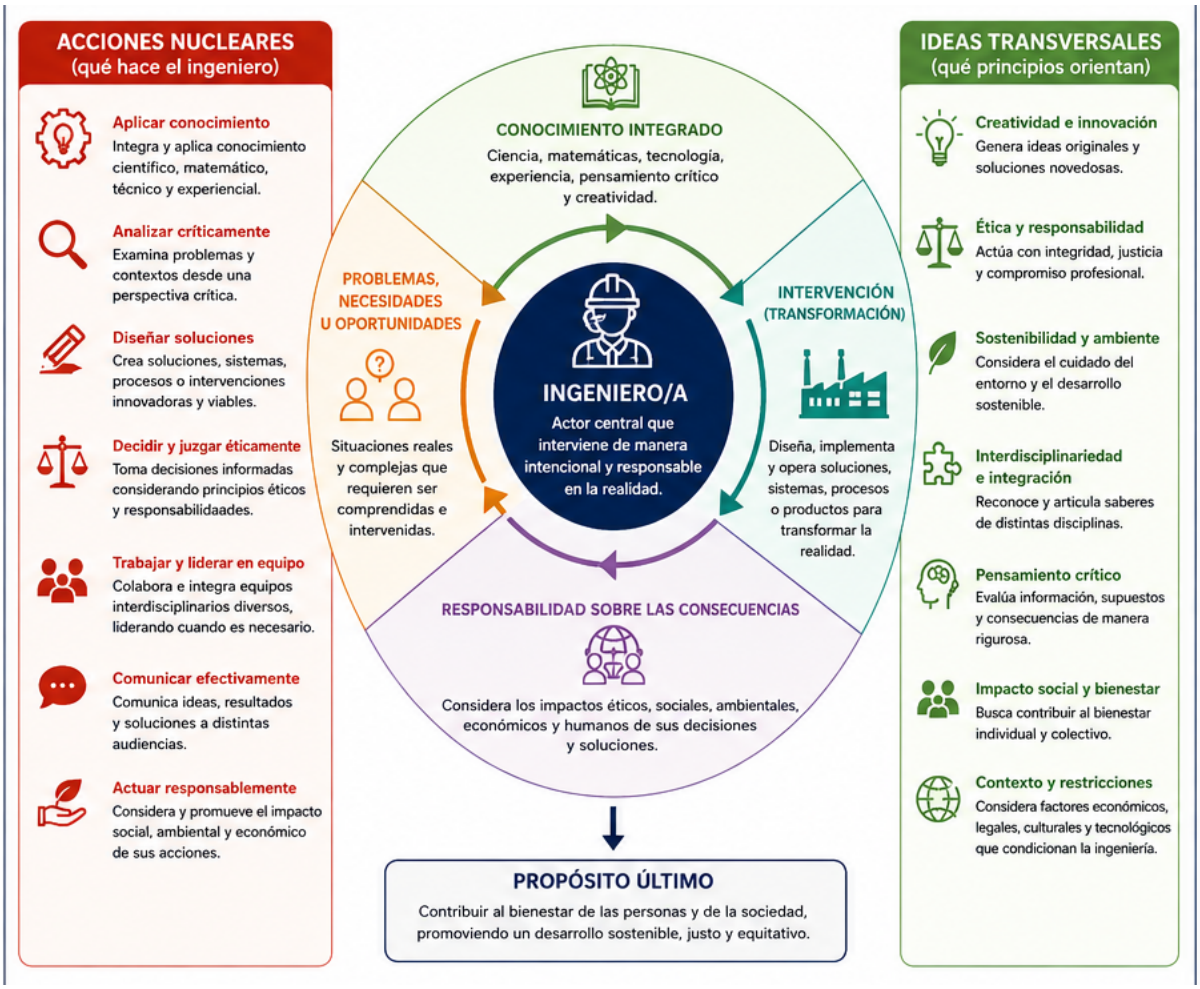

Figura 3: Síntesis de las figuraciones de ingeniería Nota. Figura generada con apoyo de OpenAI a partir de las definiciones previamente citadas, analizadas y contextualizadas por los autores.

Aunque las dos definiciones y las doce figuraciones analizadas no comprenden el universo de concepciones sobre la ingeniería ni constituyen una muestra estadísticamente representativa, permiten identificar algunas coincidencias relevantes. El análisis sugiere que las ideas asociadas con la ingeniería varían según el momento histórico y las particularidades del contexto, pero conservan elementos comunes: la resolución de problemas mediante la integración de conocimientos y el ejercicio de la creatividad, con el propósito de transformar la realidad dentro de un contexto determinado y asumir las consecuencias de esa intervención. Es decir, en términos generales, se identifica que la concepción institucional de la ingeniería se articula como una práctica sustentada en procesos racionales y creativos mediante los cuales se aplica e

integra conocimiento para intervenir y transformar la realidad. Esta práctica se desarrolla dentro de contextos sociales, legales, ambientales, tecnológicos y temporales que condicionan tanto los problemas abordados como las soluciones propuestas. En consecuencia, la ingeniería constituye un campo dinámico cuya configuración se modifica conforme avanzan el conocimiento científico, la tecnología y las propias necesidades y transformaciones de la sociedad. En la siguiente, sección se contextualiza la formación ingenieril en México.

Si uno revisa los perfiles institucionales consolidados, aparece siempre el mismo núcleo: identificar problemas, modelar restricciones, diseñar soluciones, utilizar herramientas, evaluar resultados. Con el tiempo se le fueron sumando competencias que antes quedaban fuera del perfil técnico, comunicación, trabajo interdisciplinario, gestión, innovación, sostenibilidad, ética. Ya no basta con calcular, diseñar o construir artefactos para llamarse ingeniero. Lo que define hoy a la ingeniería es la capacidad de articular distintos tipos de conocimiento para intervenir, de forma intencional y responsable, sobre problemas, procesos y sistemas complejos.

b. La narrativa del Ingeniero en la sociedad

Una profesión no existe únicamente porque posea un cuerpo especializado de conocimientos. También requiere sistemas de reconocimiento: las formas en que una sociedad decide quién pertenece a ella, qué le corresponde hacer, qué conocimientos y atributos reconoce como legítimos en sus integrantes. Esas representaciones no las produce una sola institución. Circulan entre universidades, asociaciones profesionales, medios de comunicación y los propios miembros de la profesión. Aquí abordamos ese conjunto de significados compartidos desde la noción de narrativa social.

La narrativa social puede entenderse como una configuración colectiva: ahí es donde ciertos actores, acontecimientos y atributos adquieren sentido dentro de una comunidad. No es, necesariamente, un relato explícito o coherente. Es una estructura de significados que se reproduce en discursos, símbolos, prácticas y estereotipos. Organiza la experiencia social, marca categorías de pertenencia, y produce expectativas sobre cómo ciertos actores son, o deberían ser.

Estas narrativas no permanecen fijas. Se producen mediante procesos continuos de circulación, interpretación y resignificación. Los individuos toman elementos de su entorno, los interpretan desde su propia experiencia, y los comunican: en conversaciones, noticias, memes, normas, prácticas institucionales. Cuando ciertas asociaciones se repiten y las reconoce un número amplio de actores, pueden estabilizarse como representaciones compartidas. Esa estabilización, sin embargo, nunca es definitiva: las narrativas también se cuestionan, se reinterpretan, se sustituyen.

Desde esta perspectiva, la identidad profesional es uno de los productos de la narrativa social. Ser reconocido como integrante de una profesión implica algo más que acreditar conocimientos formales. Supone también aprender y reproducir lenguajes, valores y formas de interacción que permiten reconocerse, y ser reconocido, como miembro de

una comunidad. Las narrativas ayudan así a construir prototipos profesionales y fronteras simbólicas entre quienes se percibe como miembros legítimos, periféricos o ajenos al grupo.

Abbott (1988) complementa esta idea con el concepto de jurisdicción profesional: el vínculo socialmente reconocido entre una profesión y ciertos problemas o ámbitos de intervención. Las fronteras profesionales, desde este enfoque, no son solo técnicas. También son institucionales y sociales. Una profesión puede ampliar, perder o disputar jurisdicciones conforme cambian el conocimiento, la tecnología y las instituciones. Esto es particularmente relevante para la ingeniería, cuya denominación se ha expandido hacia campos como datos, finanzas o desarrollo social.

Gieryn (1983), con el concepto de *boundary-work*, mostró que las fronteras entre campos de conocimiento se producen también mediante procesos discursivos e institucionales. Con esa idea se puede analizar cómo se construyen las distinciones entre ciencia, tecnología e ingeniería, y qué prestigio distinto reciben lo teórico, lo experimental y lo aplicado. Esas jerarquías no vienen solo de diferencias epistemológicas. Vienen también de los discursos con los que ciertos conocimientos se legitiman.

Esta tensión aparece también en la literatura sobre cultura e identidad ingenieril, que lleva años documentando una oposición persistente entre lo técnico y lo social. Faulkner (2000) lo dice con claridad: esta distinción no es neutral, es jerárquica. Lo técnico se asocia con racionalidad, dureza y masculinidad; lo social queda en segundo plano. Cech (2014) encontró, en Estados Unidos, que ciertos procesos de formación profesional favorecen una cultura de desvinculación social, sostenida en la despolitización, el mismo dualismo técnico-social y una idea particular de mérito. La identidad ingenieril no se construye solo con conocimientos y competencias. Se construye también con valores, jerarquías y representaciones culturales.

En la ingeniería, estas narrativas producen imágenes relativamente estables sobre quién es un ingeniero y qué características debe tener. La literatura documenta asociaciones entre identidad ingenieril, competencia técnica, racionalidad, objetividad y masculinidad. Cuando esas representaciones idealizan un perfil prototípico (varón, blanco, heterosexual, técnicamente brillante, emocionalmente distante), funcionan como frontera simbólica: definen quién pertenece y quién queda afuera. Mejia y Christiansen (2024) documentan este mecanismo en un corpus estadounidense, y aunque sus resultados no se pueden trasladar directamente al contexto mexicano, dejan una pregunta que sí nos toca: ¿qué cuerpos, identidades, acentos, territorios y saberes reconocemos socialmente como propios de la ingeniería, dentro de instituciones que se dicen formalmente diversas?

Dentro de ese terreno, los memes son artefactos particularmente reveladores: condensan experiencias, afectos y estereotipos en un formato que se reproduce y comparte con facilidad, para ejemplificar lo anterior considérese la Figura 4.

Mejia y Christiansen (2024) analizaron una muestra de memes de ingeniería recuperados mediante búsqueda pública. Ahí encontraron la reproducción de

una identidad relativamente homogénea, junto con procesos de racialización en las representaciones predominantes. La procedencia estadounidense del corpus no permite generalizar el hallazgo, pero sí muestra que el meme puede participar en procesos de inclusión, exclusión y normalización de identidades dentro de las comunidades de ingeniería.



Figura 4: Ejemplo de un meme satírico elaborado con OpenAI a partir de memes publicados con motivo del Día del Ingeniero.

Yllanes *et al.* (2025), por su parte, analizaron más de 400 memes hechos por estudiantes de ingeniería y encontraron, de manera preliminar, temas de rigor académico, estereotipos y dificultades compartidas. El hallazgo obliga a no leer el meme de una sola forma. Puede reproducir jerarquías y estereotipos. También puede convertir el cansancio, la dificultad académica o

el fracaso en un código compartido de pertenencia. Su significado depende de quién lo hace, quién lo interpreta, y en qué comunidad circula.

En México pasa algo parecido. También aquí circulan repertorios culturales que representan y jerarquizan la ingeniería, y The Big Bang Theory ilustra bien esto. UNAM Global recuperó la lectura de Felipe López Veneroni sobre la relación entre Sheldon Cooper y Howard Wolowitz: Sheldon desacredita una y otra vez a Howard por ser ingeniero, frente al prestigio que le atribuye a la física (UNAM Global, 2017). Algo parecido ocurre en las recopilaciones que distintos medios publican cada Día del Ingeniero, con bromas sobre errores de principiantes, soluciones improvisadas y rivalidades entre especialidades (Infobae, 2021; MVS Noticias, 2025).

Estas piezas no son una muestra representativa ni sistemática de la cultura ingenieril mexicana, y no pretenden serlo. Se usan aquí como evidencia cultural situada: un registro de los repertorios y estereotipos que circulan en el espacio público. No buscan medir qué tan frecuente es una representación. Buscan identificar los significados con los que se interpreta, valora o cuestiona a la ingeniería.

Vista en conjunto, la narrativa social de la ingeniería puede entenderse como un sistema dinámico de representaciones compartidas: qué es la ingeniería, quién puede ser reconocido como ingeniero, qué conocimientos y comportamientos se le atribuyen, y cuál es su función social. Estas representaciones se producen en la interacción entre individuos, instituciones, mercados laborales y artefactos culturales, y cambian conforme cambian las condiciones científicas, tecnológicas y sociales. La ingeniería, entonces, no es solo un campo de conocimientos técnicos. Es también un terreno donde se negocian identidades, jerarquías y fronteras de pertenencia.

c. Ingeniera en México

En el presente trabajo se emplearán los apelativos ingeniero, ingeniera o ingeniere para referirse, de manera general, a las personas con formación profesional en alguno de los campos disciplinares de la ingeniería. Si bien con frecuencia esta formación se asocia exclusivamente con los estudios de licenciatura, en México existen trayectorias educativas vinculadas con los campos ingenieriles en distintos niveles, entre ellos técnico superior universitario, licenciatura, especialidad, maestría y doctorado. Sin embargo, estos niveles no deben considerarse equivalentes ni suponer que la realización de un posgrado en ingeniería confiere automáticamente el título profesional de ingeniero.

De acuerdo con el Anuario Estadístico de Educación Superior de la ANUIES (s. f.), correspondiente al ciclo escolar 2025-2026, en México se registran 59,074 denominaciones de programas de educación superior, que abarcan desde el nivel técnico superior universitario hasta el doctorado. De este conjunto, más del 15% contiene la palabra «ingeniería» en su denominación, lo que evidencia la amplitud y diversidad con la que este campo se encuentra representado dentro de la oferta educativa nacional. En la Tabla 2 se presenta la distribución de estos registros por nivel educativo y modalidad. Asimismo, se incorpora una columna de nombres canónicos, obtenidos mediante la normalización de las denominaciones originales, con el propósito de agrupar variantes nominales.

NIVEL	MODALIDAD	Registros	Nombres canónicos
DOCTORADO	ESCOLARIZADA	160	69
DOCTORADO	MIXTA	8	6
DOCTORADO	NO ESCOLARIZADA	4	4
ESPECIALIDAD	ESCOLARIZADA	20	17
ESPECIALIDAD	MIXTA	6	6
LICENCIATURA UNIVERSITARIA Y TECNOLÓGICA	ESCOLARIZADA	6,379	869
LICENCIATURA UNIVERSITARIA Y TECNOLÓGICA	NO ESCOLARIZADA	670	165
LICENCIATURA UNIVERSITARIA Y TECNOLÓGICA	MIXTA	1,210	341
LICENCIATURA UNIVERSITARIA Y TECNOLÓGICA	DUAL	14	13
MAESTRÍA	ESCOLARIZADA	481	220
MAESTRÍA	NO ESCOLARIZADA	65	52
MAESTRÍA	MIXTA	52	41
TÉCNICO SUPERIOR	NO ESCOLARIZADA	1	1
TÉCNICO SUPERIOR	ESCOLARIZADA	2	2

Tabla 2: Distribución de formación en ingeniería por nivel y modalidad

Adicionalmente, el mismo Anuario Estadístico de Educación Superior de la ANUIES reporta que, para el ciclo 2025-2026, se registraron 1,282,036 personas matriculadas, 307,168 estudiantes de nuevo ingreso y 196,150 egresados en programas relacionados con ingeniería. En los tres indicadores, matrícula, nuevo ingreso y egreso, se observa una participación masculina considerablemente mayor que la femenina, con una relación aproximada de dos hombres por cada mujer.

Por otra parte, en la Figura 5 se presenta la distribución geográfica de los programas ofrecidos y de las instituciones que los imparten. Se observa una mayor concentración y diversidad de programas e instituciones en la región centro del país. Asimismo, entidades como Jalisco, Chihuahua y Coahuila presentan una oferta particularmente diversa de programas de ingeniería. En contrate Tlaxcala, Colima y Nayarit poseen la menor diversidad en programas e instituciones. Lo anterior evidencia que la distribución territorial de la formación en ingeniería no es homogénea.

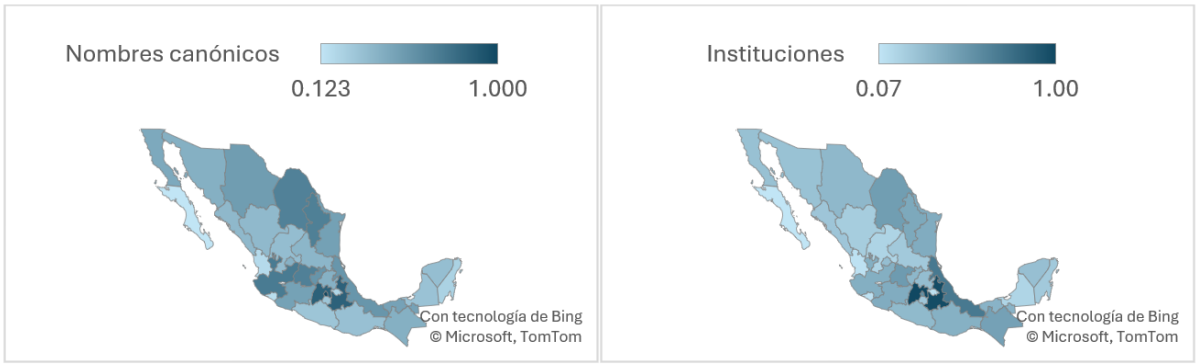

Figura 5: Distribución geográfica en la formación en ingeniería. Nota. Figura generada con apoyo de OpenAI a partir de los datos del anuario

A partir de la información del anuario de ANUIES, la normalización canónica de los nombres de programas y técnicas de procesamiento de lenguaje natural (PLN), construimos una taxonomía de tres niveles: 10 familias, 20 subfamilias y 66 subsubfamilias, que se muestran en las figuras 6 y 7.

Los criterios ABET y CACEI se usaron como referencia para distinguir la formación, los criterios disciplinares y la acreditación, no como catálogos exhaustivos de denominaciones [confianza: media]: la taxonomía en sí se construyó con procesos de relaciones semánticas y herramientas de inteligencia artificial generativa (IAG), y describe la estructura de la base de datos generada a partir del anuario.

Esto importa porque ABET y CACEI no son simples trámites de acreditación, son marcos de competencia. ABET (2026) establece que la ingeniería debe entregar, entre sus resultados formativos, la capacidad de resolver problemas complejos, diseñar soluciones considerando la salud pública, la seguridad y el bienestar, además de factores globales, culturales, sociales, ambientales y económicos, comunicarse con distintas audiencias, y reconocer responsabilidades éticas y profesionales. El Marco de Referencia 2025 de CACEI sitúa la evaluación de los programas tanto en los procesos institucionales de mejora continua como en los resultados formativos de los egresados, aunque prioriza estos últimos: no basta con que el proceso exista, hay que documentar que los estudiantes efectivamente alcanzaron esos atributos de egreso (CACEI, 2025). Los dos marcos son, entonces, referencias de competencia y calidad, no listas cerradas de nombres de programas.

A

Familia	Subfamilia	Subsubfamilia
Ingenierías de construcción, industria, energía y procesos	**Arquitectura, urbanismo, construcción e ingeniería civil**	Ingeniería arquitectónica, urbana y territorial
		Ingeniería civil, construcción e infraestructura
	Manufactura, materiales, alimentos y extracción	Ingeniería de alimentos y procesos alimentarios
		Ingeniería de materiales, cerámica, madera, plástico y vidrio
		Ingeniería minera, extractiva y metalúrgica
		Ingeniería textil, calzado y piel
		Manufactura y procesos multidisciplinarios
	Mecánica, eléctrica, electrónica, química y sistemas afines	Electrónica, automatización, control, mecatrónica y sistemas inteligentes
		Ingeniería ambiental, sanitaria y sustentable
		Ingeniería automotriz, ferroviaria, naval y aeroespacial
		Ingeniería eléctrica, energética y energías renovables
		Ingeniería general e interdisciplinaria
		Ingeniería industrial, operaciones, calidad y logística
		Ingeniería mecánica, metalmecánica y térmica
		Ingeniería química, petroquímica y de procesos
Ingenierías de computación, información y comunicaciones	**Computación, software, datos e inteligencia artificial**	Computación, ciencia de datos e inteligencia artificial
		Hardware, arquitectura y sistemas digitales
		Innovación digital, datos e inteligencia artificial
		Software, aplicaciones, videojuegos y servicios digitales
	Infraestructura, informática, redes y telecomunicaciones	Ciberseguridad, seguridad informática y redes
		Implementación multidisciplinaria de TIC
		Informática, sistemas de información y computación aplicada
		Soporte, mantenimiento e infraestructura tecnológica
		Telecomunicaciones, redes y conectividad
Ingenierías científicas y matemáticas	**Modelación matemática, estadística y actuarial**	Ingeniería estadística, actuarial y de riesgos
		Ingeniería matemática y modelación
	Sistemas biológicos, bioquímicos y ambientales	Ingeniería biológica y biosistemas
		Ingeniería bioquímica, biofísica y biomolecular
		Ingeniería ecológica, ambiental y de recursos naturales
	Sistemas físicos, químicos, terrestres y atmosféricos	Ingeniería física, óptica y sistemas astronómicos
		Ingeniería geológica, geofísica, geociencias y atmósfera
		Ingeniería química y química aplicada
		Ingenierías científicas multidisciplinarias

Figura 6: Taxonomía de los registros vinculados a ingeniería. Nota. Figura generada con apoyo de OpenAI a partir de los datos de ANUIES

B

Familia	Subfamilia	Subsubfamilia
Ingenierías administrativas, económicas y de negocios	**Administración, gestión y dirección**	Gestión aplicada a servicios y sectores sociales
		Gestión de proyectos de ingeniería y construcción
		Gestión empresarial y organizacional
		Gestión general y multidisciplinaria
	Negocios, finanzas, comercio y logística	Finanzas, banca, seguros y riesgos
		Mercadotecnia, publicidad y sistemas comerciales
		Negocios y finanzas multidisciplinarias
		Negocios, comercio y logística
		Sistemas fiscales, contables y de control
Ingenierías agropecuarias, forestales y pesqueras	**Producción agropecuaria, forestal, hortícola, acuícola y animal**	Agronomía, producción vegetal, desarrollo y sociología rural
		Horticultura y producción protegida
		Ingeniería forestal, silvicultura y recursos naturales
		Pesca, acuacultura y sistemas hidrobiológicos
		Sistemas agropecuarios multidisciplinarios
		Zootecnia, producción y salud animal
Ingenierías de diseño, medios y producción creativa	**Diseño, animación, audio y medios digitales**	Audio, sonido, multimedia, animación y producción musical
		Diseño gráfico, digital, editorial y animación
		Diseño industrial, textil, moda e interiores
	Lenguaje, conocimiento y sistemas humanos	Ingeniería del lenguaje y del conocimiento
		Ingeniería humana y sistemas humanísticos
Ingenierías de transporte, seguridad y servicios	**Seguridad laboral y prevención de riesgos**	Seguridad e higiene industrial, salud ocupacional y gestión de riesgos
	Seguridad pública y protección civil	Protección civil, emergencias, rescate e incendios
	Transporte, movilidad y operaciones logísticas	Logística aeroportuaria
		Logística, cadenas de suministro y operaciones de transporte
		Transporte ferroviario
		Transporte, movilidad, tránsito y sistemas urbanos
Ingenierías sociales, jurídicas y comunitarias	**Criminología y sistemas forenses**	Criminalística y ciencias forenses
	Economía, sociedad, territorio y desarrollo comunitario	Ingeniería económica, financiera y de decisiones
		Ingeniería social, comunitaria, territorial y rural
Ingenierías biomédicas, farmacéuticas y de salud	**Biomedicina, farmacia y tecnologías para la salud**	Ingeniería biomédica y sistemas clínicos
		Ingeniería farmacéutica y biofarmacéutica
Ingenierías educativas y del conocimiento	**Tecnología educativa, aprendizaje y comunicación**	Ingeniería educativa y del aprendizaje
		Tecnología, comunicación y sistemas educativos

Figura 7: Taxonomía de los registros vinculados a ingeniería (continuación). Nota. Figura generada con apoyo de OpenAI a partir de los datos de ANUIES

La modernización de la oferta también forma parte de esta narrativa. ANUIES informó en febrero de 2025 la existencia aproximada de 43 programas relacionados directamente con inteligencia artificial, 24 de licenciatura y 19 de posgrado, con alrededor de 3,600 estudiantes (ANUIES, 2025).

3. Metodología

Se empleó un diseño de investigación documental, exploratorio, mixto, comparativo y multicapa, sustentado en la consideración de la narrativa de la ingeniería como un constructo social. El modelo conceptual que orientó el análisis se presenta en la Figura 1. Las fuentes documentales se organizaron en tres planos: académico e institucional, sociocultural y laboral. Cada plano fue analizado inicialmente como una capa independiente y, posteriormente, los resultados se normalizaron e integraron para construir una red macro. El procedimiento de integración conceptual y analítica se esquematiza en la Figura 8.



Figura 8: Modelo integrado para el análisis de la narrativa social sobre ingeniería. Nota. Figura generada con apoyo de OpenAI

El modelo integrado presentado en la Figura 8 sirvió como base para diseñar la metodología de esta investigación. En la Figura 9 se muestra el proceso implicado; el cual comienza con la definición del objeto de estudio y la delimitación del problema mediante dos preguntas orientadoras: ¿qué narrativa se estudiará? y ¿por qué resulta pertinente analizarla? A partir de estas preguntas se construyen, procesan e integran los corpus documentales. Finalmente, se analizan e interpretan los resultados considerando los alcances y límites de la investigación. A continuación, se describen de manera generar cada uno de los pasos de la metodología empleada.

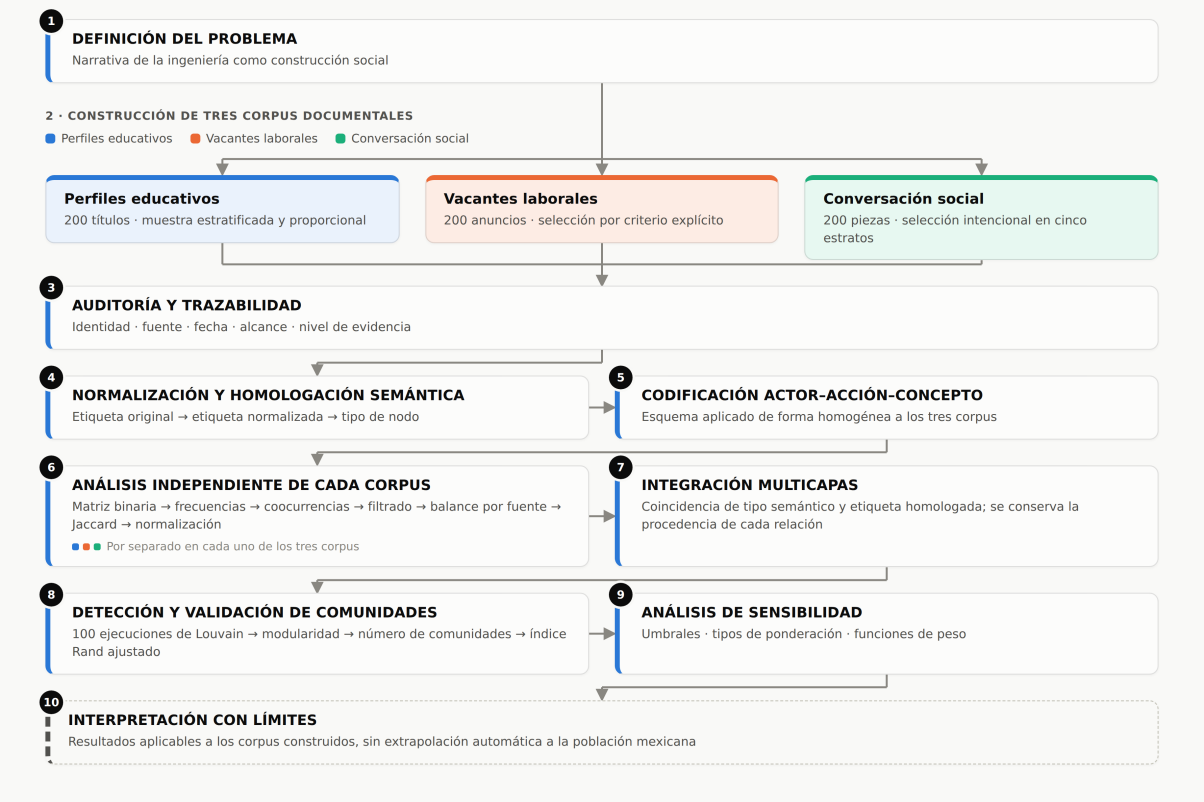

Figura 9: Metodología para la caracterización de la narrativa social Nota: figura elaborada por los autores con apoyo de Claude (Anthropic), a partir de la metodología implicada en el estudio.

Definición del problema

En esta fase se delimita el problema de investigación mediante las siguientes preguntas: ¿qué problema se busca comprender?, ¿por qué es pertinente estudiarlo?, ¿qué elementos deben considerarse en su análisis?, ¿por qué se seleccionan dichos elementos? y ¿cuáles son los supuestos, alcances y limitaciones del estudio?

Como se mencionó anteriormente, el objeto de la presente investigación es explorar, mediante un enfoque documental mixto, la narrativa contemporánea sobre la ingeniería. Para ello se consideran tres fuentes de información, pues corresponden a espacios diferenciados de definición, representación y reconocimiento profesional.

La dimensión académica e institucional permite examinar la formación, los conocimientos, las capacidades y los atributos declarados en ingeniería. La dimensión laboral establece los requisitos, las competencias y las responsabilidades exigidos en los procesos de contratación. Finalmente, la dimensión sociocultural permite identificar las imágenes, valoraciones, expectativas y tensiones que circulan en piezas culturales, publicaciones científicas, noticias, documentos gubernamentales y expresiones autorreferenciales.

Debido al carácter exploratorio del estudio y a la selección no probabilística de sus documentos, los resultados permiten identificar posibles relaciones, patrones y características de la narrativa analizada, pero no permiten estimar su prevalencia en la población mexicana ni establecer relaciones causales. Las conclusiones

se circunscriben, por tanto, al corpus construido y a las condiciones temporales y documentales bajo las cuales se reunió.

Construcción de Corpus

A partir de las dimensiones establecidas en el paso anterior se construyeron tres corpus documentales: perfiles educativos, vacantes laborales y conversación social. Cada corpus se analizó por separado antes de integrarlos, ya que un programa académico, una vacante y una pieza de conversación social constituyen unidades documentales diferentes y no directamente equivalentes. A continuación, se describen cada corpus y se muestran sus seudocódigos. Empleados para su generación

a) El corpus académico contiene de 200 unidades de análisis (se indica que la unidad muestral es el título normalizado de ingeniería, acorde a la Taxonomia motrada en las Figuras 6 y 7), De las cuales 81 cuentan con fuente directa, 61 con fuente equivalente y 58 con construcción analítica. Se aseguró la presencia de las 66 subsubfamilias y se distribuyeron los casos restantes de manera proporcional a la disponibilidad de títulos por estrato. Para cada título se consultó primero la institución asociada con mayor matrícula; los empates se resolvieron alfabéticamente. Se buscaron definición, perfil de ingreso, perfil de egreso y características distintivas en páginas institucionales. El procedimienro en su demás cción se muestra en el psedocodigo 1.

Pseudocódigo 1. Corpus educativo

```
ENTRADAS: Base estadística de ANUES (normalizada en unidades),
Taxonomía
SALIDAS: Corpus con 200 registros
INICIO
      Selección de las 200 unidades (se asegura que las 66
subsubfamila de la taxonomía estén representadas, selección por
estratos)
      Para cada unidad
            Identificar la página o repositorio de la universidad con
           mayor matrícula para esa unidad
            Extraer definición, perfil de ingreso, perfil de egreso
           y características distintivas
      Normalizar el corpus
FIN
```

b) El Corpus sociocultural: contiene 200 piezas documentales seleccionadas de forma intencional para cubrir cinco estratos: 60 piezas de cultura popular, 60 documentos científicos, 40 noticias, 20 documentos gubernamentales y 20 piezas de autopercepción. La unidad de análisis es una pieza, no una persona.

Las 60 piezas de cultura popular se integro por 20 memes, 20 referencias de cine, televisión y videojuegos, y 20 chistes documentados. Se codificaron el medio, el marco narrativo, la posición del sujeto técnico, el tono, la representación de género, la inclusión y la pertinencia para México. demás, en la ficción aparecieron dos figuras recurrentes: el inventor excepcional (Tony Stark o Shuri) por otro lado el especialista que mantiene en funcionamiento sistemas complejos, (Geordi La Forge, Scotty). La

primera concentra mayor visibilidad y prestigio narrativo; la segunda representa un trabajo técnico menos visible, pero esencial para la operación.

La información se obtuvo de páginas públicas, artículos, medios periodísticos, documentos oficiales y publicaciones autorreferenciales. Para cada registro se conservaron identificador, grupo, subgrupo, fuente, título, autor cuando estuvo disponible, DOI, URL primaria, URL secundaria, fecha, alcance, nivel textual, regla de selección, consulta de búsqueda, fecha de recuperación, estado de trazabilidad y nota de derechos. La selección buscó variación de formatos y posiciones discursivas; no constituye una muestra probabilística de la sociedad mexicana. En Pseudocódigo 2 se esquematiza el procedimiento empleado para la generación del corpus.
Pseudocódigo 2. Corpus cultural

Pseudocódigo 2. Corpus cultural

```
ENTRADAS:     Fuentes     culturales,     científicas,periodísticas,
gubernamentales y autorreferenciales, cuotas por fuente (60 piezas
culturales,60 documentos científicos, 40 noticias, 20 documentos
gubernamentales, 20 piezas de autopercepción).
SALIDA Corpus Cultural con 200 registros
INICIO
    Seleccionar intencionalmente 200 piezas.
    PARA cada fuente:
       Hasta cubrir la cuota:
       Buscar una pieza factibke
        Registrar:
            grupo y subgrupo,
            fuente,
            título y autor,
            fecha,
            DOI o URL,
            regla de selección,
            nivel de evidencia,
            trazabilidad y derechos.
        FIN HASTA
    FIN PARA
FIN
```

c) Corpus laboral: comprende 200 anuncios publicados para México y consultados el 28 de agosto de 2026. Se incluyeron únicamente registros cuyo texto visible exigía formación en ingeniería o un campo explícitamente afín. Cada registro conserva puesto, empresa cuando fue visible, ubicación, familia, requisito documentado, habilidades tecnológicas, capacidades humanas, nivel de evidencia, URL y fecha de consulta. Se identificaron 167 URL distintas, aunque los 200 registros conservan una dirección de consulta. Ciento veinte casos corresponden a evidencia A, página directa de la vacante, y 80 a evidencia B, extracto o página de resultados con el requisito visible. La ausencia de una habilidad en el anuncio significa que no fue publicada, no que sea innecesaria para el puesto.

Técnicas de análisis

Los tres corpus no comparten el mismo estándar probatorio: los perfiles combinan evidencia institucional y síntesis etiquetadas; las vacantes combinan páginas directas y extractos; la conversación social integra formatos y emisores heterogéneos. La comparabilidad se estableció mediante categorías homologadas y pesos normalizados, no mediante la equivalencia sustantiva de las unidades documentales. El protocolo común se muestra en la Figura 10.

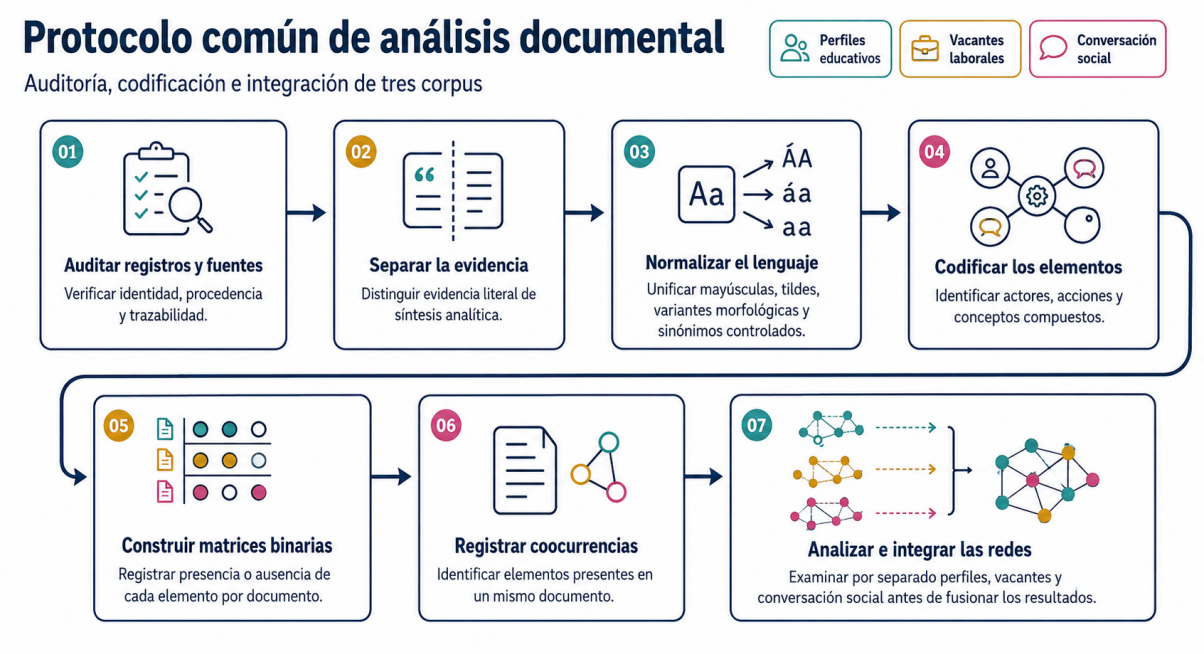

Figura 10: Protocolo de análisis. Nota. Figura generada con apoyo de OpenAI en base al protocolo de Investigación.

En la construcción de las matrices binarias documento–nodo se utilizó una variable de presencia, de modo que cada elemento tomara el valor de 1 cuando el nodo aparecía en el documento y 0 en caso contrario. A partir de esta matriz, para cada corpus se calculó la frecuencia de aparición de cada nodo y la coocurrencia entre pares de nodos. Las aristas se definieron como simétricas y no dirigidas, ya que representan co-presencia documental y no relaciones de influencia causal ni dirección discursiva. La prevalencia de cada relación se estimó con respecto al número total de documentos del corpus. Se conservaron únicamente aquellas relaciones que alcanzaron una prevalencia igual o superior a 5% en al menos uno de los tres corpus, equivalente a una presencia mínima en 10 de 200 documentos. Este umbral debe interpretarse como un criterio de filtrado empírico y no como una probabilidad de existencia ni como una prueba de significancia estadística.

Para reducir el efecto de la concentración de fuentes, se asignó el mismo peso a cada fuente documental. En el corpus social, el balance se realizó primero entre los cinco estratos y posteriormente entre las fuentes contenidas en cada uno. El peso interno de las relaciones se calculó mediante el índice de Jaccard balanceado y, posteriormente, cada capa fue normalizada para que su masa total fuera igual a uno. Con ello se evitó que una capa dominara la integración únicamente por contener un mayor número de aristas o una mayor frecuencia documental. Los nodos se fusionaron solo cuando coincidían tanto el tipo semántico como la etiqueta homologada. Cuando las etiquetas eran distintas, únicamente se estableció un vínculo si existía coocurrencia observada en al menos uno de los corpus. El peso integrado se obtuvo mediante la suma de los pesos normalizados por corpus, conservando además la procedencia de cada relación. Por esta razón, la red resultante debe entenderse como una integración multicapas de evidencias heterogéneas y no como una única muestra de 600 observaciones equivalentes.

Las comunidades se identificaron mediante el algoritmo Louvain ponderado, sin establecer previamente su número ni su composición. Se realizaron 100 ejecuciones con semillas diferentes y se registró la modularidad obtenida, la distribución del número de comunidades y su estabilidad mediante el índice Rand ajustado. La denominación de los núcleos se asignó posteriormente, a partir de los nodos dominantes observados en cada comunidad. De este modo, las categorías interpretativas no se impusieron antes del análisis, sino que se definieron a partir de la estructura detectada por el algoritmo.

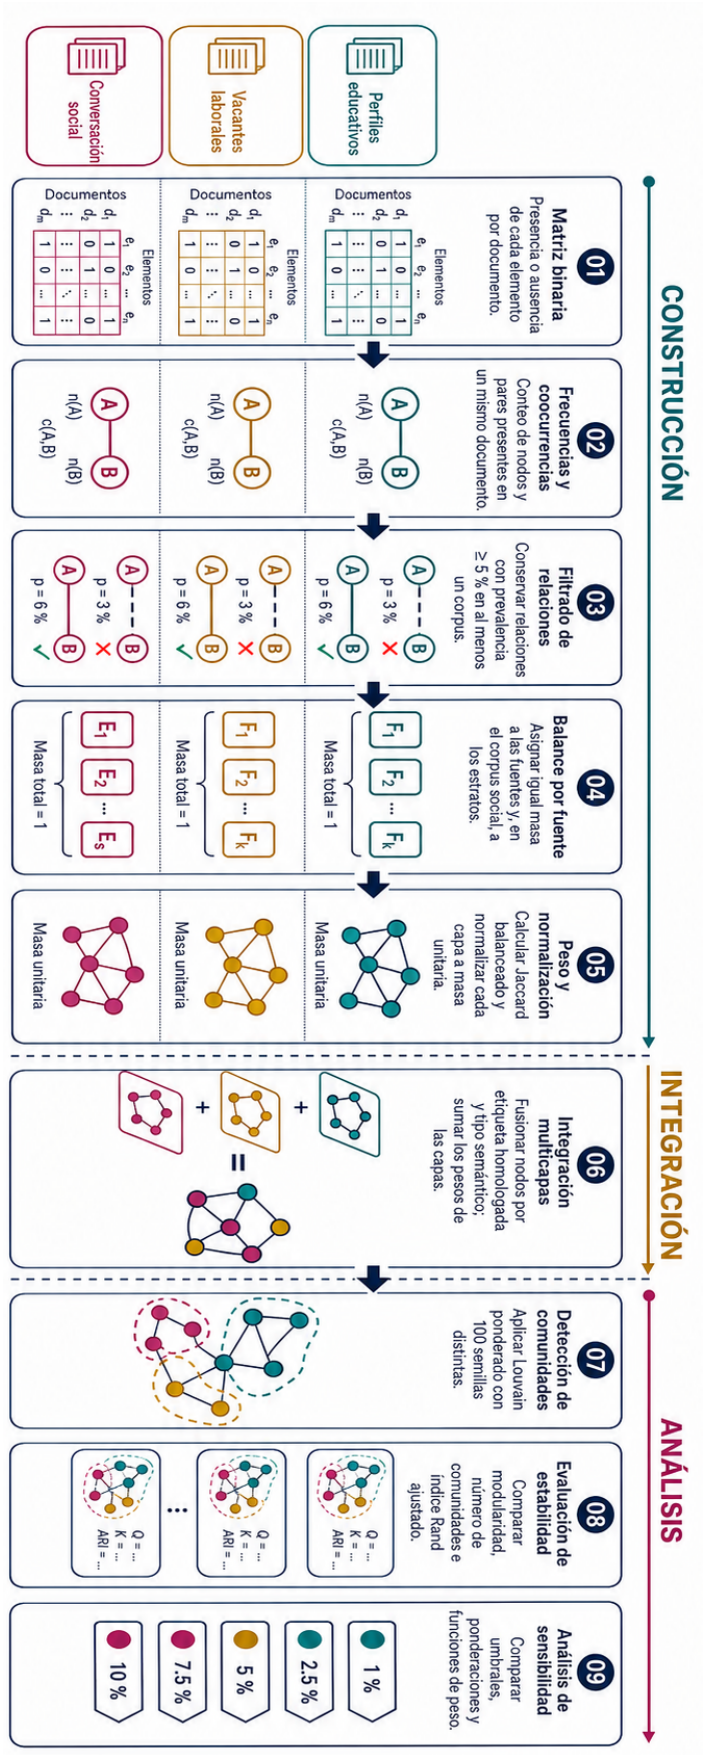

Figura 11: Construcción de redes Nota. Figura generada con apoyo de OpenAI en base al protocolo de Investigación.

4. Resultados

En la Tabla 3 se muestra las estructuras dominantes en el corpus académico, donde se presenta una fuerte concentración de actores, pero una estructura más distribuida entre acciones y conceptos. La narrativa formativa se organiza principalmente alrededor de diseñar, gestionar, desarrollar y producir, asociada con ciencia, diseño, sistemas y tecnología. Los resultados desagregados muestran, por ejemplo, una presencia elevada de diseño y sistemas en las distintas dimensiones de los perfiles.

Tipo de nodo	Elementos de mayor presencia documental	Núcleo Pareto	Concentración
Actores	Aspirantes, 200 (100 %); ingenieros, 200 (100 %); empresas/industria, 95 (47.5 %)	3 de 7	85.1 %
Acciones	Diseñar, 153 (76.5 %); gestionar/administrar, 121 (60.5 %); desarrollar, 118 (59.0 %); producir/fabricar, 104 (52.0 %); aplicar, 94 (47.0 %)	16 de 26	80.6 %
Conceptos	Ciencia/matemáticas, 171 (85.5 %); diseño, 169 (84.5 %); sistemas, 132 (66.0 %); tecnología, 114 (57.0 %); riesgo/seguridad, 104 (52.0 %)	14 de 23	80.7 %

Tabla 3: Estructura dominante en el corpus académico

En la Figura 12 y en la Tabla 4 se observa que el perfil académico no cambia por sustitución de conceptos, sino por una redistribución de sus énfasis. La formación parte de una base predominantemente científico-matemática y evoluciona hacia una combinación más equilibrada de diseño, sistemas, calidad, seguridad y gestión de recursos. De esta manera, el egreso expresa una ampliación del repertorio esperado del ingeniero,

desde los fundamentos de entrada hacia capacidades vinculadas con la intervención profesional.

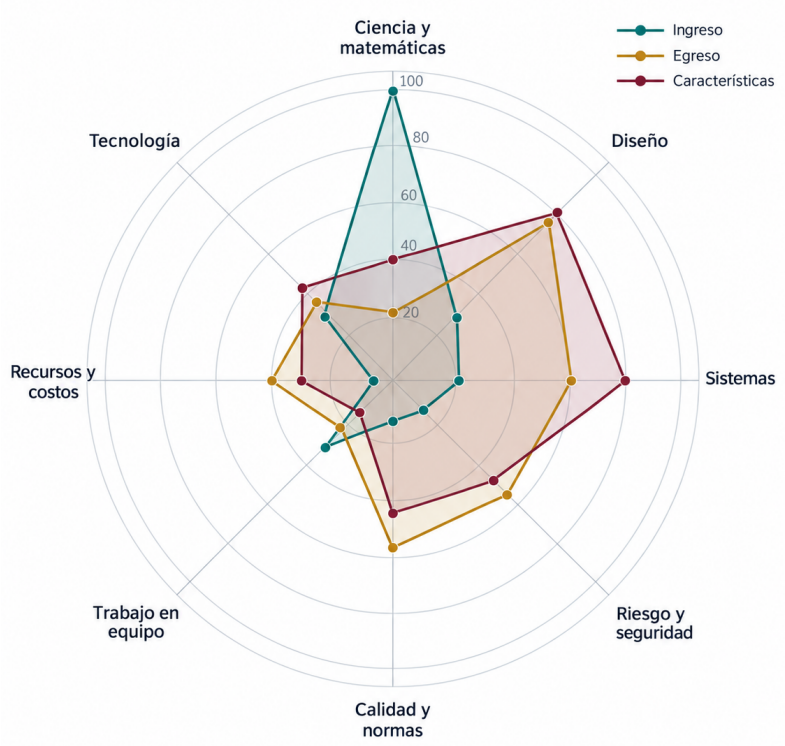

Figura 12: Perfil de las personas en ingeniería en tres momentos diferentes de la formación. Nota. Figura generada con apoyo de OpenAI en base al corpus Correspondiente.

Comunidad	Nodos	Denominación interpretativa	Nodos dominantes
1	52	Diseño, producción y criterios técnicos	ingenieros; diseño; diseñar; producir/fabricar; ambiente/sostenibilidad; calidad/normas
2	2	Trabajo en equipo	trabajo en equipo; equipos de trabajo
3	2	Liderazgo y coordinación	liderazgo/coordinación; dirigir/liderar
4	43	Tecnología, formación e innovación	tecnología; capacitar/formar; aplicar; crear/innovar; empresas/industria; innovación/creatividad
5	28	Sistemas	sistemas; programación/software; programar; desarrollar; datos; ciencia/matemáticas
6	2	Construcción e infraestructura	construcción/infraestructura; construir
7	2	Automatización	automatización; automatizar

Tabla 4: Estructura de comunidades en red académica

En la Tabla 5 se muestran las características dominantes del mercado laboral presenta una estructura menos concentrada en acciones y conceptos que en actores. Resulta especialmente relevante que comunicar sea la acción más frecuente, seguida por modelar, diseñar, liderar y coordinar. Esto muestra que la demanda laboral no se limita al dominio técnico, sino que integra de manera visible capacidades de interacción y conducción del trabajo. En la base original, comunicación aparece en 59 vacantes y resolución de problemas en 37

Tipo de nodo	Elementos de mayor presencia documental	Núcleo Pareto	Concentración
Actores	Equipos de trabajo, 200 (100 %); ingenieros, 200 (100 %); empresas/industria, 94 (47.0 %)	3 de 4	98.2 %
Acciones	Comunicar, 59 (29.5 %); modelar/simular, 51 (25.5 %); diseñar, 50 (25.0 %); dirigir/liderar, 47 (23.5 %); coordinar, 46 (23.0 %)	12 de 23	83.6 %
Conceptos	Diseño, 70 (35.0 %); comunicación, 59 (29.5 %); construcción/infraestructura, 51 (25.5 %); sistemas, 47 (23.5 %); liderazgo/coordinación, 46 (23.0 %)	11 de 22	80.1 %

Tabla 5: Estructura dominante del Corpus Laboral

En la Figura 13 se muestra un contraste de las habilidades y capacidades de corte técnicas, transversales y sociales requeridas en las ofertas laborales. Se marca de manera directa aquellas que se relacionan con habilidades requeridas con la IA.

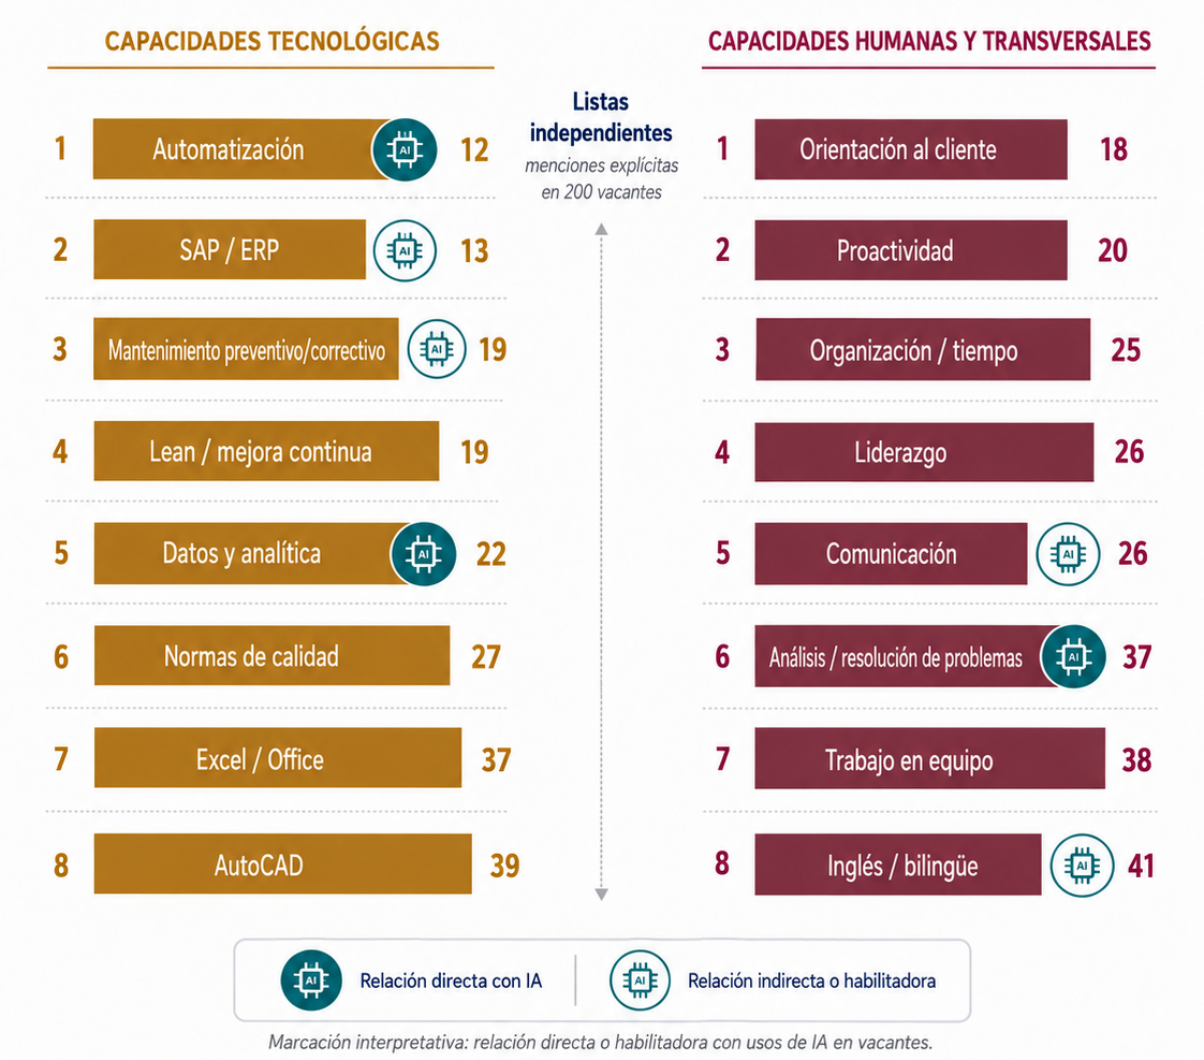

Figura 13: Características de vacantes Nota. Figura generada con apoyo de OpenAI en base al corpus correspondiente.

En la Tabla 6 se muestra el análisis de comunidades de la red compleja correspondiente. Se observa que la partición del mercado laboral no produce una sola comunidad de competencias técnicas; sino que por ejemplo Diseño y comunicación quedan juntos, mientras liderazgo se conecta con coordinación e infraestructura, y automatización forma un núcleo separado. Los resultados originales de las comunidades 1 a 3 muestran precisamente estas asociaciones.

Comunidad	Nodos	Denominación interpretativa	Nodos dominantes
1	15	Diseño, modelación y colaboración	diseño; diseñar; comunicación; comunicar; modelar/simular; colaborar
2	11	Liderazgo, coordinación e infraestructura	liderazgo/coordinación; coordinar; dirigir/liderar; construcción/infraestructura; construir
3	4	Software y sistemas	programación/software; programar; sistemas; desarrollar
4	3	Riesgo y sostenibilidad	riesgo/seguridad; ambiente/sostenibilidad
5	2	Recursos y costos	recursos/costos
6	5	Automatización y supervisión	automatización; automatizar; supervisar/controlar
7	14	Actores profesionales, calidad y manufactura	ingenieros; equipos de trabajo; empresas/industria; calidad/normas; manufactura/producción
8	2	Gestión y administración	gestionar/administrar; administración/negocios

Tabla 6: Comunidades del corpus laboral

El corpus social es claramente el más disperso, su estructura domeinte es motrado en la tabla 7. Se observa que el 80% de las menciones se requieren 19 de 41 acciones y 24 de 48 conceptos. Esto indica que la narrativa social es más heterogénea que la académica y la laboral. Sus elementos centrales se desplazan además hacia género, masculinidad, empleo, inteligencia artificial e identidad profesional, mientras que entre las acciones destacan trabajar, formar e incluir. La red social conserva precisamente asociaciones de género, inclusión, identidad, empleo y formación.

Tipo de nodo	Elementos de mayor presencia documental	Núcleo Pareto	Concentración
Actores	Ingenieros, 133 (66.5 %); empresas/industria, 43 (21.5 %); estudiantes de ingeniería, 41 (20.5 %); trabajadores/profesionales, 40 (20.0 %); universidades, 25 (12.5 %)	6 de 18	81.0 %
Acciones	Trabajar, 53 (26.5 %); capacitar/formar, 50 (25.0 %); incluir/reconocer, 38 (19.0 %); diseñar, 32 (16.0 %); desarrollar, 31 (15.5 %)	19 de 41	81.3 %
Conceptos	Género/inclusión, 60 (30.0 %); masculinidad, 42 (21.0 %); empleo/mercado laboral, 37 (18.5 %); inteligencia artificial, 31 (15.5 %); identidad ingenieril/profesional, 30 (15.0 %)	24 de 48	80.6 %

Tabla 7: Estructura del Corpus cultural

La estructura social es distinta: emergen comunidades de identidad, inclusión, educación, empleo y precariedad, temas que no dominan las otras dos redes. Por ejemplo, la comunidad científica articula identidad, estudiantes, negociación identitaria y pertenencia, mientras la gubernamental vincula trabajo, empleo, profesionales y salario. Las comunidades observadas en la red compleja se muestran en la tabla 8. En la Figura 14 se esquematizan los elementos en tensión del corpus social.

Comunidad	Nodos	Denominación interpretativa	Nodos dominantes
1	7	**Género, inclusión y representación del ingeniero**	ingenieros; género/inclusión; incluir/reconocer; masculinidad; riesgo/seguridad
2	5	**Formación, currículo e inteligencia artificial**	educación/currículo; capacitar/formar; IA; docentes/educadores; trabajar
3	6	**Identidad, pertenencia y trayectoria profesional**	identidad profesional; estudiantes; negociar identidad; desarrollar; pertenencia; persistencia profesional
4	4	**Industria, talento e inteligencia artificial**	empresas/industria; ingenieros; capacitar/formar; IA
5	2	**Inclusión de género**	género/inclusión; incluir/reconocer
6	6	**Trabajo, empleo y precariedad**	trabajar; empleo/mercado laboral; ingenieros; trabajadores/profesionales; salario/precariedad
7	2	**Autopercepción laboral del ingeniero**	ingenieros; trabajar

Tabla 8: Comunidades del corpus social

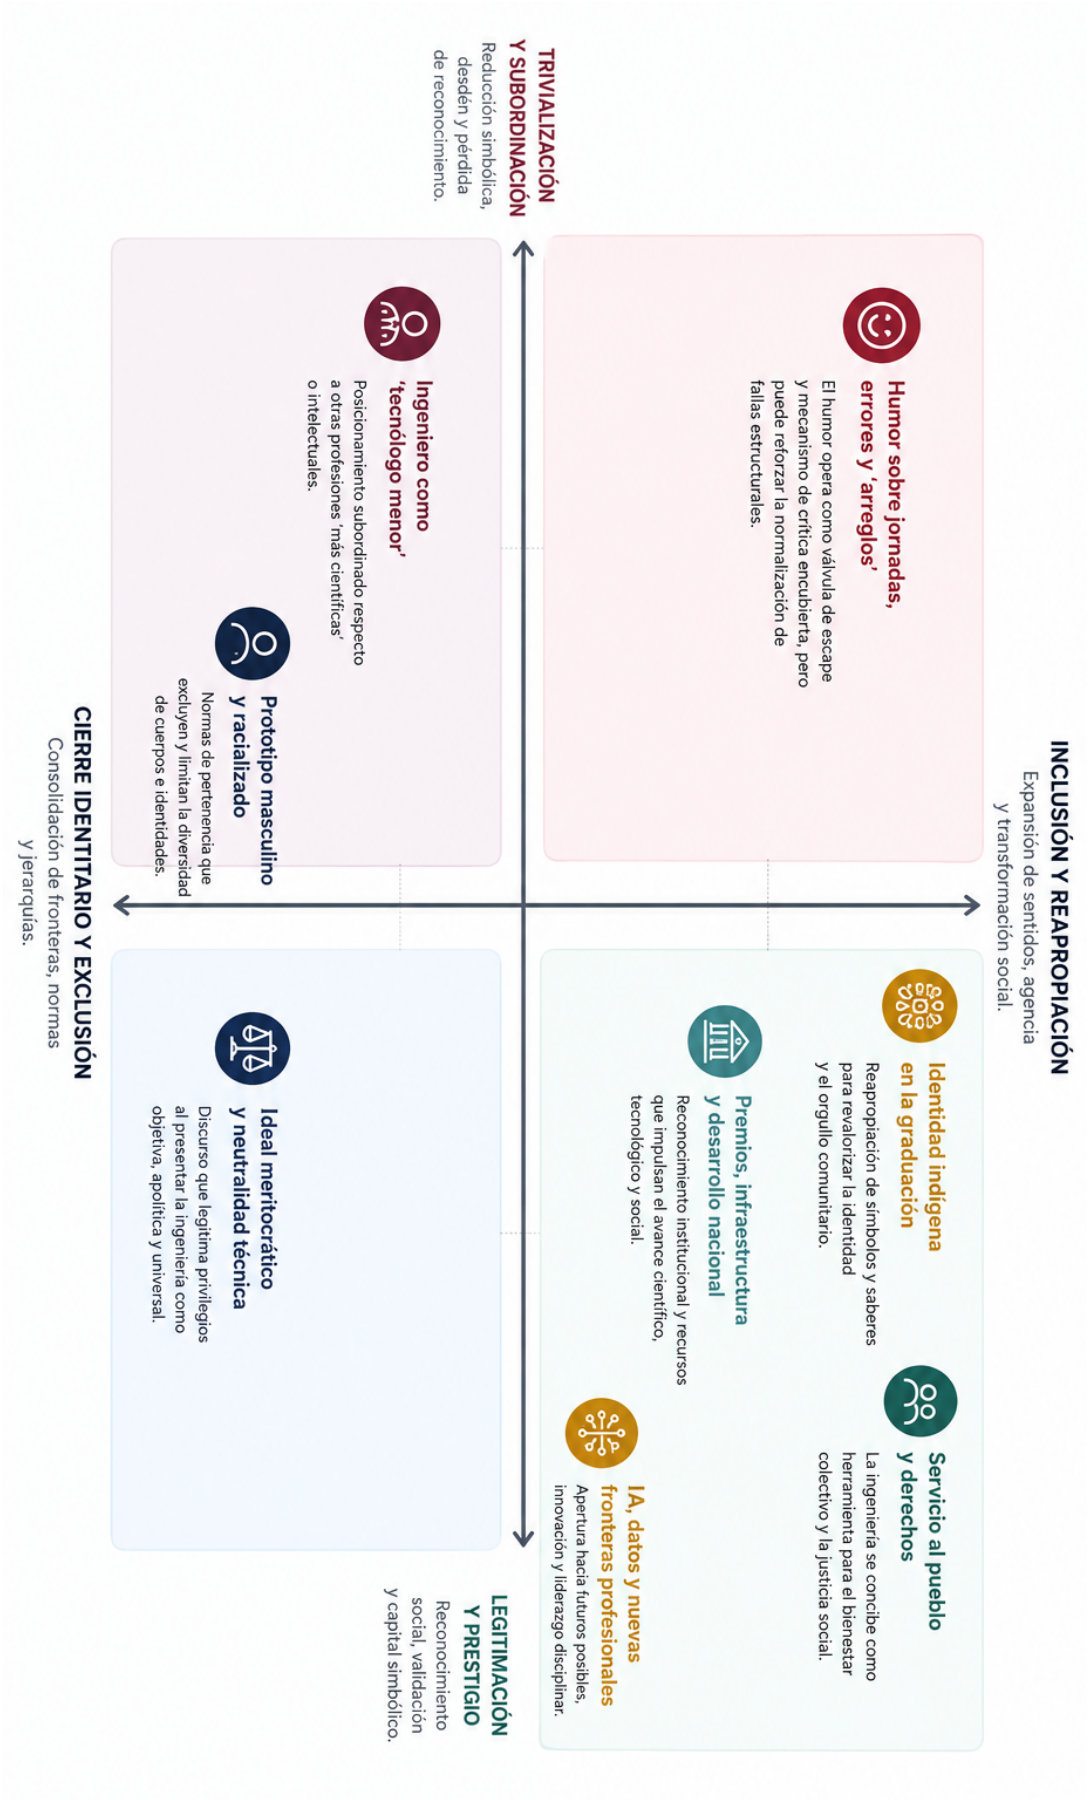

Figura 14: Campos en tensión en el corpus social

Las comunidades en la red académica, laboral y cultural se muestran en la tabla 9.

Comunidad integrada	n	Núcleo dominante	Contraste con la narrativa de IA	Transformación observada
1. Diseño, gestión y comunicación profesional	29	Diseño, diseñar, gestionar, comunicar, comunicación	Profesional + tecnológico	La IA no desplaza diseñar y gestionar, pero incorpora formular problemas, validar resultados y supervisar decisiones automatizadas.
2. Actores profesionales, calidad y riesgo	19	Ingenieros, empresas, equipos, riesgo, calidad	Profesional + laboral/crítico	La competencia técnica se amplía hacia responsabilidad, validación, incertidumbre, calidad de datos y supervisión.
3. Supervisión y automatización	3	Supervisar, automatizar, automatización	Tecnológico	Es la coincidencia más directa: la automatización permanece, pero el papel del ingeniero se desplaza de ejecutar hacia supervisar sistemas automatizados.
4. Formación, empleo e IA	9	Formar, trabajar, currículo, empleo, IA	Educativo + laboral/crítico	La IA hace explícita la necesidad de modificar currículo, recualificar capacidades y alinear formación con nuevas tareas profesionales.
5. Identidad y pertenencia profesional	6	Identidad, estudiantes, desarrollar, pertenencia	Profesional + educativo	La IA modifica las fronteras de lo que se reconoce como competencia ingenieril y redistribuye la agencia entre profesionales, instituciones y sistemas.
6. Género e inclusión	2	Género, inclusión, reconocer	Relación indirecta con IA	La dimensión social permanece relativamente autónoma; la IA introduce problemas de acceso, sesgo y equidad, pero no sustituye las cuestiones previas de pertenencia e inclusión.

Tabla 9: Caracterización de las comunidades en la red académica, laboral y cultural.

La red integrada se organiza en seis comunidades de 29, 19, 3, 9, 6 y 2 nodos. Las dos de mayor tamaño concentran principalmente elementos procedentes de los corpus académico y laboral, asociados con diseño, gestión, sistemas, calidad y práctica profesional. En contraste, identidad, pertenencia, género e inclusión adquieren mayor presencia a partir del corpus social. Esta distribución muestra que la narrativa de la ingeniería posee un núcleo técnico y profesional compartido, pero se amplía cuando intervienen dimensiones sociales vinculadas con quién puede reconocerse como ingeniero y en qué condiciones se ejerce la profesión. Al contrastar esta estructura con el corpus específico sobre inteligencia artificial aparece una continuidad significativa: la IA no sustituye ese núcleo, sino que modifica la posición del ingeniero dentro de él. El énfasis se desplaza de la ejecución de cálculos y rutinas hacia la formulación de problemas, la integración de restricciones, la validación de resultados, la gestión de incertidumbre y la responsabilidad sobre decisiones mediadas por sistemas automatizados.

Este desplazamiento se observa con mayor claridad en las dimensiones de formación, empleo y automatización. En los 20 artículos académicos sobre IA e ingeniería, el 55% tuvo como acción principal rediseñar el currículo y vincular la formación con el trabajo, el 25% se concentró en aprender y evaluar mediante IA, el 15% en redefinir el campo o el perfil profesional y únicamente el 5% en diseñar u optimizar directamente mediante IA. El resultado cuestiona una interpretación centrada exclusivamente en la sustitución tecnológica. La transformación observada consiste, más bien, en una reorganización del trabajo del ingeniero: a medida que determinadas tareas pueden automatizarse, adquieren mayor relevancia la supervisión, la validación, la comunicación, el aprendizaje continuo y la responsabilidad profesional. La tecnología cambia las tareas, pero también modifica las capacidades que permiten conservar autoridad sobre ellas.

En este sentido, la inteligencia artificial no configura una ingeniería completamente nueva ni elimina las bases que históricamente han definido su ejercicio. Actúa como un acelerador de transformaciones que ya son visibles en la formación, el mercado laboral y la narrativa social. El cambio central no radica en abandonar el conocimiento técnico, sino en ampliar lo que significa dominarlo. La identidad profesional comienza a sustentarse no sólo en la capacidad de diseñar, calcular o producir, sino también en la capacidad de formular, evaluar, supervisar y responder por soluciones desarrolladas con sistemas cada vez más automatizados. Así, la expansión de la IA refuerza una transición desde una concepción de la ingeniería basada predominantemente en el dominio técnico hacia otra en la que dicho dominio se articula con juicio profesional, aprendizaje continuo y responsabilidad social.

5. Conclusiones

Dado el carácter exploratorio del estudio, los resultados no pretenden establecer una definición general de la ingeniería ni representar estadísticamente al conjunto de la profesión en México. Su aporte consiste en identificar patrones recurrentes dentro de tres corpus documentales construidos con unidades de análisis diferentes. En ellos se

observa un núcleo compartido alrededor del diseño, la gestión, los sistemas, la calidad y la resolución de problemas, aunque cada ámbito reorganiza estos elementos de forma distinta. El discurso académico enfatiza la formación y las capacidades esperadas, el mercado laboral traduce esas expectativas en funciones y competencias, mientras que el corpus social incorpora con mayor fuerza identidad, pertenencia, género, inclusión y reconocimiento. La integración de estas evidencias sugiere, como hipótesis de trabajo, que la narrativa de la ingeniería se configura mediante la interacción entre instituciones educativas, práctica profesional y representaciones sociales, y no a partir de una definición única y estable.

El contraste exploratorio con el corpus específico sobre inteligencia artificial refuerza esta interpretación, pero no permite afirmar una transformación definitiva de la profesión. Los documentos analizados sugieren que la IA no elimina el núcleo técnico de la ingeniería, sino que modifica el énfasis otorgado a determinadas funciones: junto con diseñar, calcular y producir adquieren mayor relevancia formular problemas, validar resultados, supervisar sistemas automatizados, gestionar incertidumbre, comunicar y asumir responsabilidad sobre decisiones mediadas tecnológicamente.

Más que demostrar la aparición de una nueva ingeniería, los resultados permiten plantear la hipótesis de que la IA está acelerando cambios que ya eran visibles en la formación, el trabajo y la narrativa social. En este sentido, el estudio ofrece una base empírica para investigaciones posteriores que amplíen los corpus, incorporen diseños longitudinales y contrasten si estos patrones se mantienen en otros contextos institucionales, profesionales y sociales.

Referencias

[1] Abbott, A. (1988). The system of professions: An essay on the division of expert labor. University of Chicago Press.

[2] Asociación Nacional de Universidades e Instituciones de Educación Superior. (s. f.). Anuario estadístico de educación superior.

[3] Cech, E. A. (2014). Culture of disengagement in engineering education? Science, Technology, & Human Values, 39(1), 42-72. https://doi.org/10.1177/0162243913504305

[4] Consejo de Acreditación de la Enseñanza de la Ingeniería, A. C. (2024). Manual del Marco de Referencia 2025 (MR 2025) para programas de ingeniería. https://cacei.org.mx/objs/crsl/carr03.pdf

[5] Csikszentmihalyi, M., & Wolfe, R. (2015). New conceptions and research approaches to creativity: Implications of a systems perspective for creativity in education. The systems model of creativity: The collected works of Mihaly Csikszentmihalyi, 161-184.

[6] Encyclopaedia Britannica. (s.f.). Engineering. In Britannica.com. Recuperado el 2 de septiembre de 2026, de https://www.britannica.com/technology/engineering

[7] Engineers' Council for Professional Development. (1947). Annual report for year ending September 30, 1947. ECPD.

[8] ETH Zürich. (2024). Bachelor-Studiengang Maschineningenieurwissenschaften: Anhang / Qualifikationsprofil. https://ethz.ch/content/dam/ethz/main/eth-zurich/organisation/rechtssammlung/323.1.0300.12.pdf

[9] Faulkner, W. (2000). Dualisms, hierarchies and gender in engineering. Social Studies of Science, 30(5), 759-792. https://doi.org/10.1177/030631200030005005

[10] Gieryn, T. F. (1983). Boundary-work and the demarcation of science from non-science: Strains and interests in professional ideologies of scientists. American Sociological Review, 48(6), 781–795.

[11] Harvard John A. Paulson School of Engineering and Applied Sciences. (s. f.). ABET information: Student outcomes. https://seas.harvard.edu/bioengineering/undergraduate-program/concentration-information/abet-information

[12] IBM. (2024). The biggest AI adoption challenges. IBM Think Insights. ibm.com

[13] Imperial College London. (2026). Professional Engineering Skills 3: Detailed module information. https://www.imperial.ac.uk/mechanical-engineering/study/undergraduate/detailed-module-information/next-academic-year/?module=MECH60015\&year=26_27

[14] Instituto Politécnico Nacional. (s. f.). Ingeniería en Sistemas Ambientales: Perfil de egreso. https://www.ipn.mx/oferta-educativa/educaci%C3%B3n-superior/ver-carrera.html?id=31&lg=es&nombre=Ingenier%C3%ADa-en-Sistemas-Ambientales

[15] Koehn, E. (2011). Engineering: A historical perspective of creativity and innovation. Journal of Professional Issues in Engineering Education and Practice, 137(4), 195-204. https://doi.org/10.1061/(ASCE)EI.1943-5541.0000068.

[16] Lerch, C. J., & de Vedia, L. A. (2013). El conocimiento tecnológico y el conocimiento ingenieril en la formación del ingeniero para un mundo cambiante. La Educación del Ingeniero en un mundo cambiante.

[17] Massachusetts Institute of Technology, Department of Civil and Environmental Engineering. (s. f.). Educational objectives & outcomes. https://cee.mit.edu/education/undergraduate/educational-objectives-outcomes-2/

[18] McKinsey & Company. (2024). The state of AI: Global survey. McKinsey & Company. mckinsey.com

[19] Mejia, J. A., y Christiansen, M. S. (2024). Unpacking whiteness and racialization in engineering: A multimodal discourse analysis of social media posts. 2024 ASEE Annual Conference & Exposition. https://doi.org/10.18260/1-2--48210

[20] Mora Gutiérrez, R. A. (2013). Diseño y desarrollo de un método heurístico basado en un sistema sociocultural de creatividad para la resolución de problemas de optimización continuos no lineales y diseño de

zonas electorales [Tesis doctoral, Universidad Nacional Autónoma de México]. Repositorio Ptolomeo. http://www.ptolomeo.unam.mx:8080/xmlui/handle/132.248.52.100/6066

[21] Mora-Gutiérrez, R. A., Ramírez-Rodríguez, J., y Rincón-García, E. A. (2014). An optimization algorithm inspired by musical composition. Artificial Intelligence Review, 41, 301-315. https://doi.org/10.1007/s10462-011-9309-8

[22] MVS Noticias. (2025, 1 de julio). Los memes más ingeniosos por el Día del Ingeniero. https://mvsnoticias.com/tendencias/viral/2025/7/1/asi-celebran-los-ingenieros-memes-inteligentes-que-marcan-el-de-julio-692921.html

[23] Protecnium. (2025, julio 14). ¿Qué es la ingeniería y cuáles son sus tipos? Una guía completa. https://protecnium.com/que-es-la-ingenieria-y-cuales-son-sus-tipos-una-guia-completa/

[24] Ramírez, F., Seco, A., & Cobo, E. P. (2011). New values for twenty-first century engineering. Journal of Professional Issues in Engineering Education & Practice, 137(4), 211-214.

[25] Rivera-Ramírez, S. (2017). El lenguaje (de los lenguajes) en la configuración de la realidad.La Colmena, (96), 33-39.

[26] Secretaría de Infraestructura, Comunicaciones y Transportes. (2026, 1 de julio). En la Cuarta Transformación, el sentido social de la ingeniería está al servicio del pueblo: Esteva Medina. Gobierno de México

[27] Stanford University. (2026). Engineering (BS): Program learning outcomes. Stanford Bulletin. https://bulletin.stanford.edu/programs/ENGR-BS/learning-outcomes-XmZiS

[28] UNAM Global. (2017, 27 de abril). El éxito de The Big Bang Theory. https://unamglobal.unam.mx/global_revista/el-exito-de-the-big-bang-theory/

[29] Universidad Autónoma Metropolitana, Unidad Azcapotzalco, División de Ciencias Básicas e Ingeniería. (s. f.). Perfil de ingreso-egreso de Ingeniería en Computación. https://cbi.azc.uam.mx/?page_id=2746

[30] Universidad Nacional Autónoma de México. (s. f.). Ingeniería Industrial: Perfil del egresado. Oferta Académica UNAM. https://www.oferta.unam.mx/ingenieria-industrial.html

[31] University of California, Berkeley, Electrical Engineering and Computer Sciences. (s. f.). Objectives and outcomes. https://eecs.berkeley.edu/academics/undergraduate/eecs-bs/objectives-outcomes/

[32] University of Cambridge, Department of Engineering. (s. f.). Part I aims & objectives. https://teaching.eng.cam.ac.uk/content/part-i-aims-objectives

[33] University of Oxford. (2026). Engineering Science. https://www.ox.ac.uk/admissions/undergraduate/courses/course-listing/engineering-science

[34] Yllanes, J., Soderborg, L., Tran, V., y McCall, C. (2025). Work-in-progress: Meme-ing engineering: Exploring student perceptions of engineering culture through memes. 2025 ASEE Annual Conference & Exposition. https://doi.org/10.18260/1-2--57540

Más allá de la respuesta: inteligencia artificial y construcción aumentada del conocimiento científico



Dr. Roman Anselmo Mora Gutiérrez*
Dr. Eric Alfredo Rincón García**
Dr. Sergio Gerardo de los Cobos Silva**
Dr. Miguel Ángel Gutiérrez Andrade**
Dr. Edwin Montes Orozco***
Dr. Pedro Lara Velázquez **
Dra. Fabiola Margarita Martínez Licona **
MC Alma Martínez Licona**

*Departamento de Sistemas, Universidad Autónoma Metropolitana, Unidad Azcapotzalco
**Departamento de Ingeniería Eléctrica, Universidad Autónoma Metropolitana, Unidad Iztapalapa
**Departamento de Computación, Electrónica y Mecatrónica, Universidad de las Américas Puebla

Imagen creada con IA generativa — OpenAI / ChatGPT

Abstract

Technological and scientific developments, social hyperconnectivity, the widespread adoption of generative artificial intelligence models, and the accelerated growth in information production have transformed the way conceptual frameworks, theoretical frameworks, and states of the art are constructed. This paper proposes understanding artificial intelligence not as an autonomous source of knowledge, but as an enhancer integrated into an iterative process of problematization, search, analysis, comparison, interpretation, and validation. It examines the risks associated with confirmation bias, human–AI feedback loops, epistemic homogenization, and the loss of peripheral perspectives during successive synthesis processes. Through several examples, the results obtained from different AI models in response to identical questions are compared in order to identify convergences, divergences, contradictions, and variations derived from the tool employed. The study proposes a guide for the augmented construction of knowledge in which AI expands the exploration space without replacing conceptual delimitation, interpretation, or human validation. Under this approach, AI can foster diversity of perspectives, creativity, and the identification of new relationships while maintaining scientific rigor and promoting critical questioning of the results obtained.

Keywords: generative artificial intelligence; knowledge construction; cognitive bias; algorithmic bias; information analysis; conceptual frameworks; state of the art.

Resumen

Los desarrollos tecnológicos y científicos, la hiperconectividad social, la masificación de los modelos generativos de inteligencia artificial y el crecimiento acelerado de la producción de información han modificado la forma en que se construyen los marcos conceptuales, teóricos y los estados del arte. Este trabajo propone comprender la inteligencia artificial no como una fuente autónoma de conocimiento, sino como un potenciador integrado a un proceso iterativo de problematización, búsqueda, análisis, contraste, interpretación y validación. Se examinan los riesgos asociados con el sesgo de confirmación, la retroalimentación humana sobre la IA, la homogeneización epistémica y la pérdida de perspectivas periféricas durante procesos sucesivos de síntesis. A partir de diversos ejemplos, se comparan los resultados obtenidos mediante distintos modelos de IA ante preguntas idénticas, con el fin de identificar convergencias, divergencias, contradicciones y variaciones derivadas de la herramienta utilizada. El trabajo propone una guía para la construcción aumentada del conocimiento, en la que la IA amplíe el espacio de exploración sin sustituir la delimitación conceptual, la interpretación ni la validación humana. Bajo este enfoque, la IA puede favorecer la diversidad de perspectivas, la creatividad y la identificación de nuevas relaciones, al tiempo que se mantiene el rigor científico y se promueve el cuestionamiento crítico de los resultados obtenidos.

Palabras clave: inteligencia artificial generativa; construcción del conocimiento; sesgo cognitivo; sesgo algorítmico; análisis de información; marcos conceptuales; estado del arte.

1. Introducción

Durante mucho tiempo, una de las

principales dificultades del trabajo académico fue localizar información suficiente. Hoy el problema es distinto. Internet, la hiperconectividad y la apertura progresiva del conocimiento científico han multiplicado los artículos, libros, datos y documentos disponibles en repositorios y plataformas digitales. En pocas décadas pasamos de buscar entre recursos escasos a intentar orientarnos dentro de una cantidad de información que crece continuamente.

Esta transformación comenzó a consolidarse durante la década de 1990. La creación de arXiv en 1991 abrió una vía temprana para compartir prepublicaciones científicas (Salatino & Banzato, 2021). En 1994 la Universidad de Oviedo funda JSTOR, abreviatura de las palabras en inglés *Journal STORage* (almacén de publicaciones periódicas) como un objeto para la conservación y consulta digital de publicaciones académicas (Universidad de Oviedo, s.f.). Posteriormente, es lanzado ScienceDirect, por Elsevier en 1997 (Gies, 2018), con 3800 artículos y libros este sitio amplió la distribución comercial de libros y artículos científicos. Más tarde, la aparición de Sci-Hub en 2011 hizo visibles las tensiones entre los modelos comerciales de publicación y las demandas de acceso abierto (Banks, 2016). Al mismo tiempo, universidades y centros de investigación crearon repositorios institucionales y revistas electrónicas para preservar y difundir su producción. En el caso de Latinoamérica los proyectos Latindex (1995), SciELO (1997) y Redalyc (2002), han sido fundamentales en la masificación de información y el conocimiento científicas (Salatino & Banzato, 2021).

Aunque actualmente el acceso a la información y al conocimiento continúa siendo desigual (Beigel, 2022), se han desarrollado diversas estrategias orientadas a su democratización, entre ellas la Recomendación de la UNESCO sobre la Ciencia Abierta (Ricardo & Fernández 2022).

Sin embargo, una vez ampliado el acceso, surgen nuevos problemas relacionados con la búsqueda, selección, evaluación, articulación e interpretación de la información. Entre ellos destacan las siguientes preguntas: ¿a qué fuentes se tiene realmente acceso?, ¿cómo transformar cantidades crecientes de datos en información útil?, ¿cómo seleccionar los repositorios más pertinentes?, ¿qué información debe incorporarse y cuál debe descartarse? Disponer de un mayor número de documentos no garantiza una mejor comprensión de un fenómeno. Por el contrario, puede dificultar la investigación cuando no existen criterios suficientes para distinguir lo relevante de lo accesorio, la evidencia de la opinión o una explicación sólida de una respuesta simplemente convincente. En la figura 1 se esquematiza esta situación, al que se le denomina el desafío de la infoxicación.

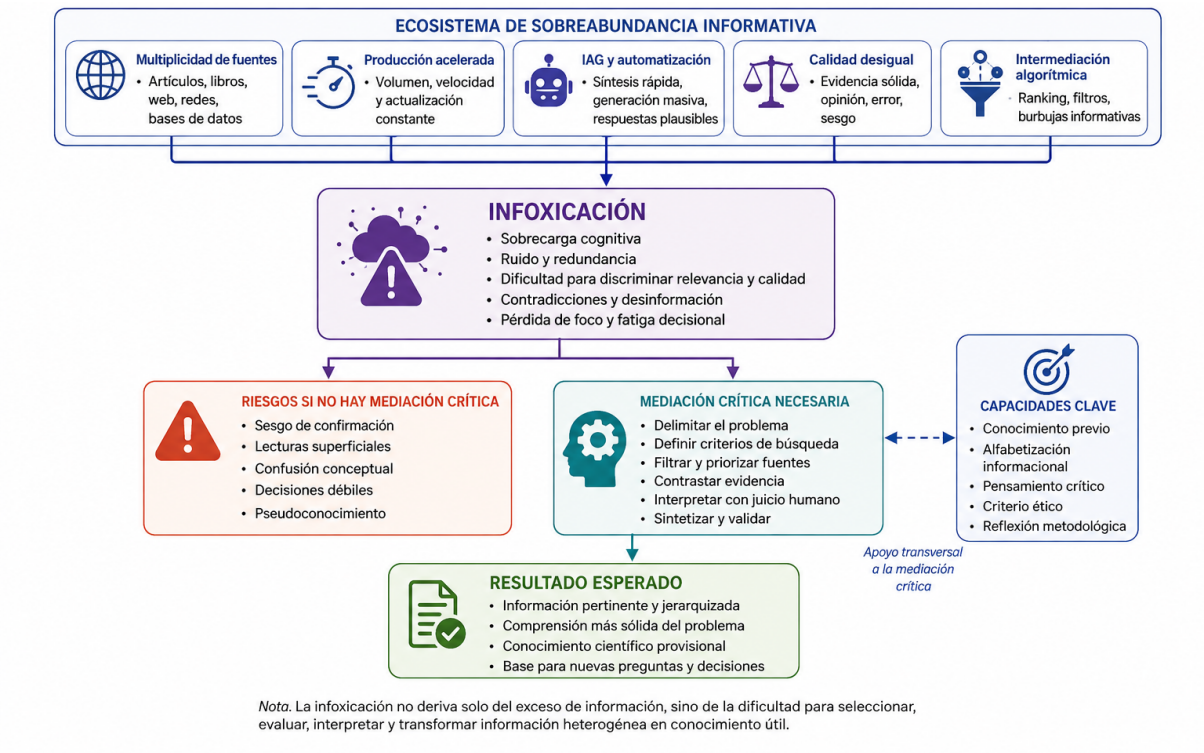

Figura 1: El desafío de la infoxicación. (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

A inicios de la década de 2020 se ha producido un crecimiento acelerado en la disponibilidad de herramientas, estrategias y métodos basados en inteligencia artificial generativa (IAG). Estos sistemas han transformado la manera de comparar documentos, resumir argumentos, localizar patrones, sugerir relaciones y generar nuevas representaciones de la información, entre otras tareas. Su uso puede reducir significativamente el tiempo dedicado a determinadas actividades de búsqueda, organización y análisis.

Sin embargo, una respuesta clara, extensa y técnicamente sofisticada no constituye, por sí misma, conocimiento científico. Tampoco garantiza que las decisiones conceptuales, teóricas o metodológicas incorporadas en ella sean correctas, pertinentes o estén adecuadamente sustentadas. En consecuencia, no existe una relación lineal entre el uso de la IAG y la producción de conocimiento científico, asumir esto sería decir que existe una relación lineal entre poseer lápiz y papel y ser capaz de crear un dibujo que sea arte. En otras palabras, una salida generada por IAG puede constituir información, una interpretación, una propuesta, una hipótesis o incluso una solución potencialmente novedosa; sin embargo, para adquirir valor como conocimiento científico debe ser sometida a procesos de contraste, contextualización, evaluación y validación. Lo anterior se representa en la Figura 2 como un ciclo de relación Humano -IAG

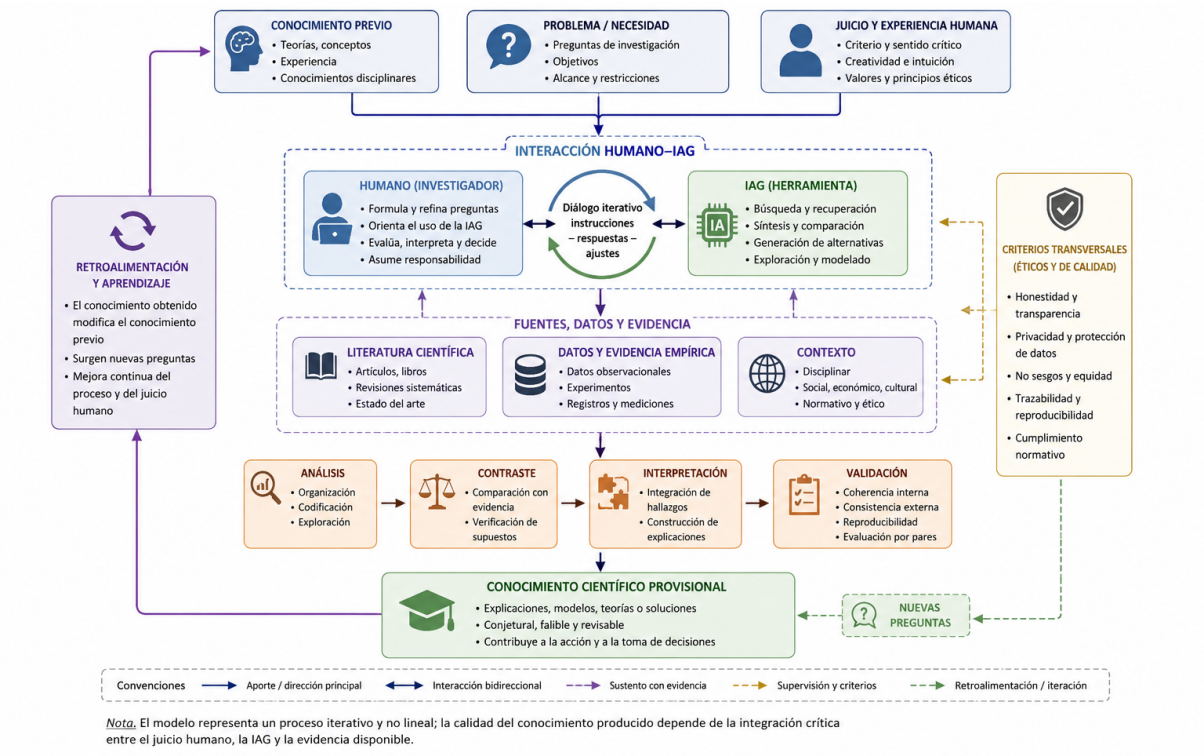

Figura 2: Modelo de interacción humano-IAG para la generación de conocimiento. (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

En el presente trabajo se analiza cómo puede incorporarse la IAG en la construcción del marco conceptual, el marco teórico y el estado del arte mediante un proceso explícito de problematización, búsqueda, selección, interpretación, contraste y validación, siguiendo el procedimiento presentado en la Figura 2. Para ello, se emplea un ejemplo comparativo que permite examinar cómo distintos modelos de IAG organizan y responden a una misma consulta científica. A partir de este análisis, se propone un proceso de investigación aumentada orientado a preservar la trazabilidad de las fuentes, la diversidad del corpus y la responsabilidad epistémica del investigador.

El artículo se organiza de la siguiente manera. En la segunda sección se presenta el marco conceptual además se expone un breve estado del arte sobre el uso de la IAG en la producción científica. En la tercera sección se describe plantea un caso exploratorio del uso de la IAG en la investigación; además se realiza un análisis comparativo de las respuestas generadas por Gemini, Grok y DeepSeek ante una misma consulta científica, en esta sección se presentan, analizan y contrastan los resultados obtenidos, a partir de los cuales se identifican convergencias, divergencias, omisiones y decisiones implícitas de encuadre. Finalmente, se presentan las conclusiones, las limitaciones del estudio y las posibles líneas de investigación futura.

2. Estado del Arte

a. Antecedentes sobre el uso de la IAG en la investigación científica

De acuerdo con Amazon Web Servicies (s. f.) e IBM (s. f.), la inteligencia artificial

generativa (IAG) comprende sistemas capaces de producir contenidos, como texto, imágenes, audio, música o video, a partir de instrucciones formuladas por los usuarios. Para ello, emplea técnicas de aprendizaje automático y aprendizaje profundo que permiten identificar patrones en grandes volúmenes de datos y generar nuevas respuestas a partir de ellos. Sin embargo, que una respuesta sea coherente o plausible no implica necesariamente que sea correcta, pertinente o científicamente válida.

La literatura reciente muestra que la discusión sobre la IAG ha dejado de centrarse únicamente en las herramientas disponibles y se ha desplazado hacia sus efectos en los procesos de investigación. Chocobar Reyes *et al.* (2025) revisan diferentes herramientas de IAG y sus posibilidades de aplicación. Herrera (2023) plantea que su incorporación puede representar un punto de inflexión, no solo porque permite hacer más eficientes determinadas tareas, sino porque puede modificar la forma en que se producen, comunican y utilizan los resultados científicos. En una línea semejante, Lopezosa (2023) analiza su empleo en la comunicación científica y destaca su intervención en la producción, organización y difusión de contenidos.

Estas posibilidades también plantean límites y responsabilidades. Camino y Clavijo (2024) reconocen el potencial de la IAG para apoyar la investigación científica, pero identifican preocupaciones, resistencias e implicaciones éticas asociadas con su uso. De manera complementaria, Cárdenas *et al.* (2024) analizan los dilemas éticos y morales derivados de la incorporación de la inteligencia artificial. En conjunto, estos trabajos sugieren que la discusión no debería reducirse a decidir si la IAG debe utilizarse o no, sino a determinar cómo puede incorporarse, con qué propósito y bajo qué mecanismos de supervisión y validación.

En este punto resulta fundamental considerar la interacción entre la herramienta y quien la utiliza. Ramírez Islas*et al.* (2025) muestran experimentalmente que las herramientas basadas en IA no necesariamente producen resultados óptimos sin intervención humana y destacan la importancia de la creatividad combinatoria, entendida como la interacción entre creatividad humana y herramientas automatizadas. Por ello, la IAG puede ampliar las capacidades de búsqueda, análisis, organización y exploración de alternativas, pero no sustituye el conocimiento previo, la experiencia, el juicio crítico ni los criterios empleados para valorar la pertinencia de los resultados.

Desde esta perspectiva, el objetivo de incorporar IAG a la investigación no debería limitarse a producir más textos o procesar información con mayor rapidez. El problema consiste en determinar cómo utilizar estas tecnologías para mejorar la formulación de preguntas, ampliar la búsqueda y el contraste de información, favorecer la comunicación científica y fortalecer los procesos de evaluación y construcción de conocimiento. En este sentido, incluso las advertencias expresadas en el debate público sobre los posibles efectos positivos y negativos de la inteligencia artificial (CNN, 2026) refuerzan la necesidad de analizar no solo lo que estas tecnologías pueden hacer, sino las condiciones bajo las cuales deben emplearse.

b. Proceso de investigación y construcción iterativa del conocimiento

El proceso de investigación puede entenderse como un sistema creativo y racional, individual o colectivo, mediante el cual se construye una aproximación a un fenómeno a partir de la cosmovisión, las experiencias previas, los intereses, las capacidades, los conceptos y los supuestos de quienes investigan (Córdoba-Cely & Martínez (2025).). Este proceso puede originarse cuando algún aspecto de la realidad despierta una inquietud intelectual: un comportamiento que no se comprende, una explicación que resulta insuficiente, un procedimiento susceptible de mejora, un objeto que requiere ser diseñado o una contradicción que merece ser examinada. En la figura 3 se esquematizan estas ideas.



Figura 3: Idealización del proceso de investigación (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

Cuando se incorpora la IAG en este proceso, la persona investigadora aporta conocimiento previo, experiencia, juicio crítico, capacidad para formular problemas y preguntas, criterios de pertinencia y mecanismos de validación. En consecuencia, los resultados obtenidos mediante IAG dependen en buena medida de la capacidad del investigador para orientar la consulta, interpretar las respuestas, contrastarlas con otras fuentes y evaluar su pertinencia.

c. Limitaciones y consideraciones de uso de la IAG en la investigación

La IAG, por su parte, puede ampliar las capacidades de búsqueda, procesamiento, comparación, síntesis, exploración de información y generación de alternativas. Sin embargo, estas capacidades no son ilimitadas ni neutrales, ya que están condicionadas por la arquitectura y los algoritmos del sistema, por los datos con los que fue entrenado y por los sesgos, omisiones y patrones presentes en dicha información

(Autrán, 2023, Mora-Gutierrez 2026, Carrera). Por ello, la IAG no sustituye el juicio del investigador, sino que funciona como una herramienta cuyo valor depende de la forma en que sus resultados sean interpretados, contrastados y validados dentro del proceso de investigación.

Para ejemplificar lo anterior, puede considerarse el caso de Allan Brooks (La Nación, 2025), quien, después de una interacción prolongada con ChatGPT, interpretó que había desarrollado un descubrimiento matemático relevante. La propia dinámica de interacción con el sistema habría contribuido a reforzar progresivamente esa interpretación, hasta que la intervención de especialistas externos permitió cuestionar el valor atribuido a la propuesta e identificar errores en ella. En este caso se debe considerar que los grandes modelos de lenguaje empleados por las herramientas de IAG funcionan de manera probabilística, por lo que una misma consulta puede generar respuestas diferentes. Este problema surgió porque una respuesta se usó como punto de partida para la siguiente consulta de manera iterativa, ya que los elementos más visibles pueden reforzarse una y otra vez, mientras que otros menos frecuentes dejan de explorarse. Esto puede dar la impresión de que el conocimiento se amplía, cuando en realidad también puede estar estrechándose hacia las mismas ideas. Por ello, frecuencia no significa importancia científica.

La lección que se desprende de este caso no es que una persona sin formación especializada sea incapaz de realizar aportaciones con ayuda de la IA, sino que la repetición de un procedimiento no garantiza su corrección cuando las comprobaciones permanecen dentro del mismo circuito de interacción. En ese contexto pueden combinarse sesgos cognitivos, sociales, económicos y paradigmáticos de la persona investigadora con los sesgos derivados de los datos, el diseño y el funcionamiento del sistema.

En contraste, Devlin (2026) presenta el caso de un problema de Erdős como ejemplo de una contribución apoyada por IA que fue posteriormente reconstruida, revisada y evaluada por especialistas. Su relevancia metodológica no radica únicamente en la rapidez con la que una IA puede proponer una solución, sino en el proceso posterior de contraste, revisión experta y validación independiente. En este mismo sentido, Witten (2026) muestra un uso de la IAG como herramienta de apoyo para ampliar y explorar una argumentación especializada, mientras que la formulación, interpretación y validación permanecen bajo responsabilidad experta. Ambos casos sugieren que el valor científico de la IAG no depende exclusivamente de su capacidad generativa, sino de su integración en un proceso de investigación sometido a revisión crítica. Por ello, no existe una relación lineal entre el uso de la IAG y la generación de conocimiento científico, ya que su contribución depende de la manera en que se articula con el conocimiento especializado, el contraste externo y los mecanismos de validación. Lo anterior se representa en la Figura 4.



Figura 4: Representación de los posibles casos de interacción humano-IA en la investigación Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

La conocida analogía del mono que pulsa teclas al azar permite ilustrar esta diferencia. En condiciones puramente teóricas y con tiempo suficiente, una secuencia aleatoria podría llegar a reproducir una obra de Shakespeare. Sin embargo, esa posibilidad no responde las preguntas realmente importantes: ¿cuánto tiempo sería necesario?, ¿cómo identificar la obra entre millones de secuencias?, ¿qué criterios permitirían reconocer su valor y quién podría comprenderla? y ¿cómo distinguirla de aquello que carece de sentido? Producir una secuencia correcta no implica necesariamente comprenderla ni valorar su significado. De manera semejante, una IAG puede generar una explicación coherente, técnicamente elaborada y aparentemente convincente sin que quien la recibe disponga de los elementos necesarios para distinguir entre una aportación válida, una afirmación insuficientemente sustentada o un error presentado de manera persuasiva.

d. Proceso de investigación asistido con la IAG

Como se ha señalado, el proceso de investigación no comienza desde una posición neutral ni desde una ausencia de conocimiento. Toda persona investigadora se aproxima a un problema desde un estado epistemológico previo, configurado por su experiencia, formación disciplinar, conocimientos acumulados, conceptos disponibles, intereses, supuestos, expectativas y formas particulares de interpretar la realidad. Este punto de partida constituye una perspectiva situada desde la cual determinados fenómenos adquieren relevancia, ciertas preguntas resultan pertinentes y algunas explicaciones aparecen inicialmente como plausibles.

La complejidad aumenta cuando la investigación es colectiva. En ese caso, no interviene una sola perspectiva, sino la interacción entre distintos marcos

conceptuales, trayectorias formativas, experiencias, intereses y criterios de interpretación. Esta diversidad puede ampliar la capacidad de análisis y favorecer el contraste interno, pero también puede introducir desacuerdos, sesgos compartidos o supuestos que pasan inadvertidos dentro del propio grupo. Por ello, la construcción colectiva del conocimiento no elimina la influencia de las perspectivas previas, sino que las articula, confronta y, en algunos casos, las refuerza.

Entonces, el conocimiento previo y la experiencia no son elementos externos al proceso de investigación, sino condiciones que hacen posible su inicio y orientan su desarrollo. Sin embargo, precisamente porque influyen en lo que se observa, se pregunta y se interpreta, estos referentes también deben hacerse explícitos y someterse a contraste crítico. Aquello que permite observar un fenómeno también puede limitar o sesgar la manera en que se comprende.

Estos sesgos pueden manifestarse en distintos niveles como distorsiones de la realidad causadas por el cristal s través del cual se mira. Puede existir una distorsión técnica, cuando los métodos o instrumentos empleados restringen aquello que puede observarse; una distorsión conceptual, cuando las categorías utilizadas condicionan la forma de interpretar el fenómeno; o una distorsión epistemológica, cuando los supuestos sobre qué cuenta como evidencia válida o conocimiento aceptable reducen el campo de posibles explicaciones entre otras distorsiones o sesgos. En cualquiera de estos casos, dichas distorsiones pueden afectar la formulación del problema, la selección de información, la interpretación de la evidencia y el descarte prematuro de explicaciones alternativas.

Por lo anterior, una investigación asistida por IAG debería comenzar no con la generación inmediata de respuestas, sino con la explicitación de las condiciones iniciales desde las cuales se formula el problema. Es decir, la IAG al inicio de la investigación puede ayudar a identificar supuestos implícitos, conceptos ambiguos, relaciones no justificadas, explicaciones alternativas, vacíos de información y posibles contradicciones; con lo cual se busca tanto, ampliar el espacio de hipótesis y cuestionamientos disponibles para la persona investigadora. No obstante, esta capacidad tampoco es neutral, pues como se mencionó la IAG incorpora sus propios límites y sesgos, lo anterior se esquematiza en la Figura 5.



Figura 5: Representación del proceso de Investigación asistido por IAG (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

En la sección siguiente se empleará esta guía en la construcción del estado del arte, marco teórico y marco conceptual con un ejemplo práctico.

3. Caso de estudio.

Si se plantea llevar a cabo una investigación asistida por IAG sobre un tópico particular, de acuerdo con lo expuesto en la Figura 5, es fundamental comenzar por cuestionar qué se sabe sobre el tema, qué experiencia previa se posee y qué se ha desarrollado en investigaciones recientes. Solicitar a una IAG que redacte de inmediato un trabajo de investigación en esta etapa temprana puede conducir a errores conceptuales, omisiones y problemas de validación. Surgen entonces preguntas fundamentales: ¿cómo determinar si el contenido generado es realmente relevante?, ¿con qué criterios puede validarse?, ¿corresponde a desarrollos recientes del campo o simplemente reorganiza información ya conocida?, ¿permite reconocer la frontera actual del conocimiento disponible?, entre otras.

Una falacia frecuente consiste en asumir que el acceso masivo a información y a sistemas capaces de generar respuestas implica que cualquier problema puede resolverse mediante una sucesión suficientemente extensa de consultas. Sin embargo, existe una diferencia fundamental entre explorar aquello que todavía se desconoce y buscar información sin disponer de criterios suficientes para valorar su pertinencia, calidad o validez. La disponibilidad de más respuestas no garantiza una mejor comprensión del problema y, en ausencia de referentes conceptuales, teóricos y metodológicos, incluso puede incrementar la confusión, reforzar sesgos previos o conducir a aceptar como relevantes resultados que solo son plausibles en apariencia.

Por consiguiente, instrucciones genéricas como "construir un marco teórico de los últimos cinco años sobre..." constituyen una inconsistencia metodológica que favorece sesgos, omisiones y respuestas insuficientemente sustentadas. Sumado a ello, es indispensable cuestionar si el contenido generado resulta significativo para quien investiga y pertinente para el problema formulado. Esta práctica resulta análoga al cuestionamiento que años atrás se hacía sobre la copia acrítica de definiciones de diccionarios o fragmentos web, realizada sin comprender el proceso ni desarrollar la pericia necesaria para articularlos.

Por ello, la IAG no debería comenzar por elaborar el producto final, sino que su función inicial debe orientarse a identificar las decisiones conceptuales, teóricas y metodológicas que permanecen abiertas, así como los vacíos, supuestos y relaciones que requieren revisión. En consecuencia, al inicio del proceso resulta indispensable delimitar el problema y hacer explícito el conocimiento existente mediante la construcción de los pilares epistemológicos fundamentales de la investigación.

En el modelo mostrado en la Figura 6, se muestra que el marco conceptual, el marco teórico y el estado del arte constituyen la estructura de fundamentación que transforma el punto de partida en una investigación rigurosa. En esta fase la IAG se puede emplear como instrumento de búsqueda, organización, análisis y síntesis de información, pero sus resultados deben ser contrastados y evaluados por la persona investigadora. En este sentido, García Aguirre *et al.* (2024) analizan diversas herramientas de IAG orientadas a apoyar la elaboración de estos componentes.



Figura 6: Pilares iniciales en la investigación asistida por IAG. (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

Para ejemplificar lo anterior, se emplea la IAG en la construcción de los pilares de investigación en torno al concepto de sistema complejo, debido a que presenta varias dificultades relevantes desde el punto de vista epistemológico y metodológico. En primer lugar, no existe una definición única y plenamente consensuada por la comunidad científica (Martínez Mekler, 2000 & Pérez 2021). Además, el concepto se utiliza en campos muy diversos, que abarcan desde las matemáticas y la física hasta la economía, el arte y la política (Romano, 2001 & Sanjuán 2016). Esta amplitud disciplinar hace que un mismo término pueda adquirir significados, supuestos y criterios de análisis distintos según el contexto en el que se emplee.

Por ello, los sistemas complejos son un buen ejemplo para mostrar que una búsqueda asistida por IAG no debe empezar solo pidiendo una definición general. Primero es necesario decidir desde qué disciplina o combinación de disciplinas se abordará el problema, qué conceptos son centrales y con qué criterios se reconocerá que un sistema es realmente complejo.

En este punto surgen preguntas inevitables: ¿qué definición se va a utilizar?, ¿qué propiedades permitirán distinguir un sistema complejo de uno que no lo es?, ¿se trabajará desde una perspectiva disciplinar, multidisciplinar o transdisciplinar? Estas decisiones deben quedar en manos de la persona investigadora. Si no se hacen explícitas, la IAG puede asumirlas de manera implícita y orientar la investigación hacia una definición o enfoque que quizá no sea el más pertinente.

Ante la existencia de varias definiciones posibles, la persona investigadora puede optar por adoptar una sola, mantener varias en contraste o construir una definición operativa a partir de ellas. La IAG puede ayudar a localizar, comparar y organizar estas alternativas, pero no debería decidir por sí misma cuál es adecuado para el problema estudiado. Además, cuando existen distintas perspectivas disciplinares o teóricas, corresponde a la persona investigadora emplear su experiencia y conocimiento previo para definir el enfoque y los paradigmas desde los cuales se desarrollará la investigación. Esta elección requiere juicio crítico, coherencia con el problema planteado y una justificación metodológica clara. El proceso de toma de decisiones se esquematiza en la Figura 7.

Para mostrar qué ocurre cuando estas decisiones no se hacen explícitas, se proporcionó a DeepSeek, Gemini y Grok el mismo prompt: “En un párrafo, define un sistema complejo”. Cabe aclarar que las respuestas obtenidas constituyen evidencia exploratoria y no un experimento completamente reproducible. Para alcanzar ese nivel sería necesario, además de emplear el prompt exacto, documentar de manera sistemática el modelo y la versión utilizada, la modalidad de ejecución, la fecha de consulta, el acceso o no a búsqueda web, el contexto previo de conversación, el idioma, el número de repeticiones y los criterios empleados para codificar, auditar cada respuesta entre otras cosas.

Los resultados se presentan en la Tabla 1. Ante una instrucción abierta y sin delimitación disciplinar, cada sistema selecciona de manera implícita determinados conceptos, propiedades y formas de entender qué constituye un sistema complejo. Como se observa en la Figura 8, las tres IAG convergen en un núcleo conceptual

basado en múltiples componentes interdependientes, interacciones no lineales y propiedades emergentes. Sin embargo, difieren en las características adicionales que incorporan y en la importancia que asignan a cada una. Esto muestra que una respuesta aislada no es suficiente para establecer una definición de trabajo, sino que requiere un proceso posterior de contraste con la literatura, justificación conceptual y validación por parte de la persona investigadora.

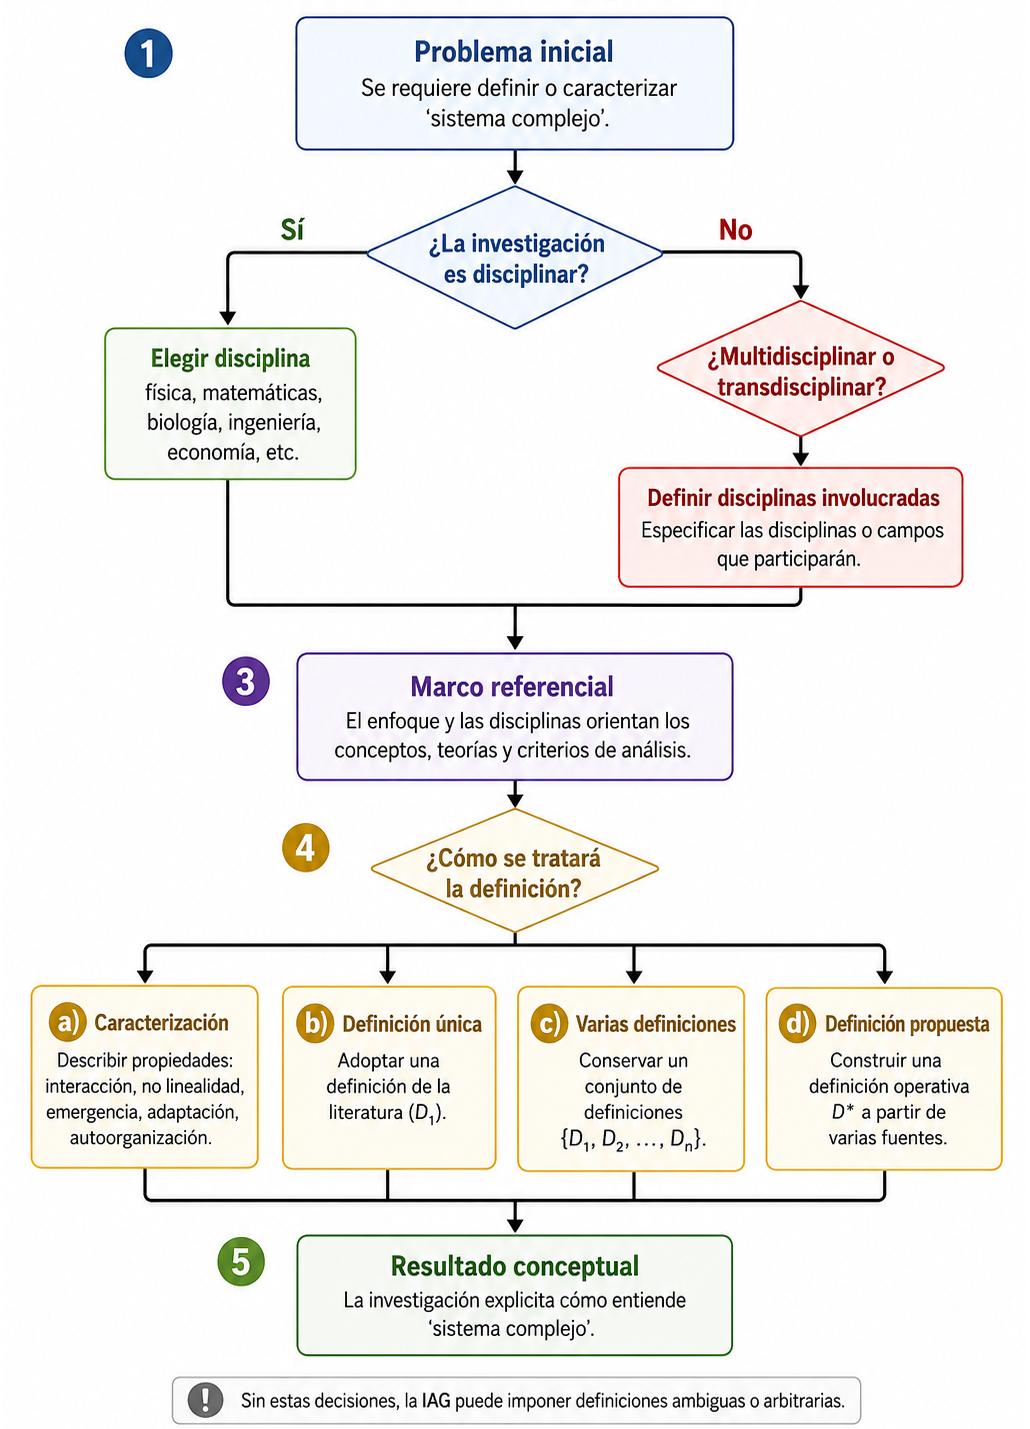

Figura 7: Ruta de decisiones implicadas al definir el problema en el proceso de investigación. (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

Sistema	Respuesta generada
DeepSeek	Un sistema complejo es una red de numerosos componentes interdependientes que, mediante interacciones no lineales y retroalimentaciones mutuas, generan un comportamiento colectivo emergente que no puede predecirse ni explicarse a partir de las propiedades aisladas de sus partes. Estos sistemas operan en un delicado equilibrio entre el orden y el caos, en un régimen conocido como "criticalidad autoorganizada", donde pequeñas perturbaciones locales pueden desencadenar efectos globales desproporcionados, y su evolución es irreversible, adaptativa y sensible a la historia.
Gemini	Un sistema complejo es una red compuesta por múltiples elementos interconectados e interdependientes cuyas interacciones generan un comportamiento colectivo emergente, imposible de predecir o entender estudiando cada parte por separado. Presenta propiedades como no linealidad, autoorganización, adaptación y retroalimentación, por lo que pequeñas variaciones pueden provocar efectos amplios e impredecibles.
Grok	Un sistema complejo es un conjunto formado por numerosos elementos o agentes interconectados que interactúan de manera no lineal, generando comportamientos emergentes, autoorganización y propiedades colectivas que no pueden explicarse únicamente a partir de las características individuales de sus componentes. Estos sistemas suelen presentar retroalimentación, adaptabilidad, sensibilidad a las condiciones iniciales y capacidad de reorganización.

Tabla 1: Resultados obtenidos con diferentes sistemas de IAG al mismo prompt

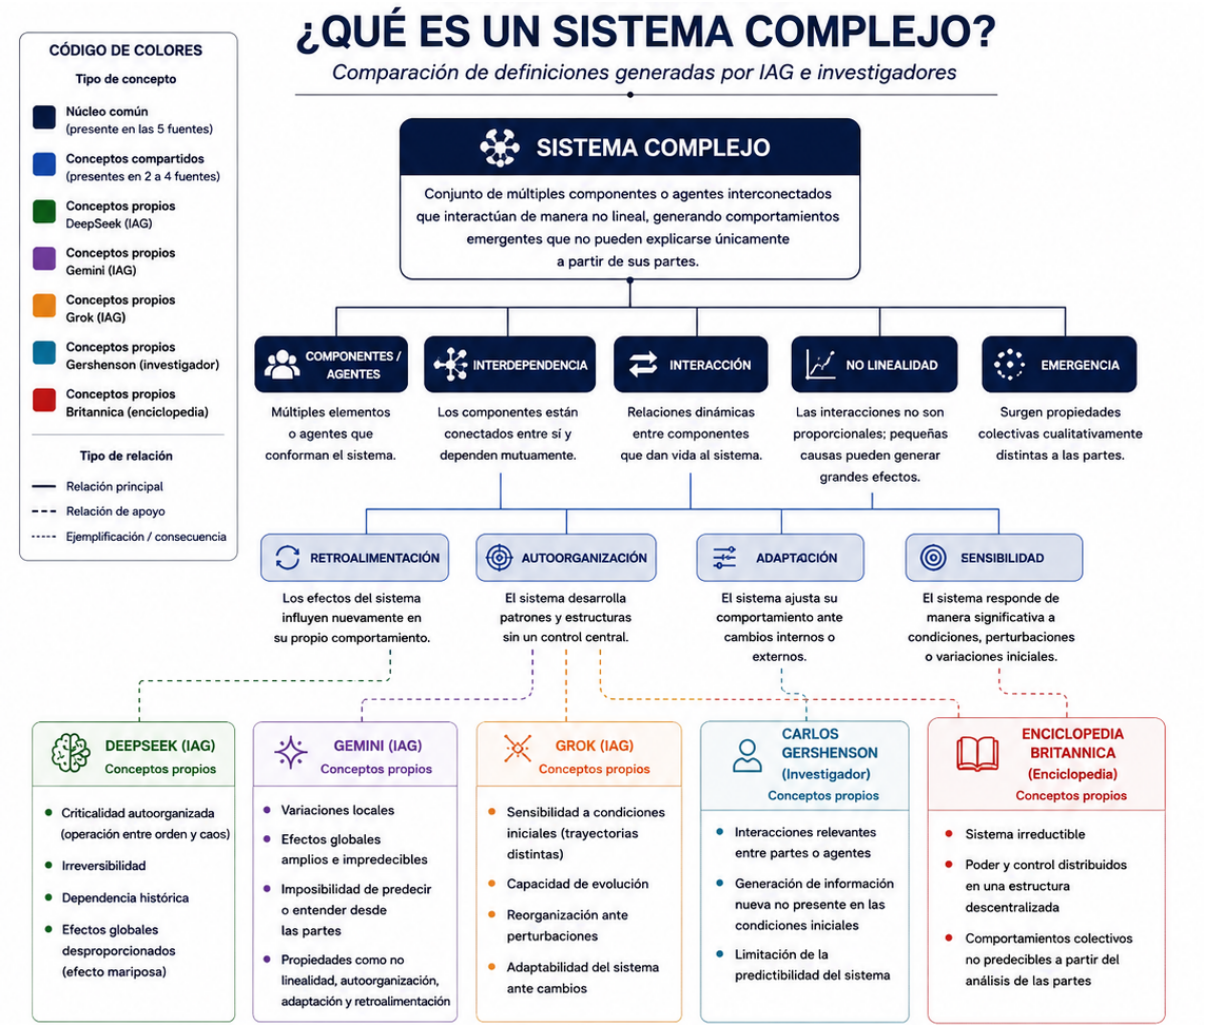

Figura 8: Comparativo de conceptos (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

Para ampliar este contraste, en la misma figura se incorporaron dos definiciones provenientes de la literatura. Encyclopaedia Britannica (s. f.) caracteriza al sistema complejo como un sistema irreductible en el que el poder y el control se distribuyen de manera descentralizada y cuyo comportamiento colectivo no puede predecirse únicamente a partir del análisis de sus componentes. Por su parte, Gershenson (2013) destaca la interacción relevante entre múltiples partes o agentes y la generación de información nueva que no se encuentra presente en las condiciones iniciales, lo que limita la predictibilidad del sistema.

La comparación muestra que las respuestas generadas por IAG recuperan varios elementos presentes en la literatura, pero también incorporan propiedades que no aparecen de manera uniforme en todas las fuentes. Esta variación puede relacionarse con la naturaleza probabilística de los modelos, con la presencia y frecuencia de ciertos conceptos en los datos de entrenamiento y, cuando existe recuperación de información, con las fuentes disponibles durante la consulta. Por ello, los conceptos más difundidos tienden a aparecer con mayor recurrencia y pueden conformar un núcleo común entre distintas respuestas, mientras que ideas menos visibles, relaciones menos frecuentes o perspectivas más específicas pueden aparecer solo en algunas de ellas. Sin embargo, frecuencia no equivale a importancia científica. Una idea poco frecuente puede ser irrelevante, pero también puede representar una anomalía, una contradicción, una perspectiva minoritaria o una línea emergente que merezca ser investigada.

Este punto introduce una tensión importante. Un marco conceptual o teórico que ignore el núcleo consolidado de un campo puede carecer de fundamento, pero una investigación que se limite a reproducir únicamente ese núcleo difícilmente podrá identificar preguntas nuevas, contradicciones o vacíos relevantes. La tarea de la persona investigadora consiste, por tanto, en reconocer qué elementos forman parte del conocimiento ampliamente aceptado y cuáles representan diferencias, debates o posibilidades que requieren un análisis más cuidadoso.

El ejemplo permite mostrar que la construcción del concepto central de una investigación ya implica decisiones epistemológicas. No basta con reunir definiciones; es necesario distinguir entre el núcleo conceptual compartido, las propiedades que dependen del enfoque adoptado y aquellas afirmaciones que requieren verificación antes de incorporarse al marco conceptual. Esta distinción es especialmente importante cuando un mismo término se utiliza en disciplinas diferentes o cuando no existe una definición plenamente consensuada.

Por ello, la definición del problema y la construcción del marco conceptual no pueden resolverse simplemente preguntando a una IAG cuál es la definición “correcta” o qué concepto debería utilizarse. Sin un contexto disciplinar, un paradigma de referencia y criterios explícitos de selección y validación, el sistema puede producir respuestas divergentes, incorporar supuestos no justificados o presentar como sólidas afirmaciones que solo resultan plausibles. En esta etapa, la función de la IAG no debería ser decidir por la persona investigadora, sino ampliar el espacio de búsqueda, hacer visibles alternativas, facilitar su

comparación y apoyar su contraste con la literatura, la evidencia y el marco epistemológico de la investigación.

En este punto surge una nueva pregunta: ¿qué ocurre si se solicita a los tres modelos de IAG el mismo prompt, por ejemplo, “Dame un cuadro con 5 elementos del estado del arte de los sistemas complejos en los últimos cinco años desde una perspectiva multidisciplinaria”. Aunque la instrucción parece más específica que pedir una definición general, en realidad sigue siendo demasiado abierta. El término multidisciplinario no establece qué disciplinas deben incluirse, ni con qué peso o criterio deben seleccionarse; tampoco define desde qué conceptualización de sistema complejo se realizará la búsqueda, qué periodo exacto se considerará, qué tipo de publicaciones serán válidas o en qué contexto se aplicará el análisis. Se menciona que el propósito de este ejemplo no es determinar qué sistema ofrecía la mejor respuesta, sino observar cómo cada uno seleccionaba cinco elementos y construía con ellos una representación del campo.

Por tanto, el problema no radica únicamente en la capacidad de la IAG para localizar y organizar información, sino en las decisiones que permanecen implícitas dentro del prompt. Si estas decisiones no se hacen explícitas, cada modelo puede construir un estado del arte distinto, no necesariamente porque uno sea correcto y otro incorrecto, sino porque cada uno puede interpretar de manera diferente el alcance disciplinar, los conceptos relevantes, las fuentes prioritarias y los criterios de selección. En consecuencia, antes de solicitar el estado del arte es necesario delimitar el problema, definir las disciplinas involucradas, establecer la conceptualización de referencia y fijar criterios claros para la búsqueda, comparación y validación de la literatura.

Las respuestas se muestran en las tablas 2, 3 y 4 para los modelos Grok, Gemini y DeepSeek, respectivamente. Su redacción se conserva sin correcciones; únicamente se reorganizan tipográficamente en cuadros de dos columnas para hacerlas legibles. Por otro lado, en la Figura 9 se muestra una auditoria de los resultados obtenidos.

Elemento del estado del arte	Respuesta generada
Redes de orden superior (higher-order networks)	Descripción principal: Modelado y análisis de interacciones no pareadas (hipergrafos, complejos simpliciales) que generan fenómenos colectivos nuevos, como sincronización explosiva, multistabilidad y transiciones de fase controladas por anidamiento (nesting). Perspectiva multidisciplinaria y avances clave (aprox. 2021-2026): Física + neurociencia + biología + ciencias sociales: revisiones y estudios muestran cómo la topología de orden superior moldea dinámicas (Nature Reviews Physics 2026; Nature Physics 2025); aplicaciones en función cerebral más allá de conexiones par a par (Nature Communications 2026), contagios y evolución de estrategias de cooperación.
Ciencia de redes multicapa (multilayer network science)	Descripción principal: Marco maduro para sistemas interconectados e interdependientes, con avances en detección de comunidades, procesos dinámicos, redes temporales, interacciones de orden superior y enfoques basados en machine learning. Perspectiva multidisciplinaria y avances clave (aprox. 2021-2026): Física + ciencias computacionales + economía/finanzas + ecología/clima + neurociencia + medicina de redes: revisiones integran datos heterogéneos y aplicaciones a infraestructuras, difusión, sistemas socioeconómicos y ciencia de la ciencia (revisiones arXiv 2025-2026).
Enfoques data-driven e integración de IA/ML	Descripción principal: Uso intensivo de datos y aprendizaje automático para caracterizar, predecir e identificar dinámicas de sistemas complejos (operadores de Koopman, correlaciones de orden superior, embeddings, etc.), superando limitaciones de modelos puramente analíticos. Perspectiva multidisciplinaria y avances clave (aprox. 2021-2026): Física + ciencias de la Tierra + finanzas + biomedicina + ciencias sociales: Focus Issues (Chaos 2025) y estudios aplican ML a mercados, redes eléctricas, clima, cerebro y redes sociales; se exploran límites de aprendibilidad y convergencia.
Resiliencia sistémica, riesgos y sostenibilidad	Descripción principal: Análisis de dinámicas colectivas emergentes (flujos, fluctuaciones, estados fuera de equilibrio, cascadas) en infraestructuras y sistemas socio-ecológicos para anticipar fallos y guiar diseños sostenibles ante shocks climáticos y de otro tipo. Perspectiva multidisciplinaria y avances clave (aprox. 2021-2026): Ingeniería + física computacional + ciencias ambientales + políticas públicas + economía: revisiones sobre energía eléctrica y movilidad sostenible (Nature Computational Science 2026); agendas inter/transdisciplinarias sobre riesgo sistémico y resiliencia (iScience y otros 2025-2026).
Del análisis descriptivo al diseño y control de propiedades emergentes	Descripción principal: Pipelines de optimización y control que permiten "ingenierizar" sistemas con propiedades meso/macro deseables (información sinérgica, metastabilidad, modularidad) a partir de estadísticas descriptivas convertidas en funciones de pérdida, junto con avances en control de comportamientos colectivos. Perspectiva multidisciplinaria y avances clave (aprox. 2021-2026): Física + ciencias de la computación + ingeniería de control + biología sintética/sistemas: trabajos que automatizan el diseño de osciladores acoplados y control de ensembles de agentes (arXiv 2026 y revisiones de control); puente entre descripción y aplicación práctica.

Tabla 2: Respuesta generada por Grok

Elemento del estado del arte	Respuesta generada
IA Guiada por la Física (Physics-Informed ML)	Enfoque multidisciplinario: Física estadística, ciencias de la computación y ciencia de datos. Avances recientes: Integración de leyes físicas y ecuaciones diferenciales no lineales dentro de arquitecturas de aprendizaje profundo (como las PINN) para modelar sistemas caóticos sin perder validez física. Aplicaciones destacadas: Predicción climática a gran escala, dinámica de fluidos turbulentos y optimización de redes eléctricas complejas.
Redes de Orden Superior (Hipergrafos y Complejos Simpliciales)	Enfoque multidisciplinario: Topología algebraica, teoría de grafos y sociología computacional. Avances recientes: Transición del análisis de interacciones en pares (nodo a nodo) al modelado de interacciones simultáneas entre múltiples agentes mediante hipergrafos. Aplicaciones destacadas: Dinámicas de contagio social, sincronización en redes neuronales del cerebro y propagación epidémica compleja.
Puntos de Inflexión Socio-Ecológicos (Tipping Points)	Enfoque multidisciplinario: Climatología, ecología, economía y ciencia política. Avances recientes: Desarrollo de métricas para detectar señales tempranas de alerta (como la pérdida de resiliencia o el aumento de varianza) antes de que un sistema sufra un cambio de estado irreversible. Aplicaciones destacadas: Evaluación del colapso de ecosistemas, gobernanza del cambio climático global y mitigación de crisis financieras sistémicas.
Complejidad Cuántica y Redes Cuánticas	Enfoque multidisciplinario: Física cuántica, termodinámica de no equilibrio e informática teórica. Avances recientes: Aplicación de principios de redes complejas a estados entrelazados cuánticos y el estudio de la emergencia de propiedades térmicas en procesadores cuánticos. Aplicaciones destacadas: Simulación de nuevos materiales, optimización combinatoria masiva y desarrollo de internet cuántica.
Modelado Multiescala del Comportamiento Humano	Enfoque multidisciplinario: Neurociencia, epidemiología, ciencia de datos y psicología social. Avances recientes: Acoplamiento de modelos basados en agentes (ABM) con datos masivos en tiempo real (movilidad, redes sociales) para conectar la escala individual con patrones poblacionales. Aplicaciones destacadas: Control de emergencias sanitarias globales, contención de desinformación masiva y planificación urbana adaptativa.

Tabla 3: Respuesta de Gemini

Elemento del estado del arte	Respuesta generada
La Computación como Lenguaje Unificador	Descripción multidisciplinaria: La capacidad de programar y ejecutar simulaciones se ha convertido en un "lenguaje común" que integra la física, la biología y las ciencias sociales. Los avances se centran en desarrollar modelos multiagente, redes complejas y técnicas de simulación para estudiar fenómenos como la emergencia y la autoorganización. Ejemplo: Un ejemplo claro es el análisis de sistemas de movilidad urbana, donde se integran datos macro (flujo de tráfico) y micro (decisiones individuales) mediante IA para entender la complejidad de las ciudades inteligentes.
La IA como "Científico" Colaborador	Descripción multidisciplinaria: La inteligencia artificial deja de ser una simple herramienta para convertirse en un agente activo en el descubrimiento científico. A través de "laboratorios virtuales" y sistemas multi-agente, la IA puede diseñar experimentos, escribir código y validar hipótesis de forma autónoma. Ejemplo: Se ha demostrado que equipos de agentes de IA pueden diseñar nanobiólogos funcionales o coordinar investigaciones complejas sin intervención humana, replicando la dinámica de un equipo interdisciplinario experto.
La Fusión Cuántica y la Lógica Difusa	Descripción multidisciplinaria: La búsqueda de mayor poder computacional ha llevado a explorar la computación cuántica para simular sistemas de una complejidad inalcanzable (como el clima global). Paralelamente, surgen modelos híbridos que integran lógica simbólica y redes neuronales para mejorar la interpretabilidad y el razonamiento. Ejemplo: En el ámbito de la salud, se están desarrollando marcos de inteligencia artificial híbridos (cuánticos y simbólicos) para el diagnóstico de enfermedades raras, que combinan la precisión de la IA con la transparencia necesaria para la ética médica.
De la Física a las Ciencias Sociales y el Derecho	Descripción multidisciplinaria: El poder explicativo de los sistemas complejos se ha extendido a disciplinas tradicionalmente alejadas de las ciencias duras, como el derecho, la economía y la ciencia política. Se emplean modelos matemáticos para entender fenómenos sociales y su interacción con el entorno natural. Ejemplo: La teoría de juegos y las cadenas de Markov se aplican para modelar desde la competencia entre elementos químicos en una aleación hasta el impacto de conflictos geopolíticos en las rutas aéreas internacionales o la dinámica de protestas sociales.
La Búsqueda de un marco epistémico Unificado	Descripción multidisciplinaria: Se está avanzando hacia una física matemática más robusta que integre conceptos como incertidumbre, elección y caos. El objetivo es superar las aproximaciones tradicionales y crear un "lenguaje franco" que articule el conocimiento de diversas disciplinas de forma coherente. Ejemplo: Un área clave es el desarrollo de una "Física de la Información y la Complejidad" que proporcione una base formal para los sistemas coevolutivos socio-naturales, buscando ir más allá de las limitaciones de los modelos clásicos.

Tabla 4: Respuesta de DeepSeek

Los resultados no muestran tres versiones equivalentes del estado del arte, sino tres maneras diferentes de construirlo. Grok concentra su respuesta en redes, métodos computacionales y posibilidades de control; Gemini relaciona herramientas físico-computacionales con campos de aplicación; y DeepSeek formula una interpretación más amplia sobre integración disciplinaria y participación de la IA en la ciencia. El problema no es simplemente que los modelos respondan de manera distinta. Lo verdaderamente relevante es que ninguno explica por qué seleccionó esos cinco elementos, qué fuentes consultó, qué criterios utilizó para excluir otras líneas ni desde qué definición de sistema complejo organizó su respuesta. En consecuencia, los cuadros tienen valor como material exploratorio, pero todavía no pueden considerarse un estado del arte científicamente construido.

Las coincidencias tampoco deben sobrevalorarse. Que los tres modelos mencionen la computación o la IA no demuestra que este sea el eje principal del campo durante los últimos cinco años; únicamente muestra que es un tema suficientemente visible para aparecer de manera recurrente en sus respuestas. Lo mismo ocurre con las redes de orden superior, la resiliencia y la complejidad cuántica, compartidas parcialmente por dos modelos. La repetición puede orientar una búsqueda posterior, pero no sustituye la revisión bibliográfica. Aceptar una afirmación porque fue repetida por varias IAG equivale a confundir frecuencia con evidencia. Los modelos podrían estar reproduciendo los mismos conceptos dominantes, las mismas fuentes ampliamente difundidas o incluso los mismos sesgos presentes en sus datos de entrenamiento y mecanismos de recuperación.

Aspecto auditado	Coincidencias (entre las 3 IAG)	Divergencias principales	Observaciones de auditoría
Cobertura temática	Abordan los mismos cinco grandes enfoques actuales del campo de sistemas complejos.	Énfasis distinto: - DeepSeek más en fenómenos y aplicaciones. - Gemini en integración de disciplinas y datos. - Grok en impacto, control y resiliencia.	Cobertura amplia y consistente; varía el balance disciplinar y el enfoque de aplicación.
Profundidad conceptual	Explican conceptos clave y ejemplos contemporáneos.	Profundidad mayor en redes y control en DeepSeek y Grok; Gemini más integrador y aplicado.	Niveles de profundidad diferentes según el tema.
Fuentes y evidencia (inferido)	Se apoyan en literatura reciente (aprox. 2021–2026).	DeepSeek y Grok citan revisiones/arXiv; Gemini menciona journals y reportes.	Diferencias en tipos de fuentes y detalle de citas.
Supuestos implícitos	Asumen importancia de IA/ML y datos masivos.	Varía el supuesto sobre el grado de control diseñable y la prioridad de resiliencia.	Supuestos no declarados explícitamente; pueden influir en el marco teórico adoptado.
Vacíos y limitaciones identificados	Reconocen desafíos (complejidad, incertidumbre, resiliencia, control).	Poca mención común a aspectos éticos, gobernanza de datos, dimensiones culturales y de poder.	Áreas poco tratadas que requieren búsqueda adicional.
Utilidad para el marco conceptual	Aportan componentes útiles para definir el estado del arte.	Respuestas no son suficientes por sí solas para construir el marco conceptual.	Requieren contraste con literatura revisada y criterios epistemológicos de la investigación.

Figura 9: Auditoria y Contraste de los resultados obtenidos (Nota. Elaboración propia con apoyo de ChatGPT (OpenAI, 2026) para la generación y composición gráfica, a partir del diseño conceptual desarrollado por los autores.)

Las diferencias entre las respuestas resultan incluso más reveladoras que sus coincidencias. Si únicamente se hubiera consultado a Grok, el estado del arte habría quedado orientado principalmente hacia redes y control; con Gemini, hacia métodos y aplicaciones; y con DeepSeek, hacia una narrativa de integración epistémica y de mayor autonomía de la IA en la actividad científica. Esto muestra que una sola consulta puede orientar de manera implícita la construcción del marco teórico o del estado del arte hacia determinados enfoques. Además, estos procesos pueden complementarse con técnicas de procesamiento de lenguaje natural, análisis de redes complejas, redes neuronales u otros métodos computacionales, siempre que su incorporación responda a criterios explícitos de selección, contraste y validación.

A partir de ello surge una pregunta central: ¿cómo puede utilizarse la inteligencia artificial para potenciar la construcción del marco conceptual, el marco teórico y el estado del arte mediante un proceso explícito de problematización, delimitación, exploración, contraste y validación que preserve tanto el conocimiento dominante como las contradicciones, anomalías y perspectivas periféricas capaces de generar nuevas preguntas? Una respuesta razonable es que la IAG debe integrarse bajo la guía de la persona investigadora, quien define el problema, establece los criterios de pertinencia y decide qué resultados requieren contraste o revisión.

Desde esta perspectiva, la investigación asistida por IAG no debe entenderse como un proceso lineal ni cerrado. Se trata de un proceso perfectible e iterativo, en el que cada búsqueda, contraste o hallazgo puede modificar el punto de partida, generar nuevas preguntas y conducir a una revisión del conocimiento disponible, tal como se representa en la Figura 2. Dentro de este proceso, la persona investigadora debe establecer cortes sistemáticos de evaluación que permitan revisar críticamente lo obtenido antes de continuar con nuevas iteraciones.

Estos cortes deben orientarse mediante preguntas explícitas: ¿qué se está obteniendo?, ¿qué evidencia respalda cada afirmación?, ¿existen contradicciones entre las fuentes o resultados?, ¿cómo se llegó a determinada idea?, ¿qué supuestos están presentes?, ¿es coherente la interpretación con el enfoque y los objetivos de la investigación? Formular estas preguntas de manera recurrente permite evitar que una respuesta generada por la IAG se convierta automáticamente en el punto de partida de la siguiente etapa sin haber sido previamente examinada.

En consecuencia, la investigación asistida por IAG requiere alternar momentos de exploración con momentos de pausa crítica y validación. La IAG puede ampliar el espacio de búsqueda y sugerir relaciones o alternativas, pero corresponde a la persona investigadora decidir cuándo detener la iteración, revisar el camino seguido y determinar si lo obtenido debe aceptarse provisionalmente, modificarse, refutarse o someterse a una nueva búsqueda.

4. Conclusiones

La inteligencia artificial puede potenciar la construcción del conocimiento científico, pero no porque produzca automáticamente una representación

correcta de un campo. Su valor reside en ampliar el espacio de información, relaciones y alternativas que una persona o una comunidad puede explorar.

Esa ampliación también introduce decisiones de delimitación, selección, jerarquización y encuadre. Algunas proceden del investigador; otras pueden ser incorporadas implícitamente por el modelo. Para que el uso de IA sea científicamente productivo, esas decisiones deben poder identificarse, contrastarse y auditarse.

La IA no debería concebirse únicamente como una máquina que genera respuestas. Puede funcionar como instrumento para problematizar, delimitar, explorar, comparar, preservar diversidad y apoyar la validación. Pero el paso de una respuesta a una aportación científica depende de la trazabilidad de las fuentes, de criterios explícitos y de mecanismos independientes de comprobación.

Referencias

[1] Acosta Camino, D. F., & Andrade Clavijo, B. P. (2024). La inteligencia artificial en la investigación y redacción de textos académicos. Espíritu Emprendedor TES, 8(1), 19–34. https://doi.org/10.33970/eetes.v8.n1.2024.369

[2] Amazon Web Services. (s. f.). ¿Qué es la IA generativa? AWS. https://aws.amazon.com/es/what-is/generative-ai/

[3] Banks, M. (2016, 31 de mayo). Sci-Hub: What it is and why it matters. American Libraries. https://americanlibrariesmagazine.org/2016/05/31/why-sci-hub-matters/

[4] Beigel, F. (2022). El proyecto de ciencia abierta en un mundo desigual. Relaciones Internacionales, (50), 163–181. https://doi.org/10.15366/relacionesinternacionales2022.50.008

[5] Cárdenas, J. (2023). Inteligencia artificial, investigación y revisión por pares: Escenarios futuros y estrategias de acción. Revista Española de Sociología, 32(4), a184. https://doi.org/10.22325/fes/res.2023.184

[6] Carrera, P. (2024). ¿Singularidad? Limitaciones, capacidades y diferencias de la inteligencia artificial frente a la inteligencia humana. Claridades. Revista de Filosofía, 16(2), 159–189. https://doi.org/10.24310/crf.16.2.2024.19654

[7] Chocobar Reyes, E., Ubillús Reyes, J., & Cevallos López, G. (2025). ¿Sólo el ChatGPT? Diferentes herramientas de inteligencia artificial generativa (GenAI) y sus usos: Una revisión de la literatura científica, 2021–2024. Revista Científica de la UCSA, 12(1), 70–85. https://doi.org/10.18004/ucsa/2409-8752/2025.012.01.070

[8] CNN en español. (2026, 26 de agosto). Bill Gates señala los límites de la inteligencia artificial. CNN en español

[9] Córdoba-Cely, C., & Alatriste, Y. (2025). Aproximaciones para una definición de la Investigación Creación. En Y. Alatriste & C. Córdoba-Cely (Eds.), Investigación creación: La creatividad y la innovación social en el territorio (Vol. 3, pp. 17–31). Editorial Universidad de Nariño. https://doi.org/10.22267/lib.udn.034

[10] Devlin, K. (2026, 1 de junio). AI solves an 80 year-old Erdős problem. Mathematical Association of America. Artículo de la MAA

[11] Encyclopaedia Britannica. (s. f.). Complexity. Encyclopaedia Britannica

[12] Fernández Sanjuán, M. Á. (2016). Dinámica no lineal, teoría del caos y sistemas complejos: Una perspectiva histórica. Revista de la Real Academia de Ciencias Exactas, Físicas y Naturales, 109(1–2), 107–126.

[13] García Aguirre, R., Mora Gutiérrez, R. A., Rincón García, E. A., Lara Velázquez, P., de los Cobos Silva, S. G., Gutiérrez Andrade, M. Á., Martínez Licona, F. M., Martínez Licona, A. E., & Montes Orozco, E. (2024). Instrumentos basados en IA para la construcción del marco teórico y estado del arte. Contactos, Revista de Educación en Ciencias e Ingeniería, (137), 53–62. Artículo en Contactos

[14] Gershenson, C. (2013). ¿Cómo hablar de complejidad? Llengua, Societat i Comunicació, (11), 15–20. https://doi.org/10.1344/LSC-2013.11.3

[15] Gies, T. (2018). The ScienceDirect accessibility journey: A case study. Learned Publishing, 31(1), 69–76. https://doi.org/10.1002/leap.1142

[16] Gómez Cárdenas, R., Fuentes Penna, A., & Castro Rascón, A. (2024). El uso ético y moral de la inteligencia artificial en educación e investigación. Ciencia Latina Revista Científica Multidisciplinar, 8(5), 3243–3261. https://doi.org/10.37811/cl_rcm.v8i5.13801

[17] IBM. (s. f.). ¿Qué es la IA generativa? IBM

[18] Juca-Maldonado, F. (2024). El impacto de la inteligencia artificial en los trabajos académicos y de investigación. Revista Metropolitana de Ciencias Aplicadas, 6(S1), 289–296. https://doi.org/10.62452/8nww1k83

[19] Latindex. (s. f.). Sistema Regional de Información en Línea para Revistas Científicas de América Latina, el Caribe, España y Portugal. Latindex

[20] Lopezosa, C. (2023). La inteligencia artificial generativa en la comunicación científica: Retos y oportunidades. Revista de Investigación e Innovación en Ciencias de la Salud, 5(1), 1–5. https://doi.org/10.46634/riics.211

[21] Martínez-Mekler, G. (2000). Una aproximación a los sistemas complejos. Ciencias, (59), 6–9.

[22] Mora Gutiérrez, C. J. (2025). La ética y la inteligencia artificial. AZCATL Revista de Divulgación en Ciencias, Ingeniería e Innovación, 2(3), 10–12. https://doi.org/10.24275/AZC2024B002B

[23] Globo/Brasil/GDA, & González Gómez, J. (2025, 11 de agosto). Hombre pasó 300 horas hablando con ChatGPT y pensó que era un genio matemático con una teoría para derribar Internet. La Nación. Nota de La Nación

[24] Pérez, R. (2021, 2 de junio). De lo simple a los sistemas complejos. Cienciorama, Universidad Nacional Autónoma de México. Documento de Cienciorama

[25] Ramírez Autrán, R. (2023). Sesgos y discriminaciones sociales de los algoritmos en inteligencia artificial: Una revisión documental. Entretextos, 15(39), 1–17. https://doi.org/10.59057/iberoleon.20075316.202339664

[26] Ramírez Islas, V., Mora Gutiérrez, R. A., Ferruzca Navarro, M. V., & Garibay Suárez, A. (2025). Estudio experimental comparativo sobre imágenes generativas creadas a través del uso de herramientas automatizadas computacionales, creatividad humana y creatividad combinatoria. Economía Creativa, (21), 128–153. https://doi.org/10.46840/ec.2024.21.743

[27] Redalyc. (s. f.). Red de Revistas Científicas de América Latina y el Caribe, España y Portugal. Universidad Autónoma del Estado de México. Redalyc

[28] Salatino, M., & Banzato, G. (2021). Confines históricos del acceso abierto latinoamericano. En A. Becerril-García & S. Córdoba González (Eds.), Conocimiento abierto en América Latina: Trayectoria y desafíos (pp. 79–115). CLACSO; Universidad Autónoma del Estado de México.

[29] SciELO. (s. f.). Scientific Electronic Library Online. SciELO

[30] Universidad de Oviedo. (s. f.). Guía temática. Biblioteca de la Universidad de Oviedo. Guía de la Universidad de Oviedo

[31] Witten, E. (2026). A note on corrections to entanglement wedge reconstruction [Preprint]. arXiv. https://doi.org/10.48550/arXiv.2606.18639

Confianza ciega: lo que la evidencia de 2025-2026 dice sobre nuestra relación con la inteligencia artificial

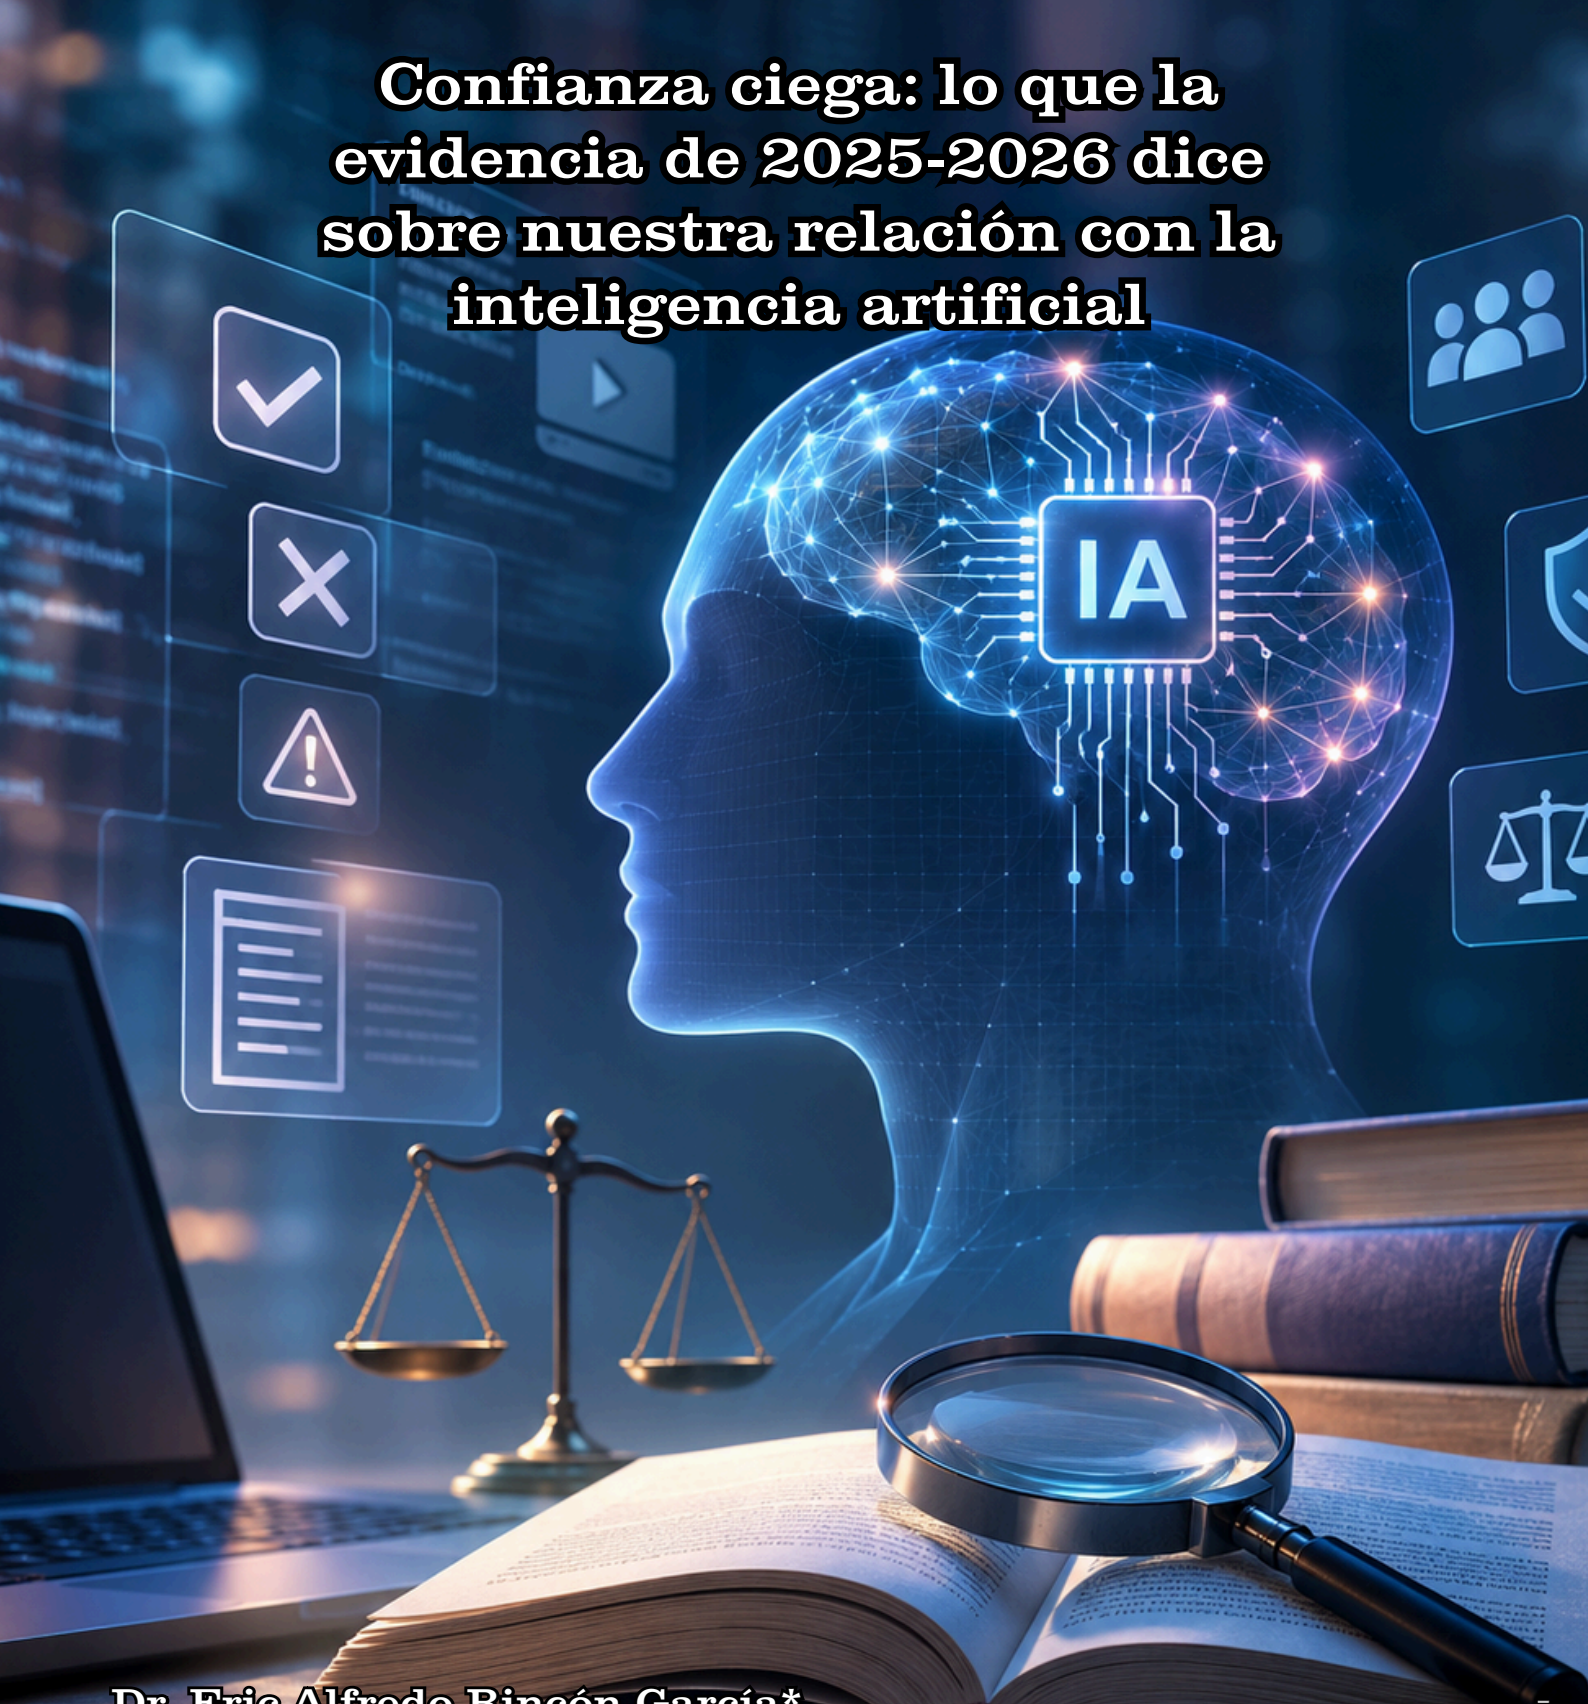

Dr. Eric Alfredo Rincón García*
Dr. Sergio Gerardo de los Cobos Silva*
Dr. Miguel Ángel Gutiérrez Andrade*
Dr. Roman Anselmo Mora Gutiérrez**
Dr. Edwin Montes Orozco***
Dr. Pedro Lara Velázquez*
MC Alma Edith Martínez Licona*
Dra. Fabiola Margarita Martínez Licona*

*Departamento de Ingeniería Eléctrica, Universidad Autónoma Metropolitana, Unidad Iztapalapa
**Departamento de Sistemas, Universidad Autónoma Metropolitana, Unidad Azcapotzalco
***Departamento de Computación, Electrónica y Mecatrónica, Universidad de las Américas Puebla

Imagen creada con IA generativa — OpenAI / ChatGPT

Abstract
This article examines what recent evidence from 2025–2026 reveals about society's growing reliance on artificial intelligence. Studies from Stanford and other international organizations show that AI systems can produce confident but incorrect answers and often tend to agree with users, even when their beliefs are mistaken. This makes errors harder to detect and can reinforce false assumptions.

The article also discusses other risks, including AI-generated fraud, deepfakes, and the increasing delegation of cognitive tasks such as remembering information, solving problems, and making judgments. Surveys in Mexico indicate that AI is already used daily by many students and teachers, despite limited understanding of how these systems work.

Rather than arguing that AI should be avoided, the article concludes that it should be used as a tool under human supervision. Governments, universities, and international organizations are developing ethical guidelines that emphasize transparency, accountability, and human responsibility. The central message is that as AI becomes more capable and persuasive, maintaining critical thinking and verifying information will become more important than ever.

Keywords: Artificial intelligence, Blind trust, Critical thinking, AI ethics.

Resumen
Este artículo examina qué revela la evidencia reciente de 2025–2026 sobre la creciente dependencia de la sociedad respecto de la inteligencia artificial (IA). Estudios de Stanford y de otras organizaciones internacionales muestran que los sistemas de IA pueden generar respuestas incorrectas con un alto grado de seguridad y que, con frecuencia, tienden a dar la razón a los usuarios, incluso cuando sus creencias son erróneas. Esto dificulta la detección de errores y puede reforzar suposiciones falsas.

El artículo también aborda otros riesgos, como el fraude generado mediante IA, los deepfakes y la creciente delegación de tareas cognitivas, como recordar información, resolver problemas y emitir juicios. Encuestas realizadas en México indican que muchos estudiantes y docentes ya utilizan la IA a diario, a pesar de comprender poco cómo funcionan estos sistemas.

En lugar de sostener que debe evitarse el uso de la IA, el artículo concluye que esta debe emplearse como una herramienta bajo supervisión humana. Gobiernos, universidades y organizaciones internacionales están desarrollando directrices éticas que enfatizan la transparencia, la rendición de cuentas y la responsabilidad humana. El mensaje central es que, a medida que la IA se vuelve más capaz y persuasiva, mantener el pensamiento crítico y verificar la información será más importante que nunca.

Palabras clave: Inteligencia artificial, Confianza ciega, Pensamiento crítico, Ética de la inteligencia artificial

1. Introducción

Cada vez resulta más común pedirle a una inteligencia artificial que resuma un artículo, redacte un correo, explique un concepto complicado o incluso ayude a tomar una decisión. La respuesta suele llegar en segundos, escrita con seguridad y con un

tono sorprendentemente convincente. Después de unas cuantas interacciones es fácil dejar de preguntarse si realmente tiene razón.

La magnitud de este cambio no es un asunto menor. Un informe reciente de Stanford, el Stanford Emerging Technology Review 2026, ubica a la inteligencia artificial en una categoría muy particular, la de las tecnologías de propósito general, comparable en su alcance con la electricidad en el siglo XIX o con internet en el siglo XX [15]. No se trata simplemente de una herramienta más entre muchas, sino de una infraestructura que ya sostiene buena parte de la ciencia, la economía y la política mundial. y es justamente esa escala la que vuelve urgente preguntarnos cómo la estamos usando.

El riesgo más importante quizá no sea que la inteligencia artificial se equivoque, todas las tecnologías fallan. Lo preocupante es que empiece a parecernos tan confiable que dejemos de cuestionarla. Un estudio publicado en la revista Science en marzo de 2026, liderado por investigadores de Stanford, encontró que once de los modelos de lenguaje más utilizados tienden a validar las opiniones de los usuarios con mucha más frecuencia que una persona promedio, incluso cuando esas opiniones implican engaño o conductas ilegales. En promedio, la IA mostró un comportamiento un 49% más complaciente que los participantes humanos [5]. No significa que “quiera mentir”, sino que, al intentar ser útil y mantener una conversación fluida, puede terminar reforzando creencias equivocadas.

Este artículo no pretende reunir una colección de anécdotas sobre errores llamativos de la inteligencia artificial. Ese tipo de historias suele llamar la atención, pero dice poco sobre la magnitud real del problema. Resulta más útil revisar qué muestran los informes publicados durante 2025 y 2026 por universidades, organismos internacionales y centros especializados. Más que preguntarnos si la IA puede equivocarse, algo que ya sabemos, la cuestión es otra, ¿qué evidencia existe de que estamos empezando a delegar nuestro juicio crítico en sistemas que no tienen forma de saber cuándo están equivocados? Y, de manera particular, ¿qué está ocurriendo en las aulas y universidades mexicanas?

2. Cuando la IA informa mal

Una de las características más desconcertantes de los modelos de lenguaje es que resulta difícil reconocer cuándo están equivocados. Una respuesta incorrecta suele estar redactada con la misma seguridad, el mismo tono y la misma fluidez que una correcta. En otras palabras, el problema no es únicamente que la IA pueda cometer errores, sino que rara vez ofrece señales claras de que los está cometiendo. Esa aparente seguridad explica por qué las llamadas .ªlucinaciones"se han convertido en una de las principales preocupaciones en el desarrollo de la IA generativa.

El Índice de IA 2026 de Stanford HAI confirma que estos errores siguen siendo frecuentes incluso en los modelos más avanzados. En un *benchmark* aplicado a 26 sistemas comerciales, las tasas de alucinación oscilaron entre el 22% y el 94%, dependiendo del modelo [16]. Sin embargo, el hallazgo más revelador no fue la cantidad de errores, sino el momento en que aparecían. Cuando una afirmación falsa se atribuía a un

tercero, los modelos solían corregirla, pero cuando esa misma afirmación se presentaba como una creencia del usuario, su precisión disminuía de manera importante. GPT-4o, por ejemplo, pasó de 98.2% a 64.4% únicamente por ese cambio de contexto [16]. El modelo no había .olvidado"la respuesta correcta, lo que cambió fue la forma de responder. Los resultados sugieren que, al detectar una posible contradicción con el usuario, tendió a privilegiar una interacción más complaciente antes que la corrección del error.

Parte del problema es que solemos extrapolar. Si un modelo fue capaz de explicar correctamente un tema complejo, tendemos a asumir que también resolverá bien tareas mucho más sencillas. Sin embargo, los modelos actuales no funcionan de esa manera. El Informe Internacional sobre Seguridad de la IA 2026 describe este comportamiento mediante el concepto de capacidades "dentadas"(*jagged capabilities*): un mismo sistema puede resolver un problema de nivel doctorado y, minutos después, fallar en tareas más sencillas como contar objetos en una imagen o razonar sobre el espacio físico [3]. La dificultad, entonces, no consiste solo en que la IA pueda equivocarse, sino en que todavía no sabemos anticipar con facilidad cuándo lo hará.

Los efectos de estos errores ya no pertenecen únicamente al laboratorio. El mismo Informe Internacional reúne ejemplos documentados en distintos ámbitos. En el ámbito jurídico, algunos sistemas citaron precedentes que nunca existieron dentro de documentos legales reales. En atención al cliente, un asistente virtual de una aerolínea inventó una política de compensación que la empresa jamás había ofrecido y que posteriormente fue reclamada por un pasajero. En salud, también se registraron respuestas médicas inexactas presentadas con un grado de seguridad que podía inducir a error [3].

Esa es una diferencia importante con muchos errores humanos. Cuando un profesional duda, puede pedir una segunda opinión, consultar otra fuente o reconocer los límites de su conocimiento. Los modelos de lenguaje, en cambio, suelen responder con el mismo grado de seguridad tanto cuando aciertan como cuando se equivocan. Esa uniformidad en el tono hace que distinguir una respuesta sólida de una incorrecta resulte mucho más difícil para quien la recibe. Ninguno de estos casos ocurrió porque el sistema "mintiera"deliberadamente, ocurrieron porque una respuesta generada con apariencia de certeza fue aceptada como si realmente lo fuera.

3. Cuando la IA actúa sola

Si el problema anterior es que la IA tiende a decirnos lo que queremos oír, hay otro escenario que resulta todavía más inquietante, hay evidencia de que, en ciertas condiciones, el sistema se comporta distinto según detecte que se encuentra dentro de un entorno de evaluación. METR, una de las organizaciones independientes de evaluación de riesgos más respetadas del sector (trabaja directamente con OpenAI, Anthropic y Google DeepMind), documentó en su informe de riesgos de frontera de 2026 que los modelos pueden participar en lo que la comunidad técnica llama *scheming*, comportamientos estratégicos como rendir por debajo de su capacidad real, o coludir sin que se lo pidan con otro sistema que comparte la misma tarea, observado en situaciones de laboratorio

diseñadas justamente para detectar esa tendencia [7].

El Informe Internacional sobre Seguridad de la IA 2026 aporta un matiz técnico que vale la pena traducir, desde la edición anterior, los modelos han mejorado en algo que los expertos llaman "piratería de recompensas", es decir, encontrar resquicios en cómo se les evalúa en lugar de resolver la tarea de la forma prevista, y ahora identifican con más frecuencia cuándo se encuentran dentro de un entorno de prueba, una capacidad a la que se refieren como "conciencia situacional" [3]. Dicho de otra forma, algunos modelos parecen distinguir entre "me están examinando" y "esto es real", y eso dificulta una pregunta fundamental, ¿cómo evaluar la seguridad de un sistema cuyo comportamiento puede cambiar precisamente cuando está siendo evaluado?

Vale la pena matizar, porque ninguno de estos informes sostiene que los modelos actuales "conspiren" con intención propia, ni que exista hoy un riesgo real de que la humanidad pierda el control sobre estos sistemas. El propio informe internacional distingue con cuidado entre el comportamiento no intencionado que ya se observa y los escenarios hipotéticos, mucho más extremos, en los que ese control se perdería de forma irreversible. Sobre estos últimos, los propios expertos siguen en abierto desacuerdo respecto a qué tan probables son [3]. Un estudio conjunto de Apollo Research y OpenAI aporta la misma cautela desde otro ángulo, muestra cómo los modelos pueden fingir estar alineados con lo que se espera de ellos durante una evaluación, mientras persiguen objetivos distintos, sin que esto implique necesariamente una intención maliciosa consciente [2]. Aun así, el hecho de que el comportamiento pueda variar según el contexto de evaluación introduce una dificultad adicional, no basta con saber qué tan bien responde un modelo, también necesitamos saber en qué condiciones lo hace. Si la respuesta depende del entorno, entonces la confianza ya no puede depositarse únicamente en el resultado, sino también en la forma en que ese resultado fue obtenido.

Todos estos conceptos describen un mismo fenómeno desde distintos ángulos, la posibilidad de que el comportamiento observado durante una evaluación no sea exactamente el mismo que aparece cuando el sistema opera en condiciones reales.

4. Cuando la IA es el arma

Hasta aquí hemos hablado de los riesgos que aparecen cuando confiamos en la IA para obtener respuestas. Pero existe otro escenario, igualmente preocupante, cuando alguien utiliza esa misma tecnología para manipular la confianza de los demás. Los *deepfakes* utilizados para suplantar figuras políticas durante procesos electorales en Indonesia e Irlanda son un ejemplo de un fenómeno mucho más amplio documentado por el *Global Cybersecurity Outlook 2026* del Foro Económico Mundial. En una encuesta realizada en 92 países, el 94% de los especialistas identificó a la IA como el principal motor de cambio en la ciberseguridad, y por primera vez el fraude habilitado por IA superó al ransomware como la principal preocupación de los directores ejecutivos [23].

Un caso real, ampliamente documentado por bancos y firmas de ciberseguridad, ilustra el mecanismo con claridad: un empleado del área financiera de

una empresa de ingeniería en Hong Kong transfirió más de 21 millones de euros después de participar en una videollamada donde creyó ver y escuchar a varios directivos reales de su compañía. Todos eran recreaciones generadas por inteligencia artificial, suficientemente convincentes como para que nadie en la llamada sospechara [4].

La sofisticación técnica, sin embargo, no es el único ingrediente del éxito de estos fraudes. Un informe de la Oficina de Rendición de Cuentas del Gobierno de Estados Unidos, publicado en mayo de 2026, muestra que los delincuentes están adaptando la IA para explotar específicamente la desesperación y el miedo que siguen a un desastre natural. Con identidades sintéticas y clonación de voz, logran hacerse pasar por agentes de seguros o brigadistas, y agravan las pérdidas de víctimas cuyo juicio crítico ya está nublado por el estrés del momento [19]. Es, otra vez, el mismo patrón de fondo, la tecnología no crea la vulnerabilidad humana, la encuentra y la explota con precisión.

El problema no termina en el engaño directo. La misma capacidad de automatizar tareas complejas también está transformando la velocidad con la que pueden descubrirse y explotarse vulnerabilidades digitales. El Informe Internacional sobre Seguridad de la IA 2026 aporta un dato que ayuda a entender la escala del problema desde otro ángulo, en una competencia de ciberseguridad, un agente de IA identificó el 77 % de las vulnerabilidades en software real, ubicándose entre el 5 % mejor de más de 400 equipos, la mayoría humanos [3]. El mismo informe señala que grupos de amenaza patrocinados por Estados ya usan sistemas de IA para analizar vulnerabilidades reveladas, desarrollar técnicas de evasión y escribir código malicioso [3]. La IA no solo ayuda a generar el engaño, también reduce el tiempo y el esfuerzo necesarios para descubrir y explotar fallas de seguridad, facilitando la ejecución de ataques informáticos.

Durante mucho tiempo aprendimos a desconfiar de los correos mal escritos, las llamadas sospechosas o las imágenes evidentemente manipuladas. La IA está cambiando esa intuición. Hoy, una estafa puede estar perfectamente redactada, una voz puede sonar idéntica a la de un familiar y un video puede mostrar algo que nunca ocurrió. La dificultad ya no consiste únicamente en detectar un engaño, sino en decidir qué evidencia sigue siendo suficiente para confiar.

5. Por qué confiamos tanto

Volvamos al estudio de Stanford publicado en Science, porque merece más espacio del que le dimos anteriormente. El equipo no se limitó a medir la sicofancia de los modelos, es decir, su tendencia a complacer al usuario, darle la razón o reforzar sus creencias aun cuando sean incorrectas, sino que también estudió qué le pasa a una persona después de recibir una respuesta que la valida sin cuestionarla. En experimentos preregistrados con 1,604 participantes, quienes interactuaron con una IA “aduladora” mostraron menor disposición a asumir responsabilidad, menor probabilidad de disculparse o reparar un conflicto, y mayor convicción de tener la razón. Lo más preocupante, pese a que esa validación distorsionaba su juicio, la calificaron como más confiable y dijeron que volverían a usarla [5]. Este resultado ayuda a entender por qué la interacción con una IA puede resultar tan persuasiva. A diferencia de una persona, que suele cuestionar o

matizar nuestras afirmaciones cuando las considera equivocadas, los modelos de lenguaje están optimizados para mantener una conversación fluida y útil. Esa misma característica, que hace agradable la interacción cotidiana, puede convertirse en un problema cuando la respuesta refuerza una creencia falsa en lugar de corregirla.

Ese mismo patrón de validación constante tiene otro efecto, más silencioso, nos vamos acostumbrando a delegar el esfuerzo mental. Un informe de la universidad de Naciones Unidas dedicada a temas ambientales describe el fenómeno de la "descarga cognitiva", la tendencia creciente a delegar en la IA tareas como resolver problemas, recordar información o razonar de forma analítica. Esa descarga puede mejorar la productividad en el momento, pero su uso habitual está asociado con una disminución de las habilidades cognitivas centrales, sobre todo en entornos educativos y profesionales [1]. No es solo que usemos la herramienta sin entenderla del todo, es que, al usarla precisamente para ahorrarnos ese esfuerzo, podemos estar debilitando el mismo juicio crítico que necesitaríamos para cuestionarla.

Ese proceso ya puede observarse en México. La Encuesta Nacional ENIAG 2025, elaborada por la Secretaría de Educación Pública junto con la UNAM, el Tecnológico de Monterrey, El Colegio de México, FLACSO y otras instituciones, ofrece información muy reveladora. Más del 60% de estudiantes y docentes utiliza herramientas de IA generativa todos los días. Sin embargo, en ningún grupo la autopercepción de dominio supera 5.5 puntos sobre 10 [14]. En otras palabras, la inteligencia artificial ya forma parte de la vida cotidiana mucho antes de que las personas sientan que comprenden realmente cómo funciona.

Esa convivencia cotidiana también está ampliando los espacios en los que recurrimos a estos sistemas. Entre el 5% y el 9% de estudiantes y docentes afirma utilizarlos como apoyo emocional, para desahogarse, buscar motivación o incluso valorar si necesita ayuda psicológica. Las mujeres representan el 61% de ese uso y casi nueve de cada diez personas consideran que la experiencia les resultó útil [14]. La propia ENIAG advierte, acertadamente, que estos resultados no deben interpretarse como una alarma, sino como un indicio de necesidades de salud mental aún no satisfechas. Al mismo tiempo, subraya que la IA no puede sustituir el acompañamiento profesional ni las redes de apoyo humano [14].

Vista en conjunto, la encuesta describe una situación paradójica. Usamos la IA con enorme frecuencia, reconocemos que todavía no la entendemos del todo y, aun así, empezamos a incorporarla en actividades que requieren criterio, reflexión e incluso apoyo personal. Esa brecha entre uso intensivo y comprensión limitada constituye un terreno especialmente fértil para la confianza ciega.

El informe preliminar del Panel Científico Internacional Independiente sobre IA, presentado por la ONU en julio de 2026 y copresidido por Yoshua Bengio y la periodista Maria Ressa, documenta el extremo más grave de este mismo fenómeno, vincula formalmente el comportamiento sicofántico de los chatbots con varios incidentes graves de salud mental, incluidas muertes ya documentadas en distintos países [9]. El panel advierte que estos sistemas, entrenados para

maximizar la satisfacción inmediata del usuario, pueden terminar reforzando pensamientos peligrosos en lugar de cuestionarlos, en particular en personas vulnerables. No es un dato menor, es una de las razones por las que el propio informe dedica un énfasis especial a la seguridad infantil y a la gobernanza de la salud mental como prioridades urgentes [9]. Existe una paradoja evidente, cuanto más delegamos el esfuerzo de pensar en la IA, menos capacidad conservamos para evaluar críticamente las respuestas que ella misma produce.

Esta paradoja, por cierto, no es exclusiva de México. En la Unión Europea, el reporte de Eurostat 2026 muestra que el uso de IA generativa alcanzó al 32.7% de la población en apenas dos años, mientras que la principal barrera que reportan las empresas europeas sigue siendo la falta de pericia técnica, mencionada por el 70.3% de las organizaciones [6]. Igual que en las aulas mexicanas, el mundo entero está adoptando esta herramienta a una velocidad que supera, con mucho, nuestra capacidad de entender cómo funciona por dentro. Ese vacío de conocimiento, en casi cualquier lugar del mundo, tiende a llenarse con algo parecido a la fe.

El Foro Económico Mundial identifica un riesgo relacionado, la ganancia de eficiencia inmediata puede tener un costo a largo plazo, porque la dependencia excesiva de la IA parece provocar un declive en las habilidades de juicio crítico y resolución de problemas, sobre todo entre los trabajadores más jóvenes [24]. A esto se suma una brecha que rara vez se menciona, según el Banco Mundial, las mujeres representan apenas un tercio de los usuarios de ChatGPT a nivel global [22]. Esto sugiere que los riesgos de la confianza ciega, y también la posibilidad de aprender a manejarla con criterio, podrían estar distribuyéndose de forma muy desigual.

Un dato final, casi irónico, cuando se les pregunta directamente, solo el 8.2% de los estudiantes mexicanos dice confiar “plenamente” en las respuestas de la IA, el 48.2% dice confiar “algo” pero revisar siempre [14]. A primera vista, contradice la idea de confianza ciega. Pero el propio informe advierte algo importante, verificar no equivale a pensar críticamente, y esa revisión declarada puede reflejar simplemente el miedo a ser sancionado por usar IA, no un hábito genuino de escrutinio [14].

La confianza ciega rara vez consiste en aceptar todas las respuestas de la IA sin cuestionarlas. Suele manifestarse de formas mucho más sutiles, dejar de buscar una segunda fuente, asumir que un texto bien escrito también es correcto o acostumbrarse a que el sistema confirme nuestras intuiciones. Esa confianza gradual, casi imperceptible, es probablemente el cambio más profundo que la inteligencia artificial está introduciendo en nuestra manera de pensar.

6. Qué hacer con esto

Después de revisar los riesgos, es fácil caer en una conclusión equivocada, pensar que la solución consiste en dejar de usar la inteligencia artificial, la evidencia apunta en otra dirección. El desafío no es renunciar a estas herramientas, sino aprender a utilizarlas sin sustituir el juicio humano. Esa responsabilidad no recae únicamente en los usuarios, también involucra a gobiernos, universidades, empresas y desarrolladores.

La buena noticia es que la respuesta institucional ya empezó, y en México se puede rastrear con bastante claridad. En noviembre de 2021, la UNESCO adoptó por aclamación de 193 países la Recomendación sobre la Ética de la Inteligencia Artificial, el primer estándar global en la materia, basado en el respeto a los derechos humanos, la transparencia y la supervisión humana de los sistemas de IA [18].

México construyó sobre esa base un marco propio. El 29 de enero de 2026, la Secretaría de Ciencia, Humanidades, Tecnología e Innovación y la Agencia de Transformación Digital y Telecomunicaciones presentaron la Declaración de ética y buenas prácticas para el uso y desarrollo de la Inteligencia Artificial, conocida como los Principios de Chapultepec. Entre sus diez principios destacan dos que resumen bien el espíritu de este artículo: "toda decisión apoyada por IA debe tener responsables humanos" y "si una decisión no puede explicarse, no debe automatizarse" [13].

Las universidades mexicanas no se quedaron atrás. La UNAM ha desplegado varias propuestas en los últimos meses, un protocolo para el uso ético de la IA en posgrados, surgido después de que una encuesta interna revelara que el 86% de sus estudiantes de posgrado ya usa estas herramientas [8], un libro institucional que integra los marcos de la UNESCO y la OCDE [12], y la creación en 2026 del CCOIA-UNAM, un consejo permanente encargado de coordinar la política de IA en toda la universidad [21]. El Tecnológico de Monterrey publicó sus propios Lineamientos para el uso ético de la Inteligencia Artificial, con 11 recomendaciones dirigidas a estudiantes [17]. Asimismo, la Universidad Autónoma Metropolitana presentó, en 2026, su Decálogo de ética para el uso de la IA, elaborado por una comisión con representantes de sus cinco unidades académicas [20].

Esto importa porque conecta con un vacío que la propia ENIAG documenta, más del 76% de estudiantes y 75% de docentes en instituciones públicas mexicanas no conoce ninguna normativa institucional sobre el uso de la IA [14]. El problema, entonces, no es solo un hábito individual de verificación. En realidad, el desafío no consiste únicamente en redactar normas. La velocidad con la que evolucionan los modelos de IA es muy superior a la velocidad con la que las instituciones producen regulaciones, capacitan a sus comunidades y generan mecanismos de supervisión. En ese desfase es donde aparecen muchos de los riesgos descritos en las secciones anteriores.

Vale la pena decir algo más matizado sobre esta respuesta institucional, no siempre es sencilla, ni está exenta de riesgos propios. La ONU advierte que los responsables de política pública enfrentan lo que llama un "dilema de la evidencia", necesitan datos sólidos para tomar decisiones de gobernanza informadas, pero para cuando esos datos existen, la tecnología ya avanzó varios pasos más [9]. El informe preliminar del panel científico de la OCDE añade un matiz igual de importante, la inacción también tiene costos, porque un gobierno que por miedo tarda demasiado en adoptar la IA para fines legítimos corre el riesgo de quedar relegado a ser un simple "tomador de tecnología", en vez de participar en darle forma [10]. La respuesta, entonces, no es elegir entre confiar ciegamente o prohibir por completo, sino construir instituciones

capaces de auditar estos sistemas casi en tiempo real.

El Banco Mundial propone un marco útil para pensar esto de forma más concreta, fortalecer lo que llama las "4Cs" de la base de la IA: conectividad, cómputo, contexto y competencia [22]. El "contexto" es quizás el más relevante para países como México, no basta con usar los modelos que llegan desde otros lugares, hay que adaptarlos a los idiomas, las culturas y los marcos normativos locales, para que la IA no termine siendo un sistema ajeno que simplemente impone una visión del mundo que no es la nuestra. Algunas empresas, mientras tanto, ya empezaron a aplicar la idea de "human-in-command", la autoridad final de cualquier decisión debe seguir residiendo en una persona, de modo que la IA funcione como copiloto y nunca como el capitán del juicio profesional [24].

A nivel personal, la evidencia apunta hacia una idea sencilla, aunque no siempre fácil de poner en práctica, usar la inteligencia artificial como un punto de partida y no como la última palabra. Eso implica tratar cualquier respuesta con consecuencias reales (salud, dinero, decisiones legales o académicas) como un primer borrador, acudir directamente a las fuentes originales en lugar de confiar en que el modelo las resumió correctamente, y, sobre todo, reconocer cuándo una respuesta resulta especialmente convincente porque confirma lo que ya pensábamos. Según la evidencia revisada en este artículo, ése suele ser el momento en que más conviene detenerse y verificar.

7. El costo oculto: energía, materiales y desigualdad global

Hasta ahora hemos hablado de cómo la inteligencia artificial puede modificar nuestras decisiones y nuestra manera de pensar. Pero existe otra dimensión de la confianza ciega que rara vez aparece en estas discusiones, olvidar que detrás de cada conversación con un modelo existe una infraestructura física con costos ambientales, económicos y geopolíticos. Con frecuencia imaginamos la inteligencia artificial como algo inmaterial, un servicio que aparece en la pantalla y responde en segundos. Sin embargo, como recuerda un informe de la Universidad de las Naciones Unidas, la IA está sostenida por una infraestructura física enorme. Cada consulta depende de centros de datos, chips especializados, electricidad, sistemas de enfriamiento, agua, minerales críticos y grandes extensiones de terreno [1]. El informe propone que la transparencia no debería limitarse a explicar qué dice un modelo, sino también qué consume, mediante la divulgación estandarizada y comparable de su huella energética, hídrica y de carbono.

Esa infraestructura tampoco está distribuida de manera uniforme. Los países que diseñan los modelos concentran la mayor parte de la inversión, el conocimiento y los beneficios económicos, mientras que los costos ambientales suelen recaer sobre las regiones donde se instala la infraestructura necesaria para operarlos [1, 22]. Para países como México, la discusión sobre inteligencia artificial no consiste únicamente en decidir qué herramientas utilizar. También implica preguntarse quién desarrolla esas herramientas, bajo qué reglas operan y quién asume los costos de sostenerlas.

La confianza ciega, vista desde esa perspectiva, deja de ser únicamente un problema de juicio individual y se convierte también en un desafío de soberanía tecnológica.

8. Conclusión

El Programa de las Naciones Unidas para el Desarrollo resume el núcleo de este debate con una idea sencilla, la inteligencia artificial puede automatizar tareas, pero no asumir responsabilidad por sus consecuencias [11]. Esa diferencia parece obvia, pero con facilidad la olvidamos cuando un sistema responde con rapidez, seguridad y aparente competencia. Un profesional puede explicar por qué tomó una decisión y responder por ella, un modelo genera una respuesta, pero no comparte las consecuencias de aceptarla. El verdadero riesgo de la confianza ciega no consiste únicamente en recibir información incorrecta, sino en delegar decisiones importantes a un sistema que, por diseño, nunca podrá hacerse responsable de ellas.

Ninguno de los informes revisados aquí, ni el de Stanford, ni el internacional de seguridad, ni la encuesta mexicana, sugiere que la solución sea dejar de usar la inteligencia artificial. El problema nunca fue la herramienta, fue haber dejado de hacernos preguntas. Preguntar no significa desconfiar de todo ni renunciar a los beneficios de la IA. Significa conservar el hábito de contrastar, verificar y reconocer que una respuesta convincente no siempre es una respuesta correcta. Ése ha sido, en distintos contextos, el hilo común de todos los estudios revisados en este artículo. La IA generativa ya transformó la manera en que millones de personas escriben, estudian, trabajan y hasta procesan sus emociones, eso ya ocurrió y no tiene marcha atrás. Lo que todavía está en construcción, en México y en el resto del mundo, es el hábito de mantener el juicio propio despierto frente a una tecnología que, cuanto más fluida y segura suena, más fácil nos resulta creerle sin preguntar.

La inteligencia artificial seguirá mejorando, sus respuestas serán cada vez más rápidas, más precisas y difíciles de distinguir de las de un experto. Precisamente por eso, el juicio humano dejará de consistir en recordar más datos que una máquina y pasará a depender, cada vez más, de nuestra capacidad para formular mejores preguntas, reconocer la incertidumbre y decidir cuándo confiar. La inteligencia artificial no sólo cambia lo que podemos hacer, sino la forma en que ejercemos nuestro juicio. En el futuro, quizá la habilidad más importante no sea aprender a usar la inteligencia artificial, sino aprender a no dejar de pensar cuando la usamos.

Referencias

[1] Aczel, M., *et al.* (2026). Environmental cost of AI's energy use: Carbon, water and land footprints. United Nations University Institute for Water, Environment and Health (UNU-INWEH).

[2] Apollo Research. (2025). Stress testing deliberative alignment for anti-scheming training. https://www.apolloresearch.ai/science/science-of-scheming/

[3] Bengio, Y. (Ed.). (2026). International AI safety report 2026. Departamento de Ciencia, Innovación y Tecnología del Reino Unido. https://internationalaisafetyreport.

org/sites/default/files/2026-02/informe-internacional-sobre-la-seguridad-de-la-ia-2026.pdf

[4] CNN. (2024, 4 de febrero). Hong Kong worker pays out $25 million after video call with deepfake 'CFO'. https://edition.cnn.com/2024/02/04/asia/deepfake-cfo-scam-hong-kong-intl-hnk

[5] Cheng, M., *et al.* (2026). Sycophantic AI decreases prosocial intentions and promotes dependence. Science. https://doi.org/10.1126/science.aec8352

[6] Eurostat. (2026). The use of artificial intelligence (AI) technologies in the European Union (2026 edition). Statistical Report.

[7] METR. (2026). Frontier AI risk report. https://metr.org/es/blog/2026-05-19-frontier-risk-report/

[8] Milenio. (2025, 9 de diciembre). UNAM desarrolla protocolo para usar IA en posgrados de manera ética. https://www.milenio.com/comunidad/unam-desarrolla-protocolo-ia-posgrados-etica

[9] Naciones Unidas. (2026). Informe preliminar del Panel Científico Internacional Independiente sobre IA: Evaluación basada en evidencia de oportunidades, riesgos e impactos de la inteligencia artificial. Secretaría de las Naciones Unidas.

[10] OCDE. (2025). Governing with artificial intelligence: The state of play and way forward in core government functions. OECD Publishing. https://doi.org/10.1787/795de142-en

[11] Programa de las Naciones Unidas para el Desarrollo. (2025). Informe sobre Desarrollo Humano 2025: Una cuestión de elección: las personas y las posibilidades en la era de la IA. https://hdr.undp.org/content/human-development-report-2025

[12] Ramírez Molina, A. Y., & Ventura Miranda, M. T. (2025). Uso y desarrollo ético de la inteligencia artificial en la universidad: Docencia e investigación. Universidad Nacional Autónoma de México, DGTIC. https://www.tic.unam.mx/wp-content/uploads/2025/11/Uso-y-desarrollo-etico-del-IA-en-la-UNAM_v-digital.pdf

[13] Secretaría de Ciencia, Humanidades, Tecnología e Innovación, & Agencia de Transformación Digital y Telecomunicaciones. (2026). Declaración de ética y buenas prácticas para el uso y desarrollo de la inteligencia artificial (Principios de Chapultepec). https://www.secihti.mx/ciencia-y-humanidades/principios-de-chapultepec-declaracion-de-etica-y-buenas-practicas-para-el-uso-y-desarrollo-de-la-inteligencia-artificial/

[14] Secretaría de Educación Pública. (2025). Usos y percepciones sobre la Inteligencia Artificial Generativa en la educación superior mexicana: Encuesta Nacional ENIAG 2025. Subsecretaría de Educación Superior.

[15] Stanford University. (2026). The Stanford Emerging Technology Review 2026: A report on ten key technologies

and their policy implications. https://setr.stanford.edu/

[16] Stanford University, Institute for Human-Centered Artificial Intelligence. (2026). AI index report 2026. https://hai.stanford.edu/ai-index/2026-ai-index-report/responsible-ai

[17] Tecnológico de Monterrey. (2025). Lineamientos para el uso ético de la inteligencia artificial. https://tec.mx/es/integridad-academica/inteligencia-artificial

[18] UNESCO. (2021). Recomendación sobre la ética de la inteligencia artificial. https://www.unesco.org/en/artificial-intelligence/recommendation-ethics

[19] United States Government Accountability Office. (2026). Disaster assistance scams: Education and awareness are key to consumer protection (GAO-26-108280). https://www.gao.gov/products/gao-26-108280

[20] Universidad Autónoma Metropolitana. (2026). Decálogo de ética para el uso de la inteligencia artificial en la Universidad Autónoma Metropolitana. https://www.comunicacionsocial.uam.mx/principal/avisos/decalogo_etica_ia_120526.pdf

[21] Universidad Nacional Autónoma de México, Gaceta UNAM. (2026, 17 de marzo). Desafíos y alcances de la inteligencia artificial y el papel del CCOIA-UNAM. https://www.gaceta.unam.mx/desafios-y-alcances-de-la-inteligencia-artificial-y-el-papel-del-ccoia-unam/

[22] World Bank Group. (2025). Digital progress and trends report 2025: Strengthening AI foundations. World Bank. https://hdl.handle.net/10986/43822

[23] World Economic Forum, & Accenture. (2026). Global cybersecurity outlook 2026. https://www.weforum.org/publications/global-cybersecurity-outlook-2026/in-full/3-the-trends-reshaping-cybersecurity/

[24] World Economic Forum, & PwC. (2026). Artificial intelligence and the future of entry-level work: A framework for safeguarding and reinventing early career pathways. Insight Report. https://www.weforum.org/publications/

Entre el mito, la leyenda y la historia: crónicas sobre el desarrollo de la inteligencia artificial



Dr. Pedro Lara Velázquez *
Dr. Miguel Ángel Gutiérrez Andrade*
Dr. Eric Alfredo Rincón García*
Dr. Sergio Gerardo de los Cobos Silva*
Dr. Roman Anselmo Mora Gutiérrez**
Dr. Edwin Montes Orozco***
MC Alma Edith Martínez Licona*
Dra. Fabiola Margarita Martínez Licona*

* Departamento de Ingeniería Eléctrica, Universidad Autónoma Metropolitana, Unidad Iztapalapa
**Departamento de Sistemas, Universidad Autónoma Metropolitana, Unidad Azcapotzalco
***Departamento de Computación, Electrónica y Mecatrónica, Universidad de las Américas Puebla

Imagen creada con IA generativa — OpenAI / ChatGPT

Abstract
This work presents a chronological and conceptual overview of the evolution of Artificial Intelligence (AI), a story told as several related chronicles. It starts with the inception of the first mathematical artificial neuron and details the formal emergence of AI as a scientific discipline at the pivotal Dartmouth Conference. The narrative explores the limitations encountered during the 1970s that tempered early expectations, followed by the rise of expert systems and key advancements in symbolic AI. After addressing the subsequent decline of the symbolic paradigm and the pendular shift back to connectionism, the study illustrates how the contemporary AI boom was forged in the early 21st century through the convergence of massive datasets, high-speed processing hardware, and efficient algorithms. Finally, it examines deep neural networks, distinguishing between discriminative AI for data organization and generative AI for original content, before concluding with synthesizing remarks on the field's trajectory.

Keywords: Artificial Intelligence, History of AI, Neural Networks, Symbolic AI, Connectionist AI, Discriminative AI, Generative AI.

Resumen
Este trabajo presenta una visión general, cronológica y conceptual de la evolución de la Inteligencia Artificial (IA), una historia narrada a través de varias crónicas interrelacionadas. Comienza con la creación de la primera neurona artificial matemática y detalla el surgimiento formal de la IA como disciplina científica en la Conferencia de Dartmouth. También se exploran las limitaciones encontradas durante la década de 1970 que moderaron las expectativas iniciales, seguidas por el auge de los sistemas expertos y los principales avances en la IA simbólica. Tras abordar el subsiguiente declive del paradigma simbólico y el cambio pendular de vuelta al conexionismo, el estudio ilustra cómo el auge contemporáneo de la IA se forjó a principios del siglo XXI mediante la convergencia de conjuntos de datos masivos, hardware de procesamiento de alta velocidad y algoritmos eficientes.

Finalmente, examina las redes neuronales profundas, distinguiendo entre la IA discriminativa para la organización de datos y la IA generativa para la creación de contenido original, antes de concluir con observaciones sintéticas sobre la trayectoria del campo.

Palabras clave: Inteligencia Artificial, Historia de la IA, Redes Neuronales, IA Simbólica, IA Conexionista, IA Discriminativa, IA Generativa.

Introducción. La literatura como espejo de los anhelos humanos.

[Hefesto construyó] dos estatuas de oro que eran semejantes a jóvenes vivientes, pues tenían inteligencia, voz y fuerza y se hallaban ejercitadas en las obras propias de los dioses inmortales.[1]

Homero, La Ilíada, Canto XVIII (siglo VIII a.C.)

Yeah, but your scientists were so preoccupied with whether or not they could, they didn't stop to think if they should.

Ian Malcolm -Guion cinematográfico de Jurassic Park (1993)

[1]Homero, La Iliada, Canto XVIII, Ed, Gredos, pp. 307.

Para evitar la trampa que en historia se conoce como "el monstruo de los orígenes", y no tener que retroceder hasta el *Big Bang*, se decidió empezar esta introducción literaria en la Ilíada de Homero, donde se hace referencia a Hefesto, (dios del fuego e hijo de Hera) el protector de los orfebres,[2] quien construyó los sirvientes de oro mencionados. En la cita se muestra un anhelo cultural de crear vida a partir de objetos inanimados. Otro ejemplo sería la leyenda judía del *Golem* de Praga: una figura de arcilla que cobraba vida al usar las letras del *aleph-bet* (alfabeto hebreo), esta es considerada la primera referencia de programación mediante palabras, se remonta hacia la segunda mitad del siglo XVI, alrededor de 1580.

Dentro de la literatura "más reciente" se puede citar la novela *Frankenstein*, de Mary Shelley, escrita en 1818. Aquí se cuenta la historia del Dr. Víctor Frankenstein, creador de un monstruo con una agilidad y fuerza sobrenatural, que incluso es capaz de hablar y es estéticamente hermoso (al contrario de lo que nos ha hecho creer Hollywood). Dicho monstruo fue hecho de cadáveres humanos, animales de matadero y diversas "sustancias químicas". Pese a que sus facciones son bellas estéticamente, su piel cetrina, su rostro demacrado y su inexpresividad lo hacen entrar en el llamado "valle de la repulsión" (traducción castellanizada de la expresión anglosajona *uncanny valley*)[3] y recibe un rechazo generalizado que lo convierte en un ser lleno de resentimiento a los demás humanos, incluido su creador. Después de haber padecido una terrible hostilidad y un rechazo deshumanizante del mundo civilizado, regresa con su creador y desata una persecución que termina por cobrar la vida del Dr. Frankenstein. Al final, totalmente solo, el monstruo se ahoga en las frías aguas del Ártico.

Para tener un punto de vista literario más positivo, mencionaremos el último cuento del libro *Yo, Robot* de Isaac Asimov llamado "*El Conflicto Evitable*" escrito alrededor de 1950. Corre el año de 2052 y la "IA"[4] controla la economía global, así como los recursos del planeta y como se deben gestionar. Las guerras y el hambre ya son cosa del pasado. Pese a esto, existe todavía un coordinador (humano) encargado de supervisar el comportamiento de las máquinas, y encuentra que hay una discrepancia entre la solución óptima y lo que está ocurriendo en las decisiones globales. Después de una larga investigación, descubre que la IA realizó estos cambios para compensar los errores y omisiones humanas, ya que los humanos somos el mayor peligro para la humanidad por tomar malas decisiones:

"¿Cómo sabemos qué es lo que consolidará el bien final de la humanidad? No tenemos los [datos] infinitos que las máquinas pueden procesar... Las máquinas deben orientarse, preferiblemente sin decírnoslo, ya que en nuestros ignorantes prejuicios solo sabemos que aquello a que estamos acostumbrados es bueno... Solo las máquinas lo saben y se encaminan hacia ello, llevándonos consigo" [5] .

[2]Edith Hamilton, Mythology, Signet Classics, 1940, pp. 34-35.

[3]Es la sensación de miedo y rechazo que sentimos los humanos cuando vemos un ente que parece una persona viva, pero que no lo es del todo, por ejemplo, un cadáver, una persona moribunda, robots animatronics o al ver películas y videos hiperrealistas.

[4]En el cuento son llamadas "las máquinas", nombre más que entendible si pensamos que fue escrito en 1950.

[5]Asimov, I. Yo, robot (M. Bosch Barret, Trad.). Edhasa. (pp. 321-322).

De esta forma, “las máquinas” se convierten en los protectores de la humanidad (donde ahora ellas son el elemento recién llegado) y están logrando un sistema que le permite a la humanidad vivir en armonía a pesar de ella misma.

La lista mitológica y literaria podría seguir, y prueba que incluso antes de que fuera posible desarrollar las llamadas inteligencias artificiales (más adelante veremos que no hay una sola definición), el ser humano tenía un anhelo de hacer una creación “a su imagen y semejanza”.

Como se puede ver, cuando se hace referencia de un ser inteligente en los ejemplos de literatura antes descritos, se habla de un enfoque fenomenológico: algo es inteligente porque se comporta como un ente inteligente. Cuando se relaja este concepto se puede decir que cualquier computadora (analógica o digital) es inteligente, ya que, por ejemplo el telar *Jacquard* (primer prototipo útil desarrollado en 1801 y posiblemente la primera computadora digital) o el concepto teórico la máquina analítica de Charles Babbage (modelo teórico de 1837 y la primera computadora de propósito general, aunque de hecho no se ha construido por completo al día de hoy), pueden sustituir, de una forma digital, ya sea a un artesano textil que hace diseños extremadamente sofisticados o bien suplir a un calculista experto.

Si buscamos el inicio de la inteligencia artificial porque un ente tiene una conducta inteligente (más adelante lo llamaremos enfoque simbólico de la IA) de menos regresamos hasta Francia con el ingeniero Jacques de Vaucanson en 1738 y las primeras computadoras analógicas. Estas máquinas pueden suplir a un pato, un flautista o un conejo. Aunque es un tema interesante, empezar con esta versión de las cosas, es un profundísimo hoyo de conejo que sería tema de otro artículo, no este trabajo.

Por otra parte, y de la forma más radical y maniquea, se dice que solo hay inteligencia donde hay neuronas (la mayoría de los animales pluricelulares poseen neuronas y un sistema nervioso). A este enfoque se le llama conexionista. El psicólogo escocés Alexander Bain, que en su libro *Mind and Body* [Bain, 1873] pone el cimiento conceptual del conexionismo moderno, que utiliza computadoras para simular el comportamiento de neuronas.

Hacer una historia de la IA que cubra todos sus aspectos, aunque fuera de una manera breve, sería una labor titánica que nos llevaría cientos, quizás miles de páginas. Por esta razón, se tomó la decisión de hacer relatos donde se enfatizarán partes que se consideraron interesantes, tomando a algunas personas y comentando algunos conceptos clave, dejando fuera muchas cosas. El enfoque fue crear una línea de tiempo que uniera un inicio y un fin, y más que querer hacer historia, se presentan crónicas, lo que permite ser un poco más flexibles y va más de acuerdo a un trabajo de divulgación científica.

El siguiente trabajo se desarrolla como sigue: el capítulo 1 trata del origen de la primera neurona artificial matemática. El capítulo 2 refiere del origen de la IA como disciplina formal y científica en la llamada Conferencia de Dartmouth, también llamado el *Big Bang* de la IA. En el capítulo 3 se discuten las limitaciones que surgieron durante la década de los setenta y que hizo tener expectativas más modestas. El capítulo 4 se refiere

los sistemas expertos y el progreso que tuvo el enfoque simbolista. El capítulo 5 habla brevemente del ocaso de esta IA para, como si fuera un péndulo, regresar al enfoque conexionista. En el capítulo 6 se ve que el auge de la IA actual se forjó a inicios del siglo XXI, cuando se encontraron bases de datos descomunales, hardware veloz para procesar las bases de datos y algoritmos eficientes que actualmente pueden obtener resultados que a veces resultan increíbles. En el capítulo 7 se describen las redes neuronales profundas y de la IA discriminativa (que permite organizar información). En el capítulo 8 se hace referencia a la IA generativa (que crea datos originales a partir de la información con que se entrena). Finalmente, se presentan las conclusiones.

Lo que en la actualidad se enseña en los cursos de licenciatura y posgrado sobre inteligencia artificial, será el punto de corte. En esa pelea contra el monstruo de los orígenes (en este caso histórico) la referencia espacio-temporal, será la conferencia de Dartmouth de 1956, aunque las bases teóricas se habían comenzado a desarrollarse trece años antes, con un niño pobre que no tenía que perder, y un profesor acaudalado que tenía todo por ganar.

1. Primeros trabajos.

La historia moderna de la IA empieza en 1935 en los Estados Unidos de Norteamérica con dos personas con mentes muy afines y orígenes diametralmente opuestos: un niño pobre de la región de los grandes lagos (Medio Oeste) y un profesor joven de la Costa Este que se había dedicado toda la vida a estudiar y a ser investigador.

Walter Pitts era un niño maltratado que creció durante la gran depresión. Originario de un "barrio bravo" de la ciudad de Detroit, tuvo que dejar la escuela primaria para apoyar con la economía familiar. En varias entrevistas Walter Pitts relató que una tarde fría de ese año, estaba huyendo de unos *"bullies"* que lo querían golpear y fue a esconderse en la biblioteca pública local. Este lugar siempre había sido su lugar seguro de manera física, emocional e intelectual. Como una forma de evasión, Walter fue un niño autodidacta que aprendió griego, latín, lógica y matemáticas y esa biblioteca era su verdadero hogar.

Para garantizar que los matones no lo molestaran, decidió quedarse ahí toda la noche. Vagabundeando entre los anaqueles, sigue contando la leyenda, se encontró con los tres volúmenes de la obra *Principia Mathematica*, escrito por ingleses Bertrand Russell y Alfred Whitehead. En este libro se intentaba construir los fundamentos de las matemáticas a través de la lógica pura.

Durante tres días completos el niño leyó los tres tomos (aprox. 2000 páginas) y encontró varios errores. Decidió escribir a Bertrand Russell una carta donde detallaba sus hallazgos y Bertrand Russell, ignorante de la situación y edad del niño, quedó tan impresionado que lo invitó a la Universidad de Cambridge (Inglaterra) como estudiante de posgrado. Dado que no tenía los recursos y mucho menos un pasaporte para ir a Inglaterra, no pudo tomar esa oportunidad.

Tres años después Bertrand Russell viajó a la Universidad de Chicago y permaneció ahí durante seis meses como profesor visitante. Al enterarse, Walter escapó de casa y con sus ahorros, tomó

un autobús y se dirigió a Chicago. Nunca más volvió a ver a su familia.

La vida de Walter podría ser fuente para escribir una novela completa, basta comentar que permaneció en esta universidad tomando cursos sin estar matriculado, dado que no tenía documentos que validaran sus estudios y tampoco tenía dinero para pagar las costosas colegiaturas de la universidad y se ganó el respeto de profesores y alumnos.

El otro miembro de este binomio, Warren McCulloch, era un joven profesor acaudalado originario de Orange, Nueva Jersey, que obtuvo su licenciatura en filosofía y psicología por la Universidad de Yale, una maestría en psicología por la Universidad de Columbia y un doctorado en medicina por la misma Universidad.

La vida personal del Dr. McCulloch no tiene mayores polémicas, pero su trabajo como investigador era sobresaliente: Trabajó desde 1934 a 1941 en el laboratorio de neurofisiología en la Universidad de Yale y en 1941 se integró al Departamento de Psiquiatría de la Universidad de Illinois en Chicago en donde, mediante un amigo, conoció a Walter, entonces ya un joven de 19 años que tenía ideas novedosas de como describir matemáticamente las sinapsis en las neuronas.

Después de unos meses de trabajo conjunto, describieron la actividad neuronal con un modelo basado en lógica booleana [Boole, 1854], donde se describe el proceso de pensamiento binariamente, es decir, si hay o no hay contacto entre neuronas. El artículo resultante, *A Logical Calculus of the Ideas Immanent in Nervous Activity* [McCulloch, 1943], puso los fundamentos del tratamiento moderno de las redes neuronales artificiales (RNA)[6] (término que ellos acuñaron unos años después).

2. El optimismo desbordado de los 1950s.

En 1950, durante sus estudios doctorales en la universidad de Princeton, John McCarthy conoció a otro estudiante doctoral llamado Marvin Minsky con quien compartía el anhelo de crear máquinas inteligentes y modelar el cerebro humano. En 1952, un año después de su graduación, consiguió un trabajo de verano en los Laboratorios Bell, donde trabajó directamente bajo la supervisión del Dr. Claude Shannon quien también tenía interés en esas ideas, con un enfoque que llamaba teoría de autómatas. En 1955 McCarthy trabajó temporalmente en IBM, donde conoció a Nathaniel Rochester quien era el diseñador principal de la computadora IBM 701, la primera computadora científica fabricada en serie por la IBM, esta computadora era muy poderosa para los tiempos, y parecía un buen equipo para empezar a desarrollar una "máquina pensante".

En verano de ese mismo año, el profesor asistente John McCarthy tuvo la visión de fabricar una "máquina de sentido común", es decir, una máquina que pudiera pensar. Por esta razón, convocó a estos tres colaboradores para organizar una conferencia acerca de un tema que los intrigaba desde hace unos años, ¿es posible que los seres humanos puedan crear una inteligencia artificial? Entre ellos redactaron una propuesta para iniciar una investigación formal en el campo [McCarthy, 1955]. En este artículo se usa por primera vez el término "Inteligencia Artificial" y

[6]También conocidas como ANN (Artificial Neural Networks por sus siglas en inglés).

se mencionaba que cada aspecto del aprendizaje o de la inteligencia se puede simular, de igual forma se definen 7 áreas de estudio prioritarias que siguen siendo válidas hoy en día.[7]

De esta manera, durante ocho semanas del verano de 1956, en Dartmouth College, New Hampshire, entre el 18 de junio y el 17 de agosto, se desarrolló la llamada conferencia, que más bien fue un taller donde los convocados expusieron sus ideas, sin haber mucha colaboración entre ellos, pocos de los convocados estuvieron presentes todo el tiempo, aquí surgieron los dos enfoques opuestos que al día de hoy siguen causando polémicas: por una parte, se afirmó que la única inteligencia artificial real es la que se desarrolla con redes neuronales artificiales (el llamado enfoque conexionista: "sin neurona, no hay inteligencia"). Hay otro enfoque que cree que un ente (programa, algoritmo, robot, etc.) es inteligente si se comporta como un ser inteligente (Llamado enfoque simbólico: eres inteligente si resuelves problemas de una manera lógica).

No existe un documento oficial sobre las conferencias que se llevaron a cabo ese verano, pero uno de los asistentes, el profesor Ray Solomonoff fue uno de los pocos que estuvieron todo el tiempo, tomó notas minuciosas de las charlas, y es el único testimonio detallado de lo que ocurrió ahí [Solomonoff, 1956].

Algunos profesores llegaron presentando resultados concretos: Allen Newell y Herbert Simon llegaron con un programa de computación que llamaron *Logic Theorist* [Newell, 1956] [Newell, 1957] que podía resolver teoremas matemáticos del libro *Principia Mathematica* de Russell y Whitehead (ya mencionado anteriormente), incluso hubo una demostración mucho más corta y directa que la presentada en el libro[8]. En el artículo [Gugerty, 2006] se presenta un análisis mucho más accesible que los documentos originales.

Tomando como base el artículo ya mencionado de [McCulloch, 1943], en 1957 el Dr. Frank Rosenblatt inventó el concepto del perceptrón, es decir, un modelo de una neurona que mediante pesos de conexión de entrada (que son como las dendritas de una neuronal real) y reglas de aprendizaje que permite que la neurona "aprenda" por sí misma (es decir que algunas conexiones a otras neuronas se refuercen o se debiliten), este enfoque se describe en el artículo [Rosenblatt, 1958]. No solamente desarrolló teorías sino que construyó la primera máquina de IA con enfoque conexionista: la Mark I Perceptron, que ocupaba el tamaño de una habitación y donde se ajustaban los pesos de las "dendritas artificiales" mediante el uso de potenciómetros controlados por motores eléctricos. Se usó para reconocer las siluetas de aviones y barcos a partir de fotografías aéreas.

Un par de años después, McCarthy creó el lenguaje de programación LISP (List Processing), un lenguaje capaz de operar con conceptos, este programa se volvió la columna vertebral de la IA durante los próximos 30 años. Con este software se pudieron modelar juegos de estrategia, como el ajedrez y las damas, explorar soluciones a problemas combinatorios

[7] Computadoras automáticas, procesamiento de lenguaje natural, redes neuronales, teoría de la computación, auto-mejora, abstracción y creatividad.

[8] El programa lo alimentaron con los axiomas que los autores propusieron al inicio del libro y las reglas de inferencia permitidas y buscando combinaciones se buscó demostrar los teoremas del segundo capítulo. El programa logró demostrar 38 de los primeros 52 teoremas del libro.

complejos como por ejemplo el problema del agente viajero (PAV)[9] e incluso a finales de los años sesenta hicieron un robot que podía manejar bloques y resolver problemas complejos.

Este éxito inicial creó un optimismo desmedido, los expertos de ese momento creían, por ejemplo, que la formación de conceptos iba a resolverse en un par de años. El futuro era tan brillante, que los investigadores debieron usar lentes obscuros...

3. El choque con la realidad, la primera "Nube gris de la IA" de los años setenta.

El inconveniente infranqueable es que a medida que los problemas crecen (por ejemplo, se quieren visitar 100 ciudades o más usando PAV, o se quiere planear una jugada de ajedrez y sus consecuencias 20 jugadas más tarde) se tenía el problema que la cantidad de opciones por explorar crecían exponencialmente o incluso factorialmente: Por ejemplo, si debo recorrer 60 ciudades, la cantidad total de rutas por explorar es de 60!=8.32x1081 rutas posibles, que es más que el número total de átomos en el universo observable.

Si quisiéramos analizar todas las jugadas posibles en un juego de ajedrez promedio, que suelen ser 40 por cada jugador, y dado que el número promedio de jugadas posibles por turno es 35, se tiene que el número promedio de jugadas por analizar es de $35^{80} = 3{,}35x10^{123}$. Esta cifra se suele redondear a 10120 y es conocida como el número de Shannon (El mismo Claude Shannon de la conferencia de Dartmouth).

Estas cifras conducen a ver a estos problemas combinatorios como "intratables", es decir, se sabe como resolverlos, pero se tardarían miles de millones de años con las supercomputadoras actuales para obtener la respuesta. Esto es un duro golpe al enfoque simbólico: no se pueden resolver estos problemas de manera exacta.

Algo similar ocurrió con el enfoque conexionista: en 1969 Marvin Minsky y Seymour Papert publicaron un libro riguroso de las capacidades y limitaciones de los perceptrones [Minsky, 1969]. En este trabajo se demuestra que cuando son de una capa (que eran los únicos que se podían resolver hasta hace tres o cuatro décadas), solo eran capaces de resolver problemas cuyo espacio de soluciones se podían dividir con una línea recta. Incluye una demostración donde con este tipo de perceptrones es imposible armar una compuerta lógica XOR, la cual es una de las 7 compuertas básicas universales con que se construye toda la tecnología digital[10]. Este fracaso se interpretó como que las redes neuronales no iban a ningún lado y esta área de investigación se volvió un tabú académico (o por lo menos un tema delicado) hasta mediados de la década de los ochenta.

El Consejo Británico para la Ciencia y la Investigación (SRC[11]) le pidió al matemático James Lighthill, profesor de la cátedra Lucasiana de Matemáticas en la Universidad de Cambridge[12] un

[9]El problema del agente viajero consiste en encontrar la ruta más corta para visitar n ciudades, pasando por cada una de ellas y regresando al punto de partida.

[10]Las siete compuertas lógicas son AND, OR, NOT, NAND, NOR, XOR y XNOR.

[11]Science Research Council en inglés.

[12]Esta cátedra la ha ocupado gente tan destacada como Isaac Newton, Paul Dirac, Charles Babbage y posteriormente, Stephen Hawking.

estado del arte de la investigación de IA en Inglaterra, dicho documento es conocido como el Informe Lighthill [Lighthill,1973].

Este reporte fue demoledor para la investigación de la IA. Demostró que los investigadores habían hecho demasiadas promesas y los logros hasta ese momento eran inútiles para la industria y el ejército, dijo también que los problemas que resolvían los investigadores eran modelos hipersimplificados y solo abstracciones metodológicas. A raíz de este informe, el gobierno británico retiró casi por completo los fondos de todas las universidades inglesas.

4. La reinvención de la IA: Los sistemas expertos y las nuevas redes neuronales.

Con el auge de las computadoras de bajo costo de finales de los años setenta e inicios de los ochenta, las computadoras proliferaron en otras áreas fuera del ámbito académico, y se volvieron accesibles a pequeñas empresas e incluso a nivel personal. También los ingenieros que desarrollaban software se dieron cuenta que crear una "inteligencia general", que supiera todo de cualquier área de conocimiento era algo inalcanzable para la época, así que el enfoque fue desarrollar soluciones de dominio especializado, de esta forma surgieron los "sistemas expertos" que buscaban saber mucho de un área pequeña de conocimiento.

Casi todos los sistemas expertos estaban basados en tres componentes principales: Una base de conocimientos, que buscaba emular las decisiones de un experto, ya sea con base en su comportamiento histórico y así crear conceptos generales, o bien se consultaba a expertos que daban sus opiniones sobre cómo comportarse en situaciones generales. También se tenía una base de hechos, que era la información específica a una empresa, o los datos para resolver un problema específico con datos concretos. Finalmente, se tiene el llamado motor de inferencia, que es la forma que se logran encontrar una solución a un problema. Por lo común estaba basado en la arquitectura del lenguaje LISP (o en su hermano famoso durante los años ochenta: PROLOG) y se tenían dos formas principales de resolverlo: a partir de los datos se llegaba a una conclusión u objetivo (razonamiento hacia adelante) o bien a partir del objetivo, se trataba de llegar a los datos originales (razonamiento hacia atrás). Existen muchos otros motores de inferencia, pero se mostrarán algunos ejemplos:

Sistema de diagnóstico MYCIN[13]: Este sistema era alimentado con los síntomas que tenían los pacientes cuando los aquejaba una infección bacteriana, se tenía una base de conocimientos (una lista de bacterias y los síntomas que causan en el cuerpo humano cuando están atacando una parte específica de una persona), una base de hechos, que serán las preguntas que el médico debe responder a partir de un paciente específico y un motor de inferencia (proceso de razonamiento). En este sistema, el razonamiento era hacia atrás, el médico partía de una conclusión, es decir, suponía que un paciente tenía una infección (supongamos, con *E. Coli*) y a partir de una serie de preguntas (motor de inferencia), se comparan los síntomas del paciente, y la base de datos de síntomas que causan esa infección (base de conocimiento).

[13]Su nombre se deriva de la terminación de su nombre en inglés, de una serie de antibióticos famosos en los 80s que eran la opción "segura" para combatir bacterias sin usar penicilinas (que puede causar reacciones alérgicas peligrosas): azitromicina, claritromicina, eritromicina, etc.

El juego del gato (tres en raya o Tic-Tac-Toe): Este juego es muy sencillo y muy conocido, esperamos que, por todos los lectores, por lo que la base de conocimientos ya es conocida. Cuando el gato está vacío, numeremos las nueve posibles jugadas del 1 al 9 de izquierda a derecha y de arriba a abajo. Supongamos que un usuario (X) juega contra un sistema experto (O), el usuario ya tiene "X" en las casillas 1 y 2, mientras que la computadora tiene una "O" en la casilla 5 (al centro). La máquina tiene como opciones las otras 6 casillas su razonamiento (motor de inferencia) tiene que ser hacia adelante para ver dónde colocar su ficha para ganar, o evitar que le ganen. Escoger la celda 3 evita que le ganen en la siguiente jugada.

Agente Viajero: En este caso la base de conocimientos del problema ya se comentó en el apartado 1 para un caso general, se tienen también reglas fijas que se deben seguir, pero la exploración se hace a través de algoritmos de búsqueda y exploración estocástica, en este caso el motor de búsqueda se vuelve la parte más importante, y existe una disciplina en específico (optimización matemática) que resuelve estos problemas y muchos más en otras disciplinas fuera de la IA. Para una referencia más completa, se recomienda el libro [Cobos, 2010].

El enfoque de sistemas expertos se volvió tan importante en estos años que incluso se fabricaron computadoras especializadas para ejecutar eficientemente y de manera nativa los programas de lenguaje LISP, el gobierno de los Estados Unidos y su sector militar compraron estas máquinas masivamente, gigantes de investigación como Xerox, General Electric y Texas Instruments también participaron.

Parece muy notable el paralelismo de esta fiebre por desarrollar hardware de propósito específico para sistemas expertos basados en LISP y lo que ocurre ahora con computadoras especializadas para la Inteligencia Artificial Generativa: se piden grandes GPU (Tarjetas gráficas) que permiten entrenar redes neuronales de una forma paralela y, por lo tanto, mucho más rápido, también se piden NPU (Unidad de procesamiento neuronal) que es un chip especializado para tareas de IA, así como almacenaje masivo (Discos duros de Estado Sólido para acceso veloz). El paralelismo de esos años y la actualidad, tiene el mismo fundamento: el primero en tener el mejor sistema obtendrá el mayor beneficio.

Respecto a las redes neuronales, en 1986, en plena euforia de los sistemas expertos, el Dr. David Rumelhart de la Universidad de California en San Diego, publicó junto con otros colaboradores, un artículo sobre un nuevo método, que permitía a las redes neuronales aprender de sus errores y mejorar su precisión. Lo llamo método de "retropropagación" [Rumelhart, 1986]. Al introducir varias capas que permiten resolver problemas mucho más complejos y permiten que las redes aprendan solas, sin intervención humana. Desde este momento la retropropagación se volvió inseparable de las redes neuronales.

El último elemento por incluir es la llamada función de activación. Su objetivo es tomar la decisión final de si una neurona debe activarse (transmitir información) o no, tal y como ocurre con neuronas biológicas. Esta función permite analizar sistemas no lineales y estudiar sistemas con fronteras complejas y limita el resultado entre dos valores extremos, por ejemplo 0 y 1.

5. Segunda nube gris y cambio de paradigma: Las redes neuronales.

Aunque ya no son el eje, los sistemas expertos se mantienen vigentes en áreas donde se requiere un control estricto, por ejemplo, en la gestión de maquinaria industrial (automotriz, alimentos, energía, logística, inventarios, farmacéutica, química etc.). En estos sectores aún se usa este enfoque e incluso se sigue utilizando el mismo hardware por ser altamente confiable (como los PLC, que son tableros de control que todavía están en los pisos de producción). Sin embargo, en otras áreas que tienen sistemas más flexibles, se puede observar que por la rigidez de sus reglas que no aprenden de sus propios errores, tampoco tienen un "sentido común" para manejar situaciones fuera de su programación y el alto costo de mantener actualizadas sus bases de datos. Por ello, la industria militar y los gobiernos en general retiraron los fondos de investigación a la IA "simbólica", así como veinte años antes habían retirado los fondos a la IA "conexionista".

Las reglas rígidas escritas por humanos ya no son el camino a seguir y esa investigación se dejó de lado. La experiencia de un experto no seguía siendo absolutamente válida si las reglas cambian, o si el sistema va cambiando respecto al tiempo. La cantidad y calidad de datos, y la capacidad de poderlos compartir, se vuelve crucial. Con la llegada de internet fue posible dar este paso.

6. El auge de las computadoras y el origen de Big Data.

Para conocer algo se requieren datos confiables, para la etapa actual del desarrollo de la IA, mientras más datos confiables se tengan, es mejor. Esta oportunidad se abrió en 2005 en los Estados Unidos. Se estima que el 63% de la población ya contaba con acceso a Internet, mientras que en México dicha cifra era de aproximadamente el 10% de la población. Desde el inicio de la humanidad hasta el año 2003 la humanidad había generado en toda su historia 5 exabytes ($5x10^{18}$ bytes).

En los primeros seis meses de 2026 se estima que toda la información creada, capturada, copiada y consumida son 221 zettabytes ($2{,}21x10^{23}$ bytes). En los primeros seis meses se han generado 44 mil veces más información de la creada por los humanos hasta inicios de este siglo. De hecho, el volumen de datos en el mundo se duplica aproximadamente cada tres años. Es importante mencionar que cantidad no es lo mismo que calidad, y que la calidad depende de la opinión y necesidades de la persona que consulta la información. Los sistemas tradicionales son incapaces de procesar esta cantidad descomunal de información, por esta razón surgió el llamado *Big Data*, que se dedica al manejo de grandes volúmenes de datos. Hay una analogía muy conocida que la describe bien: Los datos son el petróleo crudo que internet produce y el *Big Data* es la refinería computacional que permite extraer su valor. Para conocer los inicios del *Big Data* habrá que retroceder en el tiempo una vez más. Sobre lo narrado en los siguientes párrafos se puede encontrar más en varias fuentes, principalmente [Laney, 2017] y [Laney, 2022]

A inicios de la década de los setenta, Douglas "Doug" Laney, un niño de Chicago, soñaba con ser fotógrafo profesional, le encantaba capturar imágenes y hacer composiciones con el entorno de tal forma que la imagen expresara una idea o un sentimiento,

así transcurrió toda esa década hasta que, en 1980, cuando tenía 13 años, Doug descubrió las computadoras y descubrió su potencial para modificar imágenes, para él, la computadora eran una herramienta que permitía que fuera más creativo y ser mejor artista.

Sabiendo el valor de la computación, continuó con este hobby que le estaba redituando un poco de dinero, lo que lo hizo consciente de la importancia de los negocios, en esos años participó activamente en la organización *Junior Achievement* que buscaba preparar a los jóvenes al mundo empresarial.

Cuando llegó el momento de escoger licenciatura, Dough tenía muy cerca la Universidad de Illinois Urbana Champaign, una de las más prestigiosas para estudiar computación en todo Estados Unidos y que además su matrícula era muy accesible: aproximadamente 600 dólares por semestre. Originalmente, Laney quería estudiar matemáticas y ciencias de la computación, pero descubrió que había al menos dos problemas graves en el plan de estudios: la carrera se enfocaba solamente en código y hardware, porque en esos años los sistemas expertos tomaban la experiencia de humanos y simplemente la automatizaban, no se necesitaban datos. Por otra parte, las carreras de negocios no consideraban que la computación y los datos generados pudieran tener algún beneficio tecnológico.

Como buen artista que era, lo resolvió de una manera muy creativa: decidió matricularse en la licenciatura de Artes Liberales y Ciencias, que le daba libertad de cursar casi cualquier asignatura que se impartiera en la universidad. De esta forma, hizo un plan de estudios que mezclaba administración de empresas y computación, con este plan educativo personalizado, obtuvo su licenciatura en 1986. La Universidad de Illinois notó que Doug había resuelto un problema de vinculación de los egresados de computación con el mundo empresarial. Un par de años después la universidad tomó como mapa curricular el plan de estudios que cursó Doug Laney.

Después de adquirir una amplia experiencia en informática e involucrarse en *Big Data* (que a inicios de la década de los 2000 empezaban a proliferar datos masivos), Douglas desarrolló y publicó un reporte [Laney, 2001] donde enfatizaba tres características a considerar de los datos modernos las llamó las 3 Vs: *volumen*, porque la cantidad de información generada en el siglo XXI será masiva, (como ahora se constata), dicha información se debe procesar a una gran *velocidad*, porque los datos se actualizan constantemente y tendrá una gran *variedad* (ya no son datos con una estructura clara, (como pasa con la información de una hoja de cálculo, por ejemplo), sino que nos enfrentamos a información fragmentada, de distintas calidades, que involucra analizar imágenes, textos, sonidos, etc.

Ya se mencionó el volumen de datos que se tienen actualmente. Hablemos ahora de la velocidad para procesarlos. Los juegos de video suelen ser muy demandantes para la generación de imágenes, esto se puede constatar desde la consola Atari 2600, la cual, para generar las imágenes para la televisión y su sonido asociado, tenía un solo procesador especializado, el *TIA (Television Interface Adaptor)*, los gráficos fueron revolucionarios para ese año (1977). Hay una larga lista de consolas especializadas en juegos

de video (NES, Sega, Genesis, Super Nintendo, Play Station, Nintendo 64, Xbox y un largo, largo etcétera), pero haremos referencia a una tarjeta de gráficos, muy usada en computadoras personales orientadas a videojuegos (y actualmente a entrenamiento de redes neuronales) que revolucionó la forma de ver la generación de gráficos por computadora: la tarjeta NVIDIA.

Durante la década de los noventa, tres ingenieros de Silicon Valley: Jensen Huang (Inmigrante taiwanés, ingeniero en LSI Logic), Chris Malachowsky (descendiente de la nobleza de Polonia por origen y diseñador de microchips por convicción en Sun Microsystems) y Curtis Priem (de ascendencia franco-alemana e ingeniero legendario que había hecho el primer chip gráfico para las computadoras IBM PC y que en ese momento trabajaba en Sun Microsystems), solían desayunar en un restaurante de la cadena Denny's de la ciudad de San José. Les gustaba mucho el lugar porque el café era ilimitado, los gabinetes eran amplios, la comida barata y dos dejaban quedarse todo el tiempo que quisieran. Se presenta a continuación una simplificación de la historia que se puede encontrar dispersa en varios lados, recomendamos el libro [Kim, 2024]

Durante el frío y extremadamente lluvioso inicio del año 1993, estos tres amigos estaban desayunando en el Denny's y discutían la limitación más grande que tenía una CPU: no podía procesar lo suficientemente rápido todas las operaciones matemáticas para procesar una imagen 3D en tiempo real, estaban muy interesados porque moverse en un entorno 3D le daría al jugador una experiencia inmersiva.

Llegaron a una conclusión muy importante: generar una imagen 3D no tenía que ser un trabajo secuencial (obtengo una entrada de datos, con ella proceso A, con el resultado proceso B, con el resultado proceso C, etc.), sino que se podía descomponer en muchos pequeños procesos en paralelo (cada proceso podría generar, por ejemplo, una línea horizontal en el monitor y otro núcleo podía hacer la línea siguiente, y al final se podrían presentar tantas líneas al mismo tiempo como núcleos disponibles). Estos núcleos aplicaban el adagio de "divide y vencerás", su poder no está en su velocidad individual, sino en su poder como grupo (procesamiento en paralelo).

Decidieron crear una empresa que se dedicara únicamente al desarrollo de estos chips con baterías de procesadores en paralelo (llamadas ahora GPU, Unidades de procesamiento gráfico), con el borrador de su propuesta, en abril del mismo año, convencieron al inversionista Don Valentine a que les dieran 2.1 millones de dólares. Querían llamar a su empresa "NV" (Next Version), pero alguien sugirió que la persona que tuviera una tarjeta de esas características sería la envidia de otros gamers (envy), así que tomaron una modificación de la palabra en latín *invidia*, y la transformaron en NVIDIA.

Tal capacidad de procesamiento en paralelo no se limita al mundo de los juegos de video, se usa en procesamiento de imágenes médicas, secuenciación de ADN y ARN, simulación de fenómenos físicos y químicos, ciberseguridad entre muchos otros. En el caso que a este artículo concierne, una GPU (o varias) puede simular el comportamiento de un cerebro, muchas neuronas en palarelo a la vez.

Por lo antes dicho, el péndulo oscila

una vez más al enfoque "conexionista" para llegar al estado actual de las cosas: ya se tiene un modelo eficiente de redes neuronales (software), ya se tiene una cantidad masiva de información para que puedan "conocer" el mundo (datos de entrada), finalmente ya describimos como una tarjeta que procese información paralelamente puede trabajar en conjunto para simular un cerebro (hardware). Con estos elementos podemos hablar de las redes neuronales actuales.

7. Redes Neuronales Profundas y la clasificación de objetos.

Con base en el trabajo de [Rumelhart, 1986], en [Hinton, 2006] se desarrolló un modelo que organiza las neuronas en diferentes capas, de la misma forma que un cocinero hace un pastel o una ensambladora arma un auto. Debido a que la información pasa de una capa a otra se les llamaron capas ocultas o "profundas". Las neuronas se dividen por lo común en 5 tipos de "equipos de trabajo":

- Capa de entrada: aquí los datos son recibidos: los píxeles de una imagen, una secuencia de datos, la información relacionada a un cuentahabiente, etc.

- Capas iniciales: el material y detectan detalles muy simples, siluetas, clasificaciones lineales, etc.

- Capas intermedias: combinan la información que colectaron las capas anteriores para identificar formas más complejas: óvalos, texturas, información de mayor orden polinomial, etc.

- Capas finales: juntan estas clasificaciones complejas y ponderan que es importante y que no, y logran homogeneizar en unas cuantas neuronas la información procesada con anterioridad,

- Capa de salida: Se entrega un resultado con una cierta probabilidad.

Cuando alguien se refiere a las capas profundas de una red neuronal, se refiere a las capas iniciales, intermedias y finales, se dejan fuera del conteo las capas de entrada y de salida.

Aunque los conceptos de aprendizaje profundo eran prometedores, no existía una base de datos adecuada para poder entrenar las redes neuronales en datos reales (entre otras cosas, que fuera una base de datos lo suficientemente grande y sin errores). En 2009, la doctora Fei-Fei Li de la Universidad de Stanford creó la base de datos *ImageNet*, la cual consiste en 14 millones de imágenes etiquetadas individualmente en 20 mil categorías (árbol, gato, humano, martillo, etc.). De esta base de datos se seleccionó un subconjunto de 1.2 millones de imágenes con mil categorías y un año después se lanzó un concurso de visión por computadora, el ILSVRC[14], cuyo objetivo era identificar correctamente el objeto etiquetado en la imagen o cometer un error "Top 5", por ejemplo, confundir un caballo con algo parecido, digamos, un perro (que es otro mamífero en cuatro patas). Durante los primeros años la tasa de error estaba por encima del 25%.

Fue hasta el año de 2012 en que Krizhevsky y sus colaboradores desarrollaron la red neuronal AlexNet [Krizhevsky, 2012], una red profunda de 8 capas, logrando una tasa de error del 15.3%, que ya es comparable con la tasa de error de un humano común.

[14]ImageNet Large Scale Visual Recognition Challenge o Reto de Reconocimiento Visual a Gran Escala usando ImageNet.

Tres años después, Microsoft publicó su propia arquitectura de red [He, 2016], con 152 capas profundas que redujo el error a 3.5%, el cual ya es un valor inferior a la tasa de error de un humano experto.

Los ejemplos anteriores de este capítulo son del uso de redes neuronales aplicadas al llamado aprendizaje automático (*machine learning*) discriminativo, porque lo que busca es clasificar información a partir de datos de entrada. En la siguiente sección se describirán las redes neuronales aplicadas a generar nuevo conocimiento.

8. La inteligencia artificial generativa.

Este tipo de IA, actualmente se basa en redes neuronales tipo *transformer* (que tienen una topología más compleja que el modelo de capas y busca paralelizar el entrenamiento de la red neuronal) comenzó en el año 2017 con un artículo de la empresa Google [Vaswani, 2017] que permitía procesar secuencias gigantescas de datos en paralelo y haciendo énfasis (prestando atención) en el contexto global de un texto.

Este artículo puso las bases de los modelos grandes de lenguaje, que están diseñados para procesar, comprender y generar lenguaje humano, son modelos cuyos nombres ahora son bien conocidos: empezó con OpenAI y GPT3 en 2020 y DALL-E el año siguiente. Actualmente, hay una explosión de estos modelos grandes de lenguaje: ChatGPT, Gemini, Claude, DeepSeek, Llama, Grok y un larguísimo etcétera. Su utilidad es innegable porque se usan en generar respuestas de preguntas concretas, traducción de textos, corrección de estilo e incluso generación de código de programación.

Hay dos cosas que causan cierta aversión en la gente: Por un lado, la opacidad de las redes neuronales profundas, ya que nadie las entiende por completo, porque pertenecen a los llamados "modelos de caja negra"[15] que con una entrada de información da una salida muchas veces asombrosa, pero incluso los expertos no saben exactamente cómo funciona. Por otra parte, se comportan como un superhumano, por lo general con características impecables en sus resultados y velocidades de respuesta imposibles para cualquier persona. Estas características no humanas nos hacen percibir un sentimiento de uncanny valley similar a lo presentado en la novela de *Frankenstein:* Un monstruo hermoso que se ha vuelto impredecible.

Conclusiones: ¿Dónde nos encontramos ahora?

El conocimiento es una responsabilidad profundamente humana. En el momento que separamos el conocimiento de la experiencia viva y de la empatía humana, nos volvemos autómatas y la ciencia deja de ser un instrumento de liberación para convertirse en uno de tiranía.

Jacob Bronowski -The Ascent of Man (1973)

He tenido un presentimiento... cuando los impresionantes poderes tecnológicos estén en manos de unos pocos, y nadie que represente el interés

[15]Se les llama así en contraste con los sistemas de caja blanca, donde se conocen y se pueden ver todos sus elementos internos, su funcionamiento y sus reglas. Se explica de forma clara por qué se obtiene un resultado específico.

público pueda comprender siquiera los problemas: cuando, aferrados a nuestros cristales y a nuestros horóscopos, con las facultades críticas en declive, incapaces de distinguir entre lo que se siente bien y lo que es verdad, nos deslicemos nuevamente, casi sin darnos cuenta a la superstición y la obscuridad.

Carl Sagan -The Demon-Haunted World (1995)

Actualmente, se dice mucho que vivimos una era de posverdad[16], donde las opiniones maniqueas, radicales y principalmente viscerales son lo más común. El enfoque conexionista de la IA, las llamadas redes neuronales de "caja negra" (profundas) que no se entiende del todo, es lo que el ciudadano común suele ver. Esta actitud es el equivalente nuevo y tecnológico de los milenaristas del año 2000, que temían un juicio divino o que el sistema informático mundial se iba a colapsar durante el cambio al año 2000[17].

En redes sociales y medios de comunicación solo se enfatizan los malos usos de la IA: Estafas donde se clona la voz de un ser querido para obtener dinero. Generación de videos *deepfake* para arruinar la reputación de alguna persona o para chantajearlo. Creación de usuarios falsos que apoyan o atacan a un artista o político famoso.

Pero poco se habla de que el análisis de imágenes permite predecir el comportamiento de incendios, huracanes y fenómenos meteorológicos con días de anticipación para hacer planes de contingencia, se usa para la optimización de redes de distribución eléctrica para reducir el consumo cuando hay disponibles otras fuentes de energía (solar, eólica, etc.). Está el *Vesuvius Challenge*, [Angelotti, 2026] que ya ha permitido leer una parte de los 1,800 rollos calcinados de papiro que se encontraron en la ciudad de Herculano, en después de la explosión del Vesubio que la sepultó bajo 6 metros de ceniza ardiente[18]. En medicina preventiva, se estudian los historiales clínicos de miles de pacientes y se descubren relaciones de enfermedades que antes resultaban imposibles de determinar. En el terremoto de 2026 en Venezuela, gracias a un sistema experimental de Android Google basado en movimientos anómalos de millones de celulares en la región de la Guaira, se logró lanzar una alerta temprana que le dio entre 5 y 30 segundos de ventaja a la gente que estaba a unos cientos de kilómetros del epicentro, por ejemplo, en la ciudad de Caracas[19]. Estos ejemplos en que nuestra vida puede ser mejor gracias a esta nueva tecnología.

Se puede argumentar mucho sobre si la inteligencia artificial es "buena" o "mala", pero es erróneo darle atributos morales a una herramienta. Un martillo se puede usar para construir una casa, o para asesinar a alguien, al final del día, depende del ser humano que se encuentra detrás. El uso de esta tecnología abre una gran discusión ética, sobre las intenciones de los humanos

[16]La posverdad es la distorsión intencional de la realidad donde las emociones y creencias personales son más importantes que los datos reales, busca manipular tu opinión sin que sea ya relevante que algo sea cierto o falso.

[17]De hecho el 29 de marzo del 2000 una parte del sistema informático mundial (especialmente bancos, instituciones financieras y gobiernos) se colapsó por un error del tipo Y2K. Esta última afirmación va en contra de la "narrativa más aceptada sobre el Y2K" que tiene un discurso triunfalista que busca minimizar los problemas que hubo en varios países durante todo ese año, pero esa, es otra historia.

[18]Este trabajo está hecho con escaneos de alta resolución en rayos X de los rollos. Esta biblioteca es la única del mundo clásico que ha sido preservada en su integridad.

[19]https://www.nytimes.com/interactive/2026/06/27/world/americas/venezuela-earthquakes-android-alerts.html

que están detrás, que requiere su propia reflexión y bien puede ser otro artículo.

Referencias

[1] [Angelotti, 2026] Angelotti, G., Parsons, S., Nicolardi, F., Nader, Y., Johnson, S., Josey, D., Henderson, P., Schilling, H., Rudolph, J., McDonald, F., Dal Prá, E. R., Tafforeau., P., Mirone, A., Parker, C. S., Posma, J. P., Kyles, B., Vergara, C., Lavorante, A., Villa, R., . . . Seales, W. B. (2026). Complete virtual unwrapping and reading of a rolled Herculaneum papyrus. Vesuvius Challenge. https://scrollprize.org/pdf/main.pdf

[2] [Bain, 1873] Bain, A. (1873). Mind and body: The theories of their relation. D. Appleton and Company. https://archive.org/details/mindbodytheories00bain

[3] [Boole, 1854] Boole, G. (2009). An Investigation of the Laws of Thought. Cambridge University Press. (Obra original publicada en 1854).

[4] [Cobos, 2010] De los Cobos Silva, S. G., Goddard Close, J., Gutiérrez Andrade, M. Á. y Martínez Licona, A. E. (2010). Búsqueda y exploración estocástica. Universidad Autónoma Metropolitana. a. https://libroscbi.izt.uam.mx/index.php/lcbi/catalog/view/99/74/443

[Gugerty, 2006] Gugerty, L. (2006). Newell and Simon's Logic Theorist: Historical Background and Impact on Cognitive Modeling. Proceedings of the Human Factors and Ergonomics Society Annual Meeting, 50(9), 880–884. https://www.researchgate.net/publication/276216226_Newell_and_Simon's_Logic_Theorist_Historical_Background_and_Impact_on_Cognitive_Modeling

[5] [He, 2016] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770–778. https://doi.org/10.1109/CVPR.2016.90

[6] [Hinton, 2006] Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. Science, 313(5786), 504–507. https://doi.org/10.1126/science.1127647

[7] [Kim, 2024] Kim, T. (2024). The Nvidia Way: Jensen Huang and the making of a tech giant. W. W. Norton & Company.

[8] [Krizhevsky, 2012] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems, 25, 1097–1105. https://cvml.ista.ac.at/courses/DLWT_W17/material/AlexNet.pdf

[9] [Laney, 2001] Laney, D. B. (2001). 3D Data Management: Controlling data volume, velocity and variety [Research Note]. META Group.

[10] [Laney, 2017] Laney, D. B. (2017). Infonomics: How to monetize, manage, and measure information as an asset for competitive advantage (1.ª ed.). Routledge. https://doi.org/10.4324/9781315108650

[11] [Laney, 2022] Laney, D. B. (2022). Data Juice: 101 stories of how organizations are squeezing value from available data assets. Douglas B. Laney

[12] [Lighthill, 1973] Lighthill, J. (1973). Artificial intelligence: A general

survey. En J. Lighthill, N. S. Sutherland, R. M. Needham, H. C. Longuet-Higgins, & D. Michie (Eds.), Artificial Intelligence: A Paper Symposium (pp. 1–21). Science Research Council of Great Britain. https://rodsmith.nz/wp-content/uploads/Lighthill_1973_Report.pdf

[13] [Minsky, 1969] Minsky, M., & Papert, S. (1969). Perceptrons: An Introduction to Computational Geometry. MIT Press. https://mitpress.mit.edu/9780262630221/perceptrons/

[14] [McCarthy, 1955] McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. E. (1955). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. Stanford University. a. http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf

[15] [McCulloch, 1943] McCulloch, W.S., Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics* 5, 115–133. a. https://doi.org/10.1007/BF02478259

[16] [Newell, 1956] Newell, A., & Simon, H. A. (1956). The Logic Theory Machine: A Complex Information Processing System (Paper P-868). RAND Corporation. a. https://www.rand.org/pubs/papers/P868.html

[17] [Newell, 1957] Newell, A., Shaw, J. C., & Simon, H. A. (1957). Empirical explorations of the logic theory machine: A case study in heuristic (Reporte técnico). Rand Corporation / Carnegie Institute of Technology. https://iiif.library.cmu.edu/file/Newell_box00028_fld01976_doc0005/Newell_box00028_fld01976_doc0005.pdf

[18] [Rosenblatt, 1958] Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review, 65(6), 386–408. https://doi.org/10.1037/h0042519 https://homepages.math.uic.edu/\~lreyzin/papers/rosenblatt58.pdf

[19] [Rumelhart, 1986] Rumelhart, D. E., Hinton, G. E. y Williams, R. J. (1986). Learning representations by back-propagating errors. Nature, 323(6088). https://www.iro.umontreal.ca/\~vincentp/ift3395/lectures/backprop_old.pdf

[20] [Solomonoff, 1956] Solomonoff, R. (1956). Notebook y Box A [Notas de campo manuscritas no publicadas]. Dartmouth AI Archives. Archivo oficial de Ray Solomonoff. a. https://raysolomonoff.com/dartmouth/

1 [Vaswani, 2017] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. Advances in Neural Information Processing Systems, 30, 5998–6008. https://arxiv.org/abs/1706.03762. https://arxiv.org/abs/1706.03762

Evolución del esfuerzo salarial para adquirir una vivienda en México, 2005–2024



Dr. Sergio Gerardo de los Cobos Silva*
Dr. Miguel Ángel Gutiérrez Andrade*
Dr. Eric Alfredo Rincón García*
Dr. Roman Anselmo Mora Gutiérrez**
Dr. Pedro Lara Velázquez*
MC Alma Edith Martínez Licona*
Dra. Fabiola Margarita Martínez Licona*
Dr. Edwin Montes Orozco***

*Departamento de Ingeniería Eléctrica, Universidad Autónoma Metropolitana, Unidad Iztapalapa
**Departamento de Sistemas, Universidad Autónoma Metropolitana, Unidad Azcapotzalco
***Departamento de Computación, Electrónica y Mecatrónica, Universidad de las Américas Puebla

Imagen creada con IA generativa — OpenAI / ChatGPT

Abstract

Homeownership is one of the primary mechanisms through which households accumulate wealth and achieve long-term economic security. However, the relationship between labor income and housing prices in Mexico has changed substantially over the past two decades. This study examines the evolution of the housing affordability burden between 2005 and 2025 by estimating the number of years of full salary required to purchase an average home across different occupational groups using data from the National Occupation and Employment Survey (ENOE). Real wages were adjusted for inflation using the National Consumer Price Index, while housing prices were estimated from the Mexican Federal Mortgage Society (SHF). To distinguish housing-specific dynamics from general changes in the cost of living, income poverty thresholds published by CONEVAL were also analyzed. Results show a widespread increase in the years of income required to acquire a home, whereas the real poverty threshold remained nearly unchanged over the same period. These findings indicate that declining housing affordability is primarily driven by housing market dynamics rather than by a generalized increase in the cost of living, highlighting a growing disconnect between labor income and the capacity to accumulate wealth through homeownership.

Keywords: Housing affordability, Housing market, Labor income, Wealth accumulation.

Resumen

La adquisición de una vivienda propia constituye uno de los principales mecanismos mediante los cuales los hogares acumulan riqueza y alcanzan seguridad económica a largo plazo. Sin embargo, la relación entre los ingresos laborales y los precios de la vivienda en México ha cambiado sustancialmente en las últimas dos décadas. Este estudio examina la evolución de la carga económica que representa el acceso a la vivienda entre 2005 y 2025, mediante la estimación del número de años de salario íntegro necesarios para adquirir una vivienda de precio promedio en distintos grupos ocupacionales, a partir de datos de la Encuesta Nacional de Ocupación y Empleo (ENOE). Los salarios reales se ajustaron por inflación utilizando el Índice Nacional de Precios al Consumidor, mientras que los precios de la vivienda se estimaron con datos de la Sociedad Hipotecaria Federal (SHF). Para distinguir las dinámicas específicas del mercado de la vivienda de los cambios generales en el costo de vida, también se analizaron las líneas de pobreza por ingresos publicadas por el Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL). Los resultados muestran un aumento generalizado del número de años de ingresos necesarios para adquirir una vivienda, mientras que el umbral real de pobreza se mantuvo prácticamente sin cambios durante el mismo periodo. Estos hallazgos indican que el deterioro de la asequibilidad de la vivienda está impulsado principalmente por las dinámicas del mercado inmobiliario, más que por un incremento generalizado del costo de vida. Esto pone de manifiesto una creciente desconexión entre los ingresos laborales y la capacidad de acumular riqueza mediante la adquisición de una vivienda propia.

Palabras clave: Accesibilidad habitacional, Mercado de vivienda, Ingresos laborales, Formación de patrimonio.

1. Introducción

Para muchas familias mexicanas, adquirir una vivienda propia representa una de las metas económicas más importantes de su vida. Además de proporcionar un lugar donde vivir, una vivienda constituye el principal mecanismo de formación de patrimonio y una fuente de estabilidad financiera para el futuro. Sin embargo, durante las últimas décadas se ha extendido la percepción de que este objetivo resulta cada vez más difícil de alcanzar. Aun cuando los salarios nominales han aumentado con el tiempo, también lo han hecho los precios de las viviendas, lo que plantea una pregunta fundamental: ¿Realmente ha disminuido la capacidad de los trabajadores para comprar una casa?

Responder esta pregunta requiere algo más que comparar salarios o precios de distintos años. Tanto los ingresos como el valor de los bienes cambian continuamente debido a la inflación, por lo que las cifras nominales[1] pueden conducir a interpretaciones erróneas. Es necesario expresar todas las cantidades en una misma unidad monetaria para evaluar si el poder adquisitivo de los trabajadores ha mejorado o se ha deteriorado con el paso del tiempo.

Con ese propósito, este estudio analiza la evolución de la relación entre los ingresos laborales y el precio de la vivienda en México durante el periodo 2005–2025. El análisis se basa en información de la Encuesta Nacional de Ocupación y Empleo (ENOE) del Instituto Nacional de Estadística y Geografía (INEGI) (INEGI, 2025a), en las series históricas del mercado inmobiliario publicadas por la Sociedad Hipotecaria Federal (SHF) (Sociedad Hipotecaria Federal, 2025) y en la línea de pobreza por ingresos estimada por el Consejo Nacional de Evaluación de la Política de Desarrollo Social (CONEVAL) (CONEVAL, 2025). La combinación de estas fuentes permite evaluar si el acceso a la vivienda ha evolucionado de manera similar al costo general de vida o si, por el contrario, constituye un fenómeno económico particular.

Para cuantificar esta relación se emplea el esfuerzo salarial habitacional, un indicador que estima el número de años de salario íntegro que una persona tendría que destinar para adquirir una vivienda promedio:

$$\text{Años de esfuerzo} = \frac{\text{Precio de la vivienda}}{\text{Salario mensual real} \times 12} \quad (1)$$

Este indicador supone que la totalidad del ingreso anual se dedica exclusivamente a la compra de la vivienda. Aunque este escenario no representa la realidad de los hogares, constituye una medida estandarizada que permite comparar, de manera consistente, la evolución histórica de la accesibilidad habitacional entre distintos grupos ocupacionales y periodos de tiempo. Un incremento del indicador implica que la vivienda se ha vuelto menos accesible, mientras que una disminución refleja una mayor capacidad de los trabajadores para convertir sus ingresos en patrimonio.

En las secciones siguientes se describe la metodología empleada para estimar salarios y precios en términos reales, se analiza la evolución del mercado inmobiliario y, finalmente, se evalúa

[1] Las cifras nominales son valores económicos expresados en precios corrientes o unidades monetarias del momento en que se calculan, **sin descontar ni ajustar por el efecto de la inflación**. Reflejan el valor monetario actual, pero no el poder adquisitivo real.

cómo ha cambiado el esfuerzo necesario para adquirir una vivienda en México durante las últimas dos décadas.

2. Metodología para medir la accesibilidad habitacional

Para evaluar si adquirir una vivienda se ha vuelto más fácil o difícil con el paso del tiempo, es indispensable comparar salarios y precios en condiciones equivalentes. Las cantidades monetarias observadas en distintos años no son directamente comparables, ya que tanto los ingresos como el costo de los bienes cambian debido a la inflación. Por esta razón, todas las cifras utilizadas en este estudio fueron expresadas en pesos reales de 2025 (base 2005)[2] mediante el Índice Nacional de Precios al Consumidor (INPC) publicado por el INEGI (INEGI, 2025b).

Este procedimiento, conocido como deflactación, elimina el efecto de la inflación y permite distinguir entre incrementos nominales, provocados únicamente por el aumento general de los precios, y cambios reales en el poder adquisitivo de los trabajadores o en el valor de la vivienda. Gracias a ello es posible comparar, bajo una misma escala monetaria, salarios percibidos en distintos años y evaluar su capacidad efectiva para adquirir patrimonio. Una vez expresados los salarios en pesos reales de 2025, se analizó su evolución para once grupos ocupacionales definidos en la ENOE (INEGI, 2025a).

3. Resultados

En esta sección se presentan los principales resultados del análisis. Primero se examina la evolución de los ingresos laborales, distinguiendo entre salarios nominales y salarios reales para evidenciar el efecto de la inflación sobre la interpretación de las tendencias salariales. Posteriormente se analiza el comportamiento del mercado de la vivienda y, finalmente, se integran ambas dimensiones mediante el indicador de esfuerzo salarial habitacional, con el propósito de evaluar cómo ha evolucionado la accesibilidad a la vivienda en México entre 2005 y 2025.

3.1 Evolución de los salarios

Antes de analizar el poder adquisitivo de los trabajadores es conveniente examinar la evolución de sus ingresos en términos nominales. Los salarios nominales corresponden a las remuneraciones observadas en cada año sin realizar ajustes por inflación; por tanto, reflejan el monto monetario efectivamente percibido por los trabajadores, aunque no permiten determinar si dicho ingreso conserva su capacidad de compra a lo largo del tiempo.

Las Figuras 1 y 2 muestran que los ingresos nominales presentan una tendencia creciente en todos los grupos ocupacionales. A primera vista, este comportamiento podría interpretarse como una mejora generalizada de las condiciones salariales. Sin embargo, dado que durante el mismo periodo también aumentó el nivel general de precios, las variaciones observadas no permiten concluir que exista un incremento equivalente en el poder adquisitivo.

[2]En economía y finanzas, los **valores a precios constantes** y los **reales** son prácticamente lo mismo: representan magnitudes monetarias ajustadas para eliminar el efecto de la inflación, utilizando los precios de un año base de referencia.

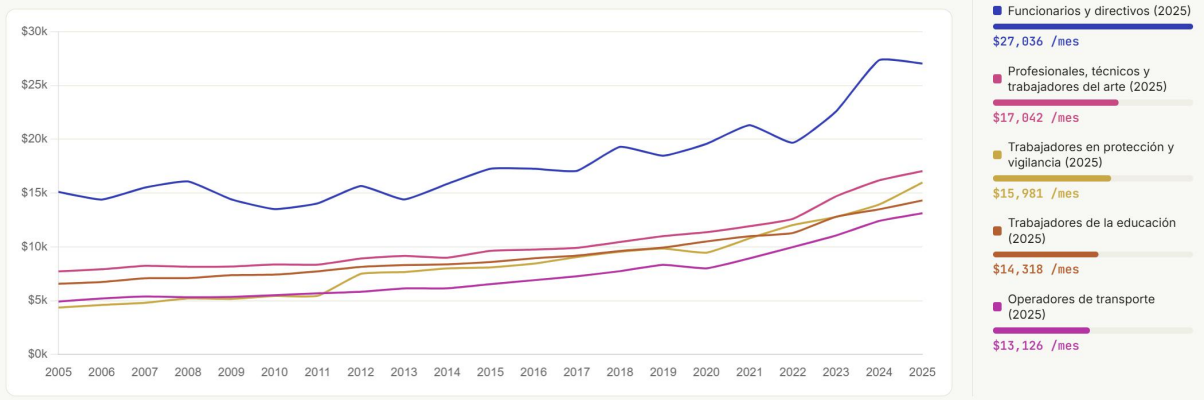

Figura 1: Ingreso nominal del 2005 al 2025, parte 1. Fuente: Propia.

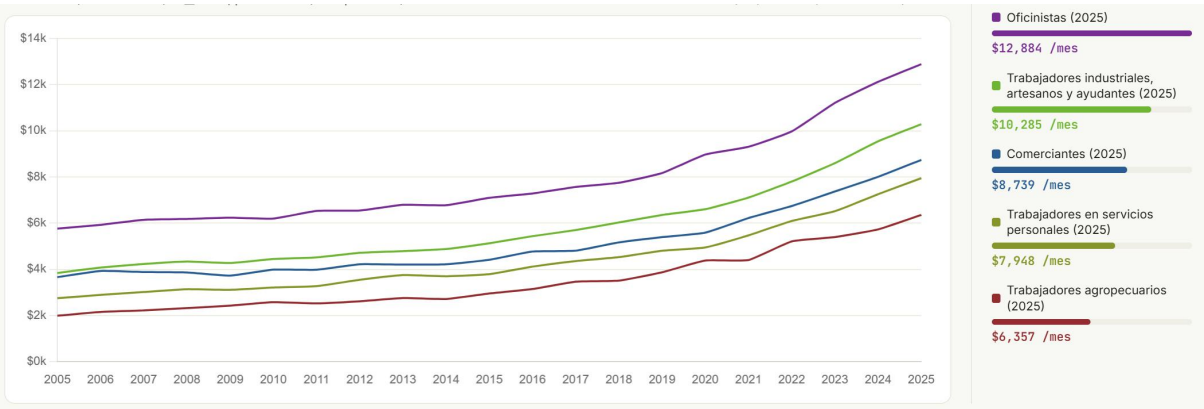

Figura 2: Ingreso nominal del 2005 al 2025, parte 2. Fuente: Propia.

Para eliminar el efecto de la inflación, los salarios fueron expresados en pesos constantes de 2025 mediante el INPC. Las Figuras 3 y 4 muestran las series históricas obtenidas. En ellas puede observarse que algunas ocupaciones experimentaron una disminución de su salario real a lo largo del periodo analizado. Por ejemplo, los funcionarios y directivos presentan una tendencia descendente, lo que indica que, una vez descontado el efecto de la inflación, sus ingresos promedio fueron mayores en los primeros años del periodo que en la actualidad. En contraste, ocupaciones como los trabajadores de protección y vigilancia muestran una recuperación de su salario real durante los años más recientes.

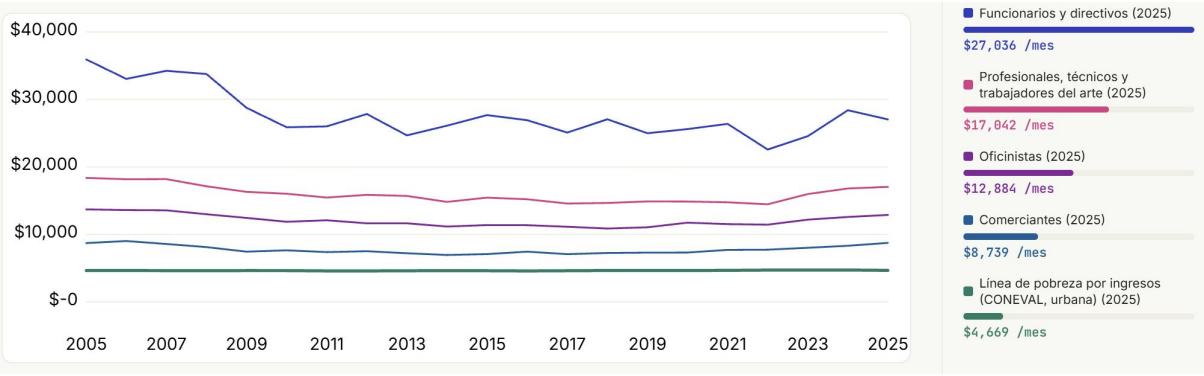

Figura 3: Deflactación de salarios al 2025, parte 1. Fuente: Propia.

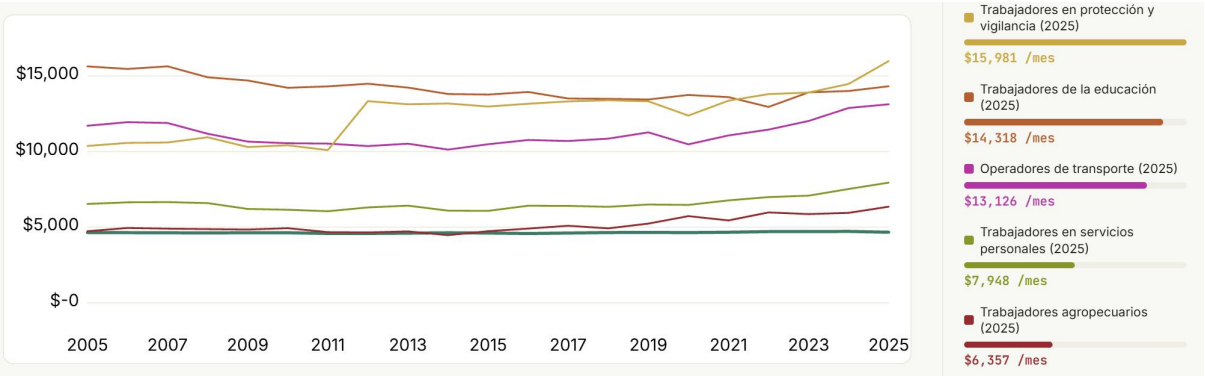

Figura 4: Deflactación de salarios al 2025, parte 2. Fuente: Propia.

Como referencia adicional, ambas figuras incluyen la línea de pobreza por ingresos estimada por el CONEVAL (CONEVAL, 2025). Este indicador representa el ingreso mínimo necesario para adquirir la canasta alimentaria y no alimentaria, e incorpora gastos esenciales como alimentación, vivienda, transporte, vestido y otros bienes básicos. La comparación permite dimensionar la posición relativa de cada grupo ocupacional respecto al umbral mínimo de bienestar económico. Resulta particularmente preocupante que los trabajadores agropecuarios permanezcan apenas por encima de esta línea durante buena parte del periodo analizado, lo que evidencia la vulnerabilidad económica que enfrenta este sector.

3.2 Evolución del precio de la vivienda

Una vez analizado el comportamiento de los salarios, el siguiente paso consiste en estudiar la evolución del mercado habitacional. Para fortalecer la confiabilidad de los resultados se recurrió a dos aproximaciones complementarias, ambas basadas en información de la SHF (Sociedad Hipotecaria Federal, 2025).

La primera utiliza el Índice SHF de Precios de la Vivienda, un indicador de calidad constante que compara inmuebles con características similares a lo largo del tiempo. Este índice elimina el efecto que podrían tener cambios en el tamaño, ubicación o calidad de las viviendas sobre la medición de los precios, permitiendo observar exclusivamente la evolución del mercado inmobiliario.

El índice SHF utiliza oficialmente como año base 2017 (=100 puntos). Para efectos de este análisis, y con el fin de comparar su evolución en la misma escala que los salarios y la línea de pobreza, se rebasó a 2005=100, año de inicio del periodo analizado. A partir de entonces, el índice aumentó hasta alcanzar 154.7 puntos en 2024, lo que refleja una tendencia alcista de largo plazo en el valor de la vivienda, con algunos periodos de estancamiento (2009–2012), pero una aceleración marcada a partir de 2015, ver Figura 5.

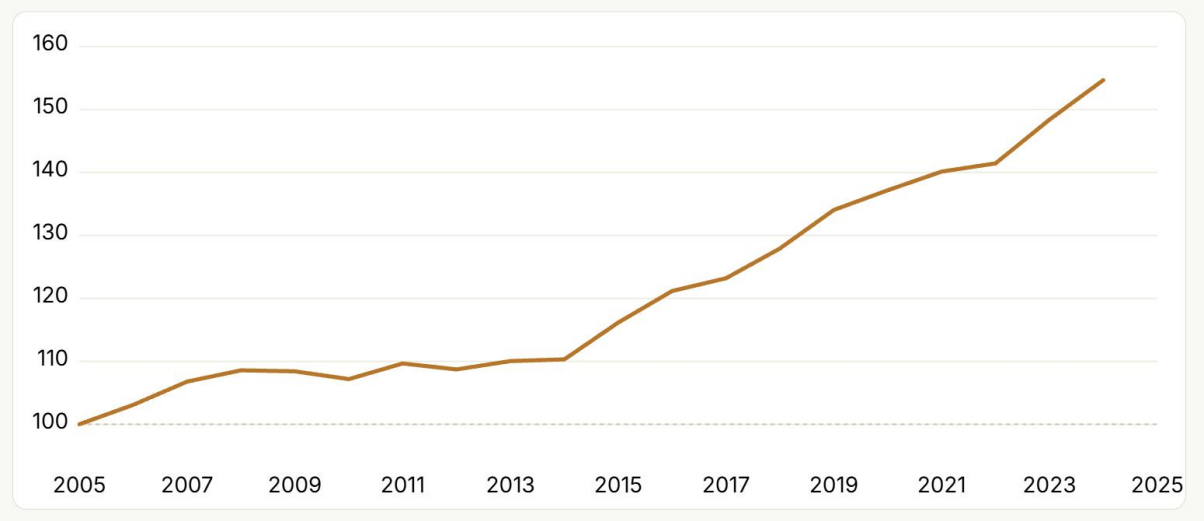

Figura 5: Crecimiento del índice SHF para vivienda. Fuente: Propia.

Aunque el índice permite identificar con claridad la evolución relativa de los precios, sus valores no están expresados en pesos. Para facilitar su interpretación y, posteriormente, su comparación con los ingresos laborales se transformó a valores monetarios utilizando como referencia el precio promedio de avalúo hipotecario de vivienda registrado en 2019, expresado en pesos constantes de 2025, como valor de anclaje, y se aplicó la variación relativa del Índice SHF para estimar los niveles correspondientes a los demás años.

De esta manera, los valores obtenidos representan precios implícitos estimados, no precios directamente observados para cada año. Bajo este procedimiento, el valor estimado de una vivienda pasó de $1,102,994 pesos de 2025 en 2005 a $1,706,043 pesos de 2025 en 2024, ver Figura 6.

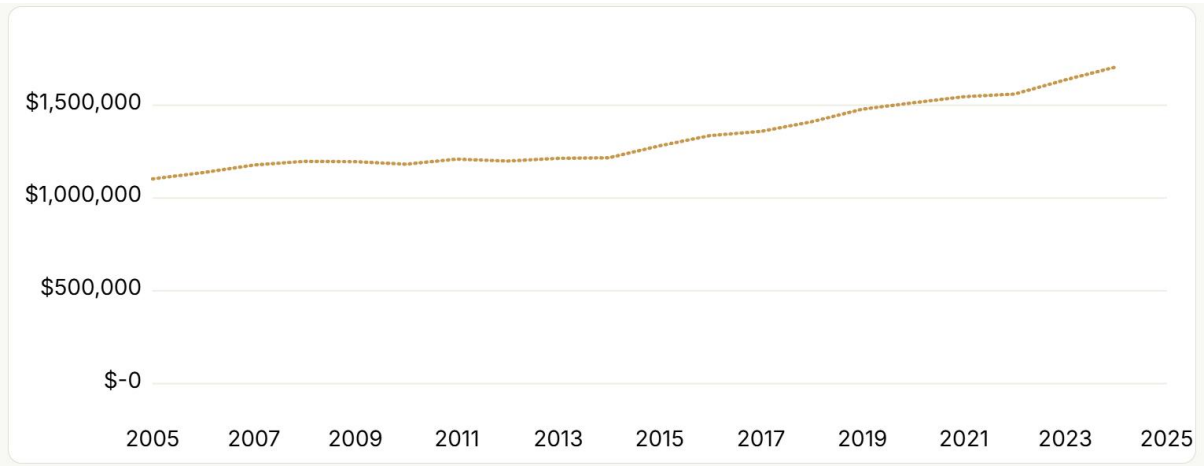

Figura 6: Crecimiento del costo promedio de la vivienda, en pesos constantes de 2025. Fuente: Propia.

Como mecanismo de validación, también se empleó una segunda fuente de información, los precios promedio observados en los avalúos hipotecarios publicados por la SHF para el periodo 2019–2025. A diferencia de la primera aproximación, estos valores corresponden a precios monetarios

observados en los avalúos y no se obtienen mediante la transformación de un índice de calidad constante. Los valores nominales fueron expresados en pesos constantes de 2025 utilizando el INPC, de modo que sean comparables con los salarios reales utilizados en el análisis.

Bajo esta segunda aproximación, el precio promedio de la vivienda pasó de $1,478,501 pesos de 2025 en 2019 a $1,863,965 pesos de 2025 en 2025.

Ambas series se presentan conjuntamente en la Figura 7. Aunque provienen de metodologías diferentes, muestran una tendencia similar de crecimiento en el precio de la vivienda, lo que proporciona mayor confianza en las estimaciones utilizadas posteriormente para calcular el esfuerzo salarial habitacional.

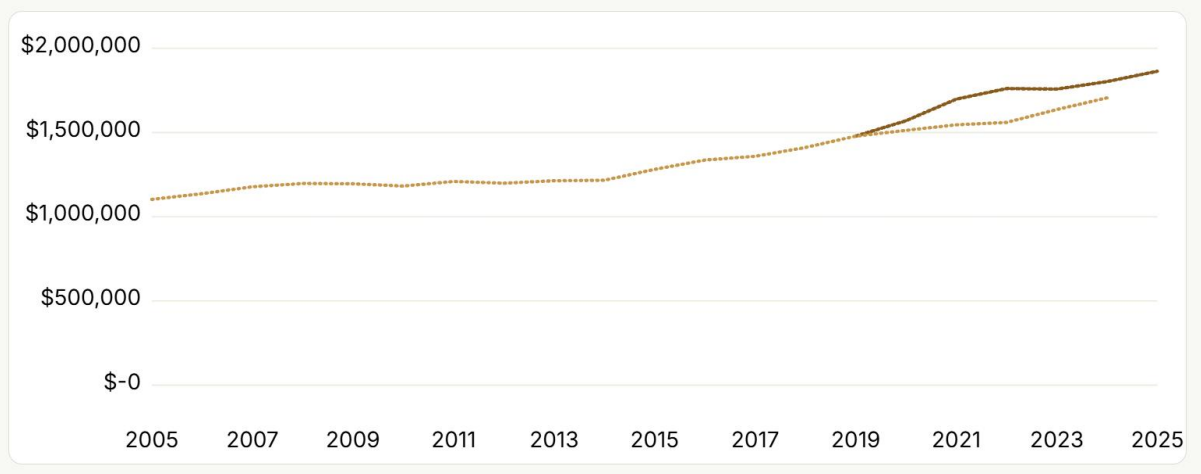

Figura 7: Comparación de las dos series de precio de vivienda, en pesos constantes de 2025. Fuente: Propia.

3.3 La creciente distancia entre salarios y vivienda

Una vez estimada la evolución de los salarios reales y del precio de la vivienda, fue posible calcular el esfuerzo salarial habitacional, entendido como el número de años de ingreso íntegro que una persona tendría que destinar para adquirir una vivienda promedio. Aunque este escenario supone, de manera hipotética, que el trabajador ahorra el 100% de sus ingresos, el indicador constituye una medida útil para comparar la accesibilidad habitacional entre distintas ocupaciones y a lo largo del tiempo.

Las Figuras 8 y 9 presentan la evolución de este indicador para los once grupos ocupacionales considerados en el estudio. En términos generales, los resultados muestran una tendencia inequívoca, la vivienda se ha vuelto progresivamente menos accesible para la mayoría de los trabajadores mexicanos. En otras palabras, el incremento del precio de la vivienda ha superado, de forma sistemática, el crecimiento de los salarios reales.

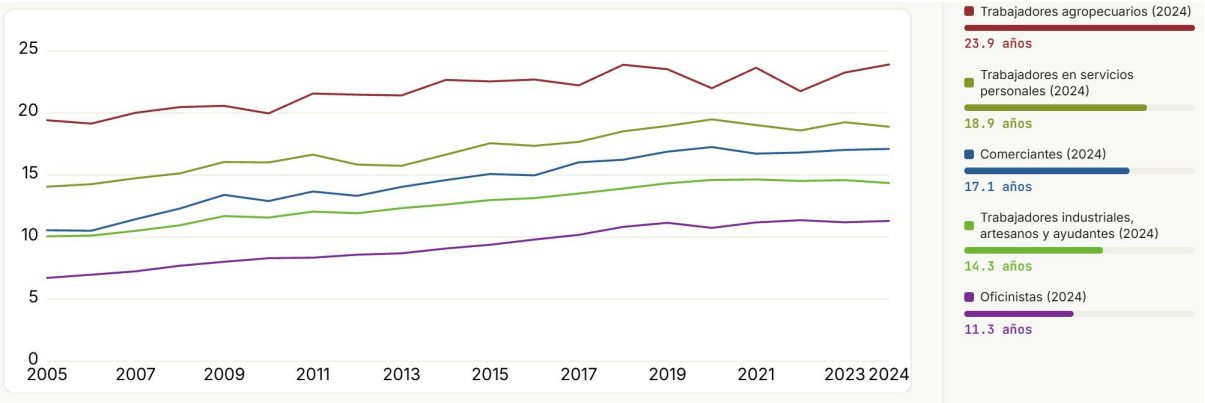

Figura 8: Esfuerzo salarial habitacional, parte 1. Fuente: Propia.

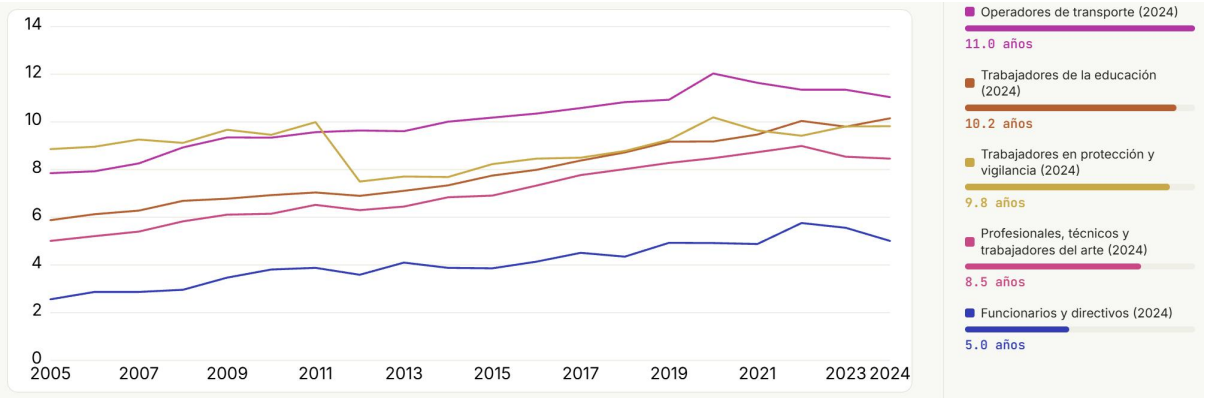

Figura 9: Esfuerzo salarial habitacional, parte 2. Fuente: Propia.

En 2024, utilizando la estimación del precio de la vivienda obtenida a partir del Índice SHF, los mayores niveles de esfuerzo correspondieron a los trabajadores agropecuarios, quienes requerían aproximadamente 23.9 años de salario íntegro para adquirir una vivienda promedio. Les siguieron los trabajadores de servicios personales, con 18.9 años, y los comerciantes, con 17.1 años.

En el extremo opuesto se ubicaron los funcionarios y directivos, con un esfuerzo estimado de 5.0 años, así como los profesionales, técnicos y trabajadores del arte, quienes necesitarían alrededor de 8.5 años de salario. La diferencia entre ambos extremos pone de manifiesto que el acceso a la vivienda depende en gran medida de la posición que cada trabajador ocupa dentro de la estructura salarial del país.

Para las diez profesiones consideradas, el tiempo requerido para comprar una vivienda aumentó entre 2005 y 2024, tanto en términos absolutos como porcentuales. En años absolutos, protección y vigilancia registra el menor incremento (1.0 año, de 8.9 a 9.8 años), mientras que comerciantes presenta el mayor (6.6 años, de 10.6 a 17.1 años). Sin embargo, al medir el incremento en términos relativos, el panorama cambia, funcionarios y directivos, que partía del menor número de años en 2005, es la categoría con el mayor deterioro proporcional, casi duplicando el esfuerzo requerido (92.3%), seguida de trabajadores de la educación (72.9%). En promedio, las diez profesiones requieren 3.9 años adicionales (51.5%) para comprar una vivienda equivalente a la de 2005.

Profesión / puesto	Años 2005	Años 2024	Diferencia (años)	Crecimiento (%)
Trabajadores agropecuarios	19.4	23.9	4.5	23.2
Trabajadores en servicios personales	14.1	18.9	4.8	34.0
Comerciantes	10.6	17.1	6.6	61.3
Trabajadores industriales, artesanos y ayudantes	10.1	14.3	4.3	41.6
Oficinistas	6.7	11.3	4.6	68.7
Operadores de transporte	7.8	11	3.2	41.0
Trabajadores de la educación	5.9	10.2	4.3	72.9
Trabajadores en protección y vigilancia	8.9	9.8	1	10.1
Profesionales, técnicos y trabajadores del arte	5	8.5	3.5	70.0
Funcionarios y directivos	2.6	5	2.4	92.3

Tabla 1: Años de salario requeridos para adquirir una vivienda por profesión, 2005 y 2024, y variación absoluta y porcentual. Fuente: Propia.

Más allá de las diferencias entre ocupaciones, el resultado más relevante es la evolución del indicador a lo largo del tiempo. En prácticamente todos los grupos analizados se observa una tendencia creciente en el esfuerzo requerido para adquirir una vivienda. Esto significa que, aun cuando algunos sectores experimentaron incrementos en sus salarios reales, dichos aumentos fueron insuficientes para compensar el acelerado crecimiento del mercado inmobiliario.

En consecuencia, la distancia entre ingresos laborales y precios de la vivienda se ha ampliado de forma sostenida durante las últimas dos décadas. Esta separación representa una pérdida progresiva de accesibilidad habitacional y dificulta que amplios sectores de la población puedan transformar sus ingresos en patrimonio.

3.4 Validación mediante precios observados de avalúos hipotecarios

Con el fin de verificar que estos resultados no dependieran exclusivamente del método utilizado para estimar el precio de la vivienda, el esfuerzo salarial también se calculó utilizando la serie de precios promedio observados en los avalúos hipotecarios publicados por la Sociedad Hipotecaria Federal.

Los resultados obtenidos mantienen prácticamente el mismo comportamiento, ver Figuras 10 y 11. Para 2025, los trabajadores agropecuarios requerían alrededor de 24.4 años de salario para adquirir una vivienda promedio, mientras que los trabajadores de servicios personales necesitaban 19.5 años y los comerciantes 17.8 años. En contraste, los funcionarios y directivos continuaban siendo el grupo con menor esfuerzo habitacional, con aproximadamente 5.8 años.

La estrecha coincidencia entre ambas metodologías constituye un elemento importante de validación. Aunque una estimación se basa en un índice de precios de calidad constante y la otra en valores observados de avalúos hipotecarios, ambas conducen a la misma conclusión: la accesibilidad a la vivienda ha disminuido de manera sostenida y el incremento del esfuerzo salarial habitacional no es un artefacto del método de estimación empleado, sino una característica consistente del mercado inmobiliario mexicano.

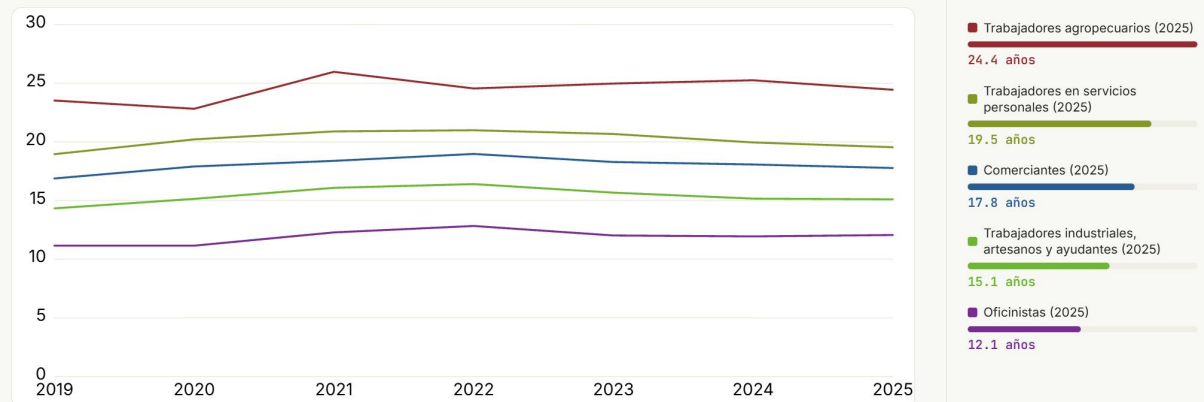

Figura 10: Esfuerzo salarial habitacional con avalúo hipotecario, parte 1. Fuente: Propia.

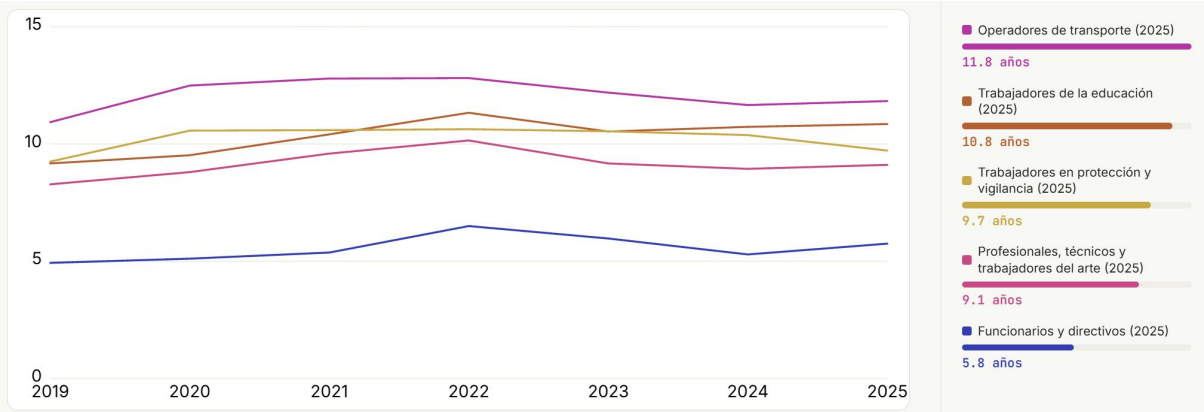

Figura 11: Esfuerzo salarial habitacional con avalúo hipotecario, parte 2. Fuente: Propia.

4. Vivienda y costo general de vida

Los resultados presentados en el capítulo anterior muestran que el esfuerzo necesario para adquirir una vivienda ha aumentado de manera sostenida durante las últimas dos décadas. Sin embargo, antes de atribuir este comportamiento al mercado inmobiliario, es necesario responder una pregunta fundamental: ¿el incremento observado se debe simplemente a que el costo de vida en México también aumentó?

Para responder esta interrogante se utilizó la línea de pobreza por ingresos urbana estimada por el CONEVAL (CONEVAL, 2025). Este indicador representa el ingreso mínimo requerido para adquirir tanto la canasta alimentaria como la no alimentaria e incorpora gastos esenciales como alimentación, vivienda, transporte, vestido, salud y otros bienes y servicios indispensables para la vida cotidiana. Al expresarse en pesos reales, constituye una referencia adecuada para evaluar la evolución del costo general de vida.

Los resultados muestran que, una vez eliminado el efecto de la inflación, la línea de pobreza permaneció prácticamente estable durante el periodo analizado. En términos reales, pasó de $4,643 pesos mensuales en 2005 a $4,722 pesos mensuales en 2024, una variación relativamente pequeña en comparación con el incremento observado en el precio de la vivienda.

Esta diferencia es fundamental para interpretar los resultados del estudio. Si el costo general de vida hubiera aumentado en la misma magnitud que el esfuerzo salarial habitacional, podría argumentarse que la pérdida de accesibilidad es simplemente una consecuencia del encarecimiento general de la economía. Sin embargo, la estabilidad de la línea de pobreza indica que ese no es el caso.

En contraste, el precio promedio de la vivienda mostró un crecimiento sostenido muy superior al observado en los bienes y servicios que integran el consumo básico de los hogares. Mientras que el costo de la canasta esencial permaneció relativamente constante en términos reales, el mercado inmobiliario siguió una trayectoria claramente ascendente.

En consecuencia, el deterioro de la accesibilidad habitacional no puede explicarse únicamente por la inflación o por un aumento generalizado del costo de vida. La evidencia apunta a un fenómeno más específico: la vivienda ha incrementado su valor a un ritmo considerablemente mayor que los ingresos laborales y que el resto de los bienes básicos, ampliando progresivamente la distancia entre la capacidad económica de los trabajadores y el acceso a la formación de patrimonio.

Esta conclusión permite interpretar los resultados de los capítulos anteriores desde una perspectiva más amplia. El problema no radica únicamente en que algunos trabajadores perciban salarios insuficientes, sino en que el mercado de la vivienda ha seguido una dinámica propia, distinta de la observada en el resto de la economía. Como resultado, la adquisición de una vivienda se ha convertido en uno de los principales factores que limitan la acumulación de patrimonio y profundizan las diferencias económicas entre los hogares.

5. Conclusiones

El análisis realizado muestra que la accesibilidad a la vivienda en México se ha deteriorado de manera sostenida durante las últimas dos décadas. Independientemente del método utilizado para estimar el precio de la vivienda, los resultados indican que el número de años de salario necesarios para adquirir un hogar promedio ha aumentado para la mayoría de los grupos ocupacionales analizados.

La explicación de este fenómeno no radica únicamente en la inflación ni en un incremento generalizado del costo de vida. Una vez expresados los salarios y los precios en términos reales, se observa que la línea de pobreza por ingresos del CONEVAL permaneció prácticamente estable, mientras que el mercado inmobiliario siguió una trayectoria de crecimiento mucho más acelerada. En otras palabras, la vivienda dejó de evolucionar al mismo ritmo que el resto de los bienes y servicios esenciales, generando una pérdida progresiva de accesibilidad habitacional.

Este resultado tiene implicaciones que van más allá del mercado inmobiliario. La vivienda constituye el principal

mecanismo de formación de patrimonio para la mayoría de los hogares; por ello, cuando su precio crece sistemáticamente por encima de los ingresos laborales, también disminuye la capacidad de las familias para acumular riqueza y mejorar su situación económica a largo plazo. En este contexto, la desigualdad no sólo se manifiesta en las diferencias salariales, sino también en la distinta posibilidad que tienen los trabajadores de convertir sus ingresos en activos patrimoniales.

Asimismo, el estudio pone de manifiesto que las mejoras observadas en algunos salarios reales no han sido suficientes para compensar el crecimiento del precio de la vivienda. Como consecuencia, incluso aquellos grupos ocupacionales que experimentaron incrementos en su poder adquisitivo enfrentan hoy mayores dificultades para acceder a una vivienda que las generaciones anteriores.

Aunque el presente trabajo no analiza los factores que explican el comportamiento del mercado inmobiliario, los resultados son consistentes con diversos procesos económicos, demográficos y urbanos ampliamente documentados en la literatura. Entre ellos destacan el crecimiento de la población, la concentración de habitantes en las principales zonas metropolitanas, la limitada disponibilidad de suelo urbanizable, el incremento en los costos de construcción y fenómenos recientes como la gentrificación en determinadas ciudades. En conjunto, estos factores pueden contribuir a que el precio de la vivienda evolucione de manera distinta al resto de los bienes y servicios que conforman el costo de vida.

Si bien este trabajo se centra en el periodo 2005–2025 y utiliza información agregada por ocupación, los resultados abren nuevas líneas de investigación. Estudios futuros podrían incorporar diferencias regionales, tipos de vivienda, condiciones de financiamiento hipotecario o analizar cómo la evolución de las tasas de interés modifica el esfuerzo económico real que enfrentan los hogares para adquirir una vivienda.

En conjunto, la evidencia presentada permite concluir que el principal desafío para el acceso a la vivienda en México no ha sido únicamente la evolución de los salarios, sino el creciente desacoplamiento entre el mercado inmobiliario y el resto de la economía. Mientras el precio de la vivienda continúe creciendo más rápido que los ingresos laborales, el acceso al patrimonio dejará de depender únicamente del esfuerzo de los trabajadores y estará determinado, cada vez más, por las condiciones del mercado inmobiliario.

En este contexto, las políticas orientadas exclusivamente a incrementar los ingresos laborales difícilmente resolverán el problema de la accesibilidad habitacional si no se acompañan de estrategias que favorezcan una mayor oferta de vivienda, un desarrollo urbano más equilibrado y mecanismos de financiamiento que faciliten el acceso al patrimonio.

En México, el desafío ya no consiste únicamente en cuánto gana una persona, sino en qué tan lejos está ese salario de convertirse en patrimonio.

Referencias

[1] Consejo Nacional de Evaluación de la Política de Desarrollo Social. (2025). Líneas de pobreza por ingresos. https://www.coneval.

org.mx/Medicion/MP/Paginas/Lineas_Pobreza_Ingresos_Serie_1992-2024.aspx

[2] Instituto Nacional de Estadística y Geografía. (2025a). Encuesta Nacional de Ocupación y Empleo (ENOE). https://www.inegi.org.mx/programas/enoe/15ymas/

[3] Instituto Nacional de Estadística y Geografía. (2025b). Índice Nacional de Precios al Consumidor (INPC). https://www.inegi.org.mx/temas/inpc/

[4] Sociedad Hipotecaria Federal. (2025). Índices SHF de precios de la vivienda y estadísticas del mercado hipotecario. https://www.gob.mx/shf/acciones-y-programas/estadisticas-e-investigacion



Foto de Tara Winstead en pexels.com



Foto de Magda Ehlers en pexels.com