AÑO 18 VOL. 3 SEP-DIC 2026

KOMPUTER SAPIENS

Revista de Divulgación de la Sociedad Mexicana de Inteligencia Artificial

Ciudad Inteligente para combatir la obesidad sarcopénica

IA Verde: El arte de cocinar algoritmos sin calentar el planeta



ISSN 2007-0691

Editor invitado
Efrén Mezura Montes

komputersapiens.org



Kalixxotl: El arte en la portada

Título: ***Cocinando Algorítmos***

Ilustración: ***Luis Gerardo Téllez Lorenzo***

¿Qué tienen en común una receta y un algoritmo? Ambos parten de una combinación de elementos, decisiones y ajustes para llegar a un resultado. La ilustración explora esta similitud al imaginar la optimización de algoritmos como un proceso similar al de cocinar. Así como un chef combina ingredientes, prueba mezclas y ajusta cantidades, los investigadores experimentan con componentes de hardware, software, y configuraciones para encontrar combinaciones que hagan a los algoritmos más eficientes y reduzcan su impacto ambiental.

La ilustración plantea una pregunta sencilla: ¿qué combinación puede hacer que un algoritmo sea más eficiente y sostenible? Los ingredientes representan los distintos componentes que intervienen en el proceso, mientras que los personajes asumen el papel de los investigadores, quienes combinan, ajustan y experimentan. La imagen pone en primer plano el carácter experimental de la investigación: no existe una única fórmula y pequeñas modificaciones pueden hacer una gran diferencia. Cocinar se convierte así en una representación visual de este proceso de experimentar, mezclar y optimizar para dar sazón al algoritmo.

La receta no está escrita: se descubre a través de la experimentación, hasta encontrar una combinación más inteligente, eficiente y verde.

EDITORIAL

Mensaje a nuestros lectores Komputer Sapiens

Estimada comunidad lectora:

Vivimos un auge sin precedentes de la inteligencia artificial, pero pocas veces nos detenemos a entender qué hay detrás de ese término. Desde hace 18 años, esta revista mantiene un propósito claro: abrir la caja negra y mostrar, con lenguaje accesible pero riguroso, cómo funcionan estos sistemas. Exploremos juntos si el miedo apocalíptico tiene fundamento o el entusiasmo ciego es exagerado, y comprendamos tanto su potencial como sus límites.

Creemos que la alfabetización tecnológica es hoy tan necesaria como la alfabetización básica. Entender qué es un algoritmo, cómo se entrena un modelo o por qué la IA a veces se equivoca nos permite tomar decisiones más informadas, tanto individuales como colectivas. Cada número es una invitación a preguntar, cuestionar, reflexionar y aprender juntos.

Gracias por acompañarnos en este viaje hacia un mundo tan fascinante como desafiante.

KARINA FIGUEROA
Editora en jefe
KOMPUTER SAPIENS



DIRECTORIO

Mesa Directiva SMIA

Presidente SMIA
Hiram Eredín Ponce Espinosa
Vicepresidente
Roberto Antonio Vázquez Espinosa de los Monteros
Secretario
Gilberto Ochoa Ruiz
Tesorera
Iris Iddaly Méndez Gurrola
Vocales
Ari Yair Barrera
Bella Citlali Martínez
Claudia Ibeth González Berrelleza
Gustavo Arroyo Figueroa
Hugo Jair Escalante Balderas
Ismael Medina Muñoz
Iván Alejandro Olvera Rodríguez
Joanna Alvarado Uribe
Leobardo Morales Tiburcio
Noé Alejandro Castro
Obdulia Pichardo Lagunas

Komputer Sapiens

Director general
Hiram Eredín Ponce Espinosa
Editora en jefe
Karina Mariela Figueroa
Editor científico
Héctor Gabriel Acosta Mesa
Editores asociados
Marco Antonio Aguirre Lam
Laura Cruz Reyes
Editor invitado
Efrén Mezura Montes
Coordinadora de producción
Viridiana Mena Gómez
Diseño Editorial
Barbarosos: Oscar Omar Saldivar López y Luis Gerardo Téllez Lorenzo
Portada
Luis Gerardo Téllez Lorenzo
Corrección de estilo
Claudia Leticia Díaz González
Gilberto Rivera Zárate
Guillermo de Jesús Hoyos Rivera
Luis Miguel García Velázquez
Marcela Quiroz Castellanos
Nelson Rangel Valdez
Nicandro Cruz Ramírez
Sonia Lilia Mestizo Gutiérrez
Susana Aurora Velasco Montiel
Leonardo Romero Muñoz
Fernando Piña Campos
e-Tlakuilo
Karina Figueroa
Rosa María Valdovinos
Kalixxotl
Luis Gerardo Téllez Lorenzo
Oscar Omar Saldivar López
Estado del IArte
Reyna Carolina Medina Ramírez
Jorge Rafael Gutiérrez Pulido
Sakbe
Laura Cruz Reyes
Claudia G. Gómez Santillán
Laura Gómez Cruz
IA & Educación
María Lucía Barrón Estrada
J. Julieta Noguez Monroy
María Yasmín Hernández Pérez
Descrubriendo Konocimiento
Alejandro Guerra Hernández
Gildardo Sánchez Ante

Directores Fundadores
Carlos Alberto Reyes García
Ángel Kuri Morales

Comité Editorial

Alexander Gelbukh
Ángel Kuri Morales
Antonio Sánchez Aguilar
Carlos Alberto Reyes García
Eduardo F. Morales Manzanares
Félix Castro
Grigori Sidorov
Ildar Batyrshin
Jesús Favela Vara
José A. Martínez Flores
Juan Humberto Sossa Azuela
Juan Manuel Ahuactzin Larios
Karina Mariela Figueroa Mora
Laura Cruz Reyes
Leonardo Garrido Luna
Luis Enrique Sucar Succar
Manuel Montes y Gómez
Miguel González Mendoza
Ofelia Cervantes Villagómez
Ramon Brena Pinero
Raúl Monroy Borja

Revisores

Adriana Laura López Lobato
Alejandra Silva
Alejandro Sebastian de la Cueva de Labastida
Alicia Martínez Rebollar
Andrés Espinal Jiménez
Angel Díaz Pacheco
Angel Leonel Ortiz Herrera
Angélica Guzmán Ponce
Antonieta Martínez-Velasco
Armando Ayala Corona
Carlos Alberto Lopez Herrera
Carlos Andrés Miranda Palma
Carlos Ignacio Hernández Castellanos
Cecilia-Irene Loeza-Mejía
César Augusto Camas Flores
Cesar Alberto Rosales Alcantar
Christian Casillas Farfán
Cinhtia Maribel González Segura
Claudia Ibeth Gonzalez Berrelleza
Claudia Leticia Díaz González
Cleto Álvarez
Daniela Moctezuma
Edgar Mixcoha
Eduardo Morales
Efrén Mezura Montes
Federico Miguel Cireb Galán
Francisco Javier Hernández López
Francisco Rafael Trejo-Macotela
Georgina Castillo Valdez
German Augusto Osorio Zuluaga
Gilberto Rivera Zárate
Gloria Ekaterine Peralta Peñuñuri
Guillermo de Jesús Hoyos Rivera
Héctor-Gabriel Acosta-Mesa
Humberto Avila Pérez
Ignacio Segovia-Dominguez
Isaías Emmanuel Garduño Olvera
Ivan de Jesus May-Cen
Izlian Yolanda Orea Flores
Jaime Aguilar-Ortiz
Jazmín rodriguez Flores
Jejanny Lucero Hernández Martínez
Jesús Emmanuel Solís Pérez
Jesús Adolfo Mejía de Dios
Jesús Arnulfo Barradas Palmeros
Jesus Horacio Pacheco Ramirez
Jesús Miguel García Gorrostieta
Jesús Nestaly Marín Nevárez
Jonas Velasco Alvarez
Jonathan Montalvo-Urquizo
Jorge Alberto Calvillo Rodriguez
Jorge Arturo Flores-López
José Luis Rosas-Acevedo
Jose Agustin Almaraz-Damian
José Antonio Fuentes-Tomás
José Jaime Camacho Escoto
José Luis López Martínez
José Luis Morales Reyes
Josue Román Martínez Mireles
Karina Gutierrez Fragoso
Karina Mariela Figueroa Mora
Karla Paola Martínez Rámila
Laura Sanely Gaytán Lugo
Lino Alberto Rodriguez Coayahuitl
Lizzie Edmea Narváez Díaz
Lucero de Montserrat Ortiz Aguilar
Luis Miguel García Velázquez
Manuel Montes-y-Gómez
Marcela Quiroz Castellanos
Marco Aurelio Sotelo
Maria Auxilio Medina Nieto
María Margarita Reyes Sierra
Mario Castelán
Mario Ben-Hur Chuc Armendariz
Martha Lorena Avendaño-Garrido
Michel García García
Miguel Angel Alvarez Carmona
Miguel Gonzalez-Mendoza
Milton Jesús Vera Contreras
Miriam Pescador Rojas
Mirna Ariadna Muñoz Mata
Nancy Pérez Castro
Nelson Rangel Valdez
Nicandro Cruz Ramírez
Oliver Fernando Cuate González
Patricia Batres Mendoza
Pedro Gonzalez Zamora
Rafael Morales Gamboa
Ramón Aranda
Ramón Zatarraín Cabada
Raquel Torres
Raul Monroy
René Navarro
Ricardo Rafael Quintero Meza
Rocío Alejandra Aldeco-Pérez
Rocio Erandi Barrientos Martínez
Rolando Menchaca Méndez
Rosa María Valdovinos Rosas
Sandra Edith Nava Muñoz
Saúl Juan Carlos Salazar Samaniego
Selene Ramos Ortiz
Sergio Hernández Méndez
Sonia Lilia Mestizo Gutierrez
Stephanie Amador Larrea
Susana Aurora Velasco Montiel
Victor Hugo Benitez Baltazar
Víctor Manuel Bá(z Beltrán
Victor Manuel Chi Pech

©Komputer Sapiens, Año XVIII Volumen III, septiembre-diciembre,
es una publicaciónn cuatrimestral de la Sociedad Mexicana
de Inteligencia Artificial, A.C., con domicilio en Ezequiel Montes
56 s/n, Fracc. los Pilares, Metepec, Edo. de México,
C.P. 52159, México.

www.komputersapiens.org,
editorial@komputersapiens.org,

Reserva de derechos al uso exclusivo número
04-2009-111110040200-102
otorgado por el Instituto Nacional de Derechos de Autor
ISSN 2007-0691.
Indizada en el IRMDCT de SECIHTI y en Latindex.

Los artículos y columnas firmados son responsabilidad exclusiva
de los autores y no reflejan necesariamente los puntos de vista
de la Sociedad Mexicana de Inteligencia Artificial. La mención
de empresas o productos específicos en las páginas de Komputer
Sapiens no implica su respaldo por la Sociedad Mexicana de
Inteligencia Artificial.

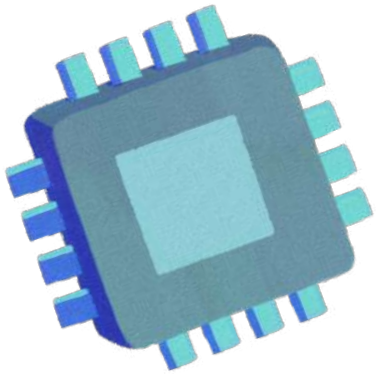
Queda estrictamente prohibida la reproducción total
o parcial por cualquier medio, de la información aquí
contenida sin autorización por escrito de los editores.

Komputer Sapiens es una revista de divulgación en idioma español
de temas relacionados con la inteligencia artificial.

Licenciada bajo Creative Commons Atribución-No Comercial-Sin
Obras Derivadas 2.5 México (CC BY-NC-ND 2.5 MX)

CONTENIDO

KOMPUTER SAPIENS



COLUMNAS

Pág. 3 : Sapiens Piensa
Todo sobre esta edición
Editor invitado: Efrén Mezura Montes

Pág. 6: e-Tlakuilo
Cartas de nuestros lectores
Karina Figueroa y Rosa María Valdovinos

Pág. 7: Estado del IArte
La IA como aliada de la salud mental
Jorge Rafael Gutiérrez Pulido y Reyna Carolina Medina Ramírez

Pág. 9: Sakbe
El ecosistema de la IA generativa: dónde aprender,experimentar y crear
Laura Cruz Reyes, Claudia G. Gómez Santillán y Laura Gómez Cruz

Pág. 86: IA & Educación
Estudiar Inteligencia Artificial, una emocionante aventura
María Lucía Barrón Estrada, J. Julieta Noguez Monroy y María Yasmín Hernández Pérez

Pág. 89: Deskubriendo Konocimiento
Revisión de "Co-Intelligence: Living and Working with AI"
Alejandro Guerra Hernández y Gildardo Sánchez Ante

ARTÍCULOS

Pág. 11
Nueva arquitectura conceptual de una Ciudad Inteligente para combatir la obesidad sarcopénica
Carlos-Alfonso Tovilla-Zarate, Eddy Sánchez De la Cruz , Irahan Otoniel José Guzmán, Mirta Fuentes-Ramos

Pág. 18
¿Qué se esconde en el pixel? El árbol que le pregunta a las imágenes
Adriana Laura López Lobato, Efrén Mezura Montes, Héctor-Gabriel Acosta-Mesa

Pág. 26
IA Verde: El arte de cocinar algoritmos sin calentar el planeta
Efrén Mezura Montes, Héctor-Gabriel Acosta-Mesa, Nancy Pérez Castro

Pág. 34
¿Sabes cómo preguntar a la IA? Oportunidades y desafíos éticos en la escritura académica
Jonathan Rojas Simón, René Arnulfo García Hernández, Verónica Neri-Mendoza, Yulia Ledeneva

Pág. 41
Codificación Cuántica de Imágenes: Una Nueva Frontera para la Inteligencia Artificial
Emmanuel Martínez Guerrero, Guo-Hua Sun, Shi-Hai Dong

Pág. 48
Leer el Frijol sin Dañarlo: una Misión Para la Inteligencia Artificial
Elia Nora Aquino Bolaños, Héctor-Gabriel Acosta-Mesa, Jimena Esther Alba Jiménez, José Luis Morales Reyes

Pág. 54
¿Cómo puede la inteligencia artificial escuchar a un motor y decir si está enfermo?
Martín Valtierra Rodríguez

Pág. 60
Laboratorios, clubes y talleres: estrategias funcionales para involucrar a más niñas y mujeres en STEM e IA
Laura Araceli Guerrero Herrera, Marcos Yamir Gómez Ramos

Pág. 66
Inteligencia Artificial de los Residuos Sólidos Urbanos: Cómo la tecnología aprende a limpiar nuestras ciudades
Araceli Hernández Cruz, Jorge Luis Castañeda Gutiérrez, José Crispin Hernández Hernández

Pág. 73
El Espíritu Algorítmico: Ética y Empatía como base en la creación de aplicaciones de IA
José Roberto Ramírez Guerrero

Pág. 78
La neutralidad en los LLMs: Una meta inalcanzable
David Torres Moreno, Nadia María Peralta Nava, Pablo Ricardo Jimenez Cruz

50 AÑOS: Tecnológico de Monterrey | Campus Chihuahua • País invitado de Honor: FRANCIA | 200 años de amistad Francia–México

País invitado de Honor
FRANCIA

MICAI 25 YEARS 2000-2026

MEXICAN INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE | ITESM Campus Chihuahua

MICAI es el congreso líder de inteligencia artificial en México

MICAI 2026 celebra **25 años** impulsando las fronteras de la Inteligencia Artificial en México.

Este evento servirá como **un puente para la cooperación internacional,** teniendo a Francia como País Invitado de Honor en el marco de la celebración **del Bicentenario Francia–México.**

Tecnológico de Monterrey | CAMPUS CHIHUAHUA 50 AÑOS



Más información en: **micai.org/2026/**

02-06 NOV 2026

25 AÑOS DE MICAI: Mexican International Conference on Artificial Intelligence | 02 - 06 Noviembre 2026 | Chihuahua, México

SOCIEDAD MEXICANA DE INTELIGENCIA ARTIFICIAL | Tecnológico de Monterrey | CAMPUS CHIHUAHUA 50 AÑOS | AMBASSADE DE FRANCE AU MEXIQUE | MÉXICO FRANCIA 2026 200 AÑOS DE AMISTAD | CHIHUAHUA BURÓ DE CONVENCIONES | ¡ah Chihuahua! | technologies an Open Access Journal by MDPI



COLUMNA

Sapiens Piensa

EDITOR INVITADO: ***Efrén Mezura Montes***

Como sociedad, aún estamos con un sentimiento de sorpresa persistente y, en muchas ocasiones, con un dejo de incertidumbre ante la ola que nos ha cubierto desde la liberación de ChatGPT en noviembre de 2022. La Inteligencia Artificial Generativa está cambiando muchos aspectos del quehacer humano, lo que obliga a estar informado como usuario responsable. Sin embargo, junto con la versión generativa de la Inteligencia Artificial, existen temas altamente relevantes que debemos conocer, pues constituyen la base de la tecnología que, más pronto que tarde, estará en nuestras manos.

En este número de Komputer Sapiens se seleccionaron 11 artículos que abordan temas importantes de la Inteligencia Artificial, como su impacto positivo y negativo en el medio ambiente, su uso en salud, los problemas en la industria, las estrategias para incorporar a más niñas y jóvenes a carreras relacionadas con esta área, la Inteligencia Artificial Generativa, el procesamiento de imágenes y el desarrollo de software. Agradecemos especialmente a los revisores y al comité editorial por el excelente trabajo realizado en la elaboración de este número de la revista.

En el artículo **"Codificación Cuántica de Imágenes: Una Nueva Frontera para la Inteligencia Artificial"**, los autores presentan de manera muy sencilla las diferentes alternativas actuales para representar imágenes en sistemas cuánticos. Para ello, se incluye una introducción al concepto de "qubit", se destacan las limitaciones actuales del hardware cuántico y se enumeran aplicaciones relevantes en las que la codificación cuántica de imágenes puede aportar ventajas para la Inteligencia Artificial.

Los autores del artículo **"Laboratorios, clubes y talleres: estrategias funcionales para involucrar a más niñas y mujeres en STEM e IA"** destacan la importancia de construir trayectorias educativas sólidas para niñas y jóvenes interesadas en STEM e

©2026 SMIA | ISSN 2007-069



Inteligencia Artificial y señalan que, para ello, el aprendizaje activo, el trabajo colaborativo y la experimentación directa que promueven los laboratorios, clubes y talleres son fundamentales. El documento también incluye nombres de mujeres referentes en estas áreas, experiencias previas y algunas propuestas para que estos espacios sean funcionales.

En el artículo **"¿Cómo puede la Inteligencia Artificial escuchar a un motor y decir si está enfermo?"**, el autor destaca el uso de la Inteligencia Artificial para detectar de forma temprana anomalías en el funcionamiento de los motores de inducción. Se destaca la señal de corriente como el medio para determinar este tipo de daños, la cual se transforma en una imagen mediante la transformada corta de Fourier. De esta manera, se emplean redes neuronales convolucionales y técnicas de Inteligencia Artificial explicable para identificar daños en el motor.

"¿Qué se esconde en el pixel? El árbol que le pregunta a las imágenes" es el título del artículo donde sus autores presentan los árboles de decisión convolucionales como una alternativa que abona a la explicabilidad en el proceso de segmentar imágenes. De manera amena, se introduce el concepto de kernel y su función para extraer información de las imágenes, y se presenta la evolución diferencial como mecanismo de búsqueda para generar este tipo de árboles.

Los autores del artículo **"Leer el Frijol sin Dañarlo: una Misión para la Inteligencia Artificial"** detallan el uso de redes neuronales convolucionales generadas mediante algoritmos evolutivos para estimar las antocianinas en muestras de frijoles, destacando su papel importante para determinar, sin destruir, las propiedades de nuestros alimentos. El artículo también destaca el papel tan relevante que tiene el frijol en una buena alimentación.

El concepto de Inteligencia Artificial Verde, las emisiones de CO_2 derivadas de los costosos entrenamientos de las Inteligencias Artificiales Generativas actuales, el diseño de algoritmos evolutivos y la estimación de sus emisiones de carbono se presentan en el artículo **"IA Verde: El arte de cocinar algoritmos sin calentar el planeta"**, en el que los autores destacan la importancia de desarrollar herramientas de Inteligencia Artificial eficientes y respetuosas con nuestro medio ambiente.

Los autores del artículo **"¿Sabes cómo preguntar a la IA? Oportunidades y desafíos éticos en la escritura académica"** comentan la importancia de la interacción con herramientas de Inteligencia Artificial Generativa mediante prompts, destacando tres enfoques e incluyendo ejemplos de cada uno. Además, discuten las ventajas del uso de estas herramientas en la escritura académica, así como los riesgos y los desafíos éticos que conlleva.

En el artículo **"Inteligencia Artificial de los Residuos Sólidos Urbanos: cómo la tecnología aprende a limpiar nuestras ciudades"**, los autores abordan el papel de la Inteligencia Artificial en la recolección de residuos sólidos urbanos, en donde el Aprendizaje de Máquina y la optimización inteligente desempeñan un papel fundamental. Finalmente, proponen una metodología y presentan un caso de estudio con datos del estado de Tlaxcala.

©2026 SMIA | ISSN 2007-069

Los autores del artículo **"Nueva arquitectura conceptual de una Ciudad Inteligente para combatir la obesidad sarcopénica"** presentan una revisión de la literatura sobre la identificación de esta condición mediante tecnologías emergentes y, posteriormente, proponen una arquitectura conceptual que utilice Inteligencia Artificial, sensores y dispositivos móviles para coadyuvar a paliar esta patología. Finalmente, destacan los desafíos éticos y filosóficos que conllevan este tipo de soluciones tecnológicas.

En el artículo **"La neutralidad en los LLMs: ¿Una meta inalcanzable?"**, sus autores plantean la hipótesis de que la neutralidad será algo que un Modelo de Lenguaje Largo no podrá alcanzar, pues su entrenamiento proviene de datos que, por la naturaleza del quehacer humano y del lenguaje, tienen sesgos que la máquina magnifica mediante los cálculos probabilísticos que realiza internamente. Además, la propia interacción del modelo con los humanos, que tienen sesgos, incrementa el sesgo preexistente en el modelo. Finalmente, presentan un experimento sencillo que evidencia la existencia de estos sesgos.

El autor del artículo **"El Espíritu Algorítmico: Ética y Empatía como base en la creación de aplicaciones de IA"** establece la ética y la empatía como pilares del desarrollo de aplicaciones de software basadas en Inteligencia Artificial. Establece, además, que mantener estos dos ejes en el desarrollo de aplicaciones conlleva conflictos éticos. Finalmente, enumera los beneficios derivados del desarrollo ético y empático de software y comenta sobre la importancia de la asertividad tecnológica. KS

Efrén Mezura Montes
Editor invitado
KOMPUTER SAPIENS



Sobre el editor

Efrén Mezura Montes es director del Instituto de Investigaciones en Inteligencia Artificial de la Universidad Veracruzana. Diseña y estudia algoritmos inspirados en la naturaleza para el aprendizaje computacional y la optimización. Cuenta con más de 200 artículos publicados, cuatro libros y más de 12 600 citas en Google Scholar. Es investigador Nivel III del SNII, presidente de la Sociedad Mexicana de Ciencia de la Computación, miembro regular de la Academia Mexicana de Ciencias y de la Academia Mexicana de Computación, e integra el Comité Técnico Asesor de la Red Nacional de Inteligencia Computacional Aplicada. Asimismo, se desempeña como editor asociado de ocho revistas JCR y miembro de comités de la IEEE en inteligencia artificial. Ha sido galardonado con el Premio Estatal de Ciencia y Tecnología 2023 de Veracruz y la Medalla al Mérito de la Universidad Veracruzana 2024.

©2026 SMIA | ISSN 2007-069

COLUMNA

e-Tlakuilo:
Cartas de nuestros lectores

Karina Figueroa y Rosa María Valdovinos



etlakuilo@komputersapiens.org

Artículo: Sesgo en los datos y los prejuicios en algoritmos de aprendizaje automático - IA
©Komputer Sapiens, Año 17, Volumen 3

P: Además de instituciones que emiten recomendaciones en cuanto a la aplicación de aprendizaje automático, como las mencionadas en el artículo, ¿Qué organismos o marcos regulatorios existen actualmente para supervisar su uso, especialmente en áreas de alto impacto social, como salud y justicia?
Por: Abigail Romero Trejo

R: En México y en América Latina, la regulación del aprendizaje automático transita de esquemas de soft law (recomendaciones éticas) a iniciativas con fuerza vinculante e instituciones públicas de supervisión directa. Dentro de México podemos encontrar acuerdos e iniciativas encargados de supervisar y regular el uso de la inteligencia artificial y el aprendizaje automático, como la SCJN, el CJF, el PNAA o el INAI. Al final de la respuesta, presento un poco de bibliografía.

A nivel Latino América, la Red Iberoamericana de Protección de Datos, la Corte IDH, la OPS, que forma parte de la OMS, y la UNESCO también han emitido recomendaciones e iniciativas de la jurisprudencia sobre el impacto de la IA en diversos temas como la salud o los derechos humanos. Igualmente, adjunto bibliografía.

1. https://sil.gobernacion.gob.mx/Archivos/Documentos/2025/04/asun_4896460_20250430_1747757009.pdf
2. https://www.scjn.gob.mx/derechos-humanos/sites/default/files/boletin-materia-ddhh/2026-01/Boletin_NOVIEMBRE-DICIEMBRE-V3.pdf
3. https://revistasam.com.ar/index.php/RAM/article/view/1169
4. https://www.ride.org.mx/index.php/RIDE/article/view/2291
5. https://unesdoc.unesco.org/ark:/48223/pf0000381137_spa

Artículo: Sesgo en los datos y los prejuicios en algoritmos de aprendizaje automático
©Komputer Sapiens, Año 17, Volumen 3

P:¿Se ha planteado realizar experimentos para comprobar sus recomendaciones en cuanto a minimización del sesgo?
En caso de ser así ¿Cuál sería la metodología apropiada o pasos a seguir desde la recolección de datos?
Por: Víctor Gonzalo Rivero Martínez

R: Para llevar las recomendaciones sugeridas en el trabajo escrito en proyectos de aprendizaje automático, la literatura científica propone un protocolo experimental riguroso estructurado en cinco fases:

1. Auditoría sociodemográfica y muestreo estratificado (Recolección)
2. Análisis exploratorio del sesgo muestral (data pre-processing audit)
3. Intervención experimental de mitigación
4. Evaluación experimental y métricas comparativas
5. Prueba de esfuerzo (stress testing) y auditoría continua

Cada una de ellas vale la pena revisarla con más detalle para comprender su alcance y su objetivo; para ello, adjunto algunas referencias.

1. https://dl.acm.org/doi/10.1145/3457607
2. https://ai.ageditor.ar/index.php/ai/article/view/20
3. https://arxiv.org/abs/2307.05842
4. https://revistas.ulasalle.edu.pe/ricce/article/download/251/265/
5. https://zaguan.unizar.es/record/162274?ln=es

©2026 SMIA | ISSN 2007-069



Ilustración: Omar Saldivar y Gerardo Téllez

COLUMNA

Estado del IArte

La IA como aliada de la salud mental

Jorge Rafael Gutiérrez Pulido (𝕏@jrgpulido) y Reyna Carolina Medina Ramírez

estadoiarte@komputersapiens.org

La Organización Mundial de la Salud (OMS) en su plan de acción integral sobre salud mental 2013–2030 [1] promueve un enfoque multisectorial para atender, proporcionar cuidados y seguimiento a quienes lo necesitan. La salud mental es un estado de bienestar en el que la persona reconoce sus capacidades, puede afrontar las variaciones de la vida, trabajar de forma productiva y contribuir a su comunidad. Comprende un equilibrio entre los aspectos emocionales, psicológicos y sociales los cuales influyen en cómo las personas piensan, sienten, toman decisiones, y se relacionan con los demás. Como la vida misma, este bienestar es dinámico y puede verse afectado por factores biológicos, psicológicos, familiares, sociales, económicos y ambientales. Sin embargo, cuando los síntomas persisten, aumentan de intensidad o interfieren de manera importante con las actividades cotidianas, las relaciones personales, el desempeño escolar o laboral y la calidad de vida, es recomendable solicitar una valoración por parte de un profesional de la salud mental [2]. Entre las principales señales que indican la necesidad de

1. https://www.who.int/es/publications/i/item/9789240050860
2. https://www.federaciocatalanatdah.org/wp-content/uploads/2018/12/dsm5-manualdiagnosticoyestadisticodelostrastornosmentales-161006005112.pdf

buscar ayuda profesional se encuentran la tristeza persistente durante varias semanas, la pérdida de interés por actividades previamente placenteras, ansiedad intensa o constante, ataques de pánico, alteraciones importantes del sueño o del apetito, dificultades para concentrarse, cambios marcados en el comportamiento, aislamiento social, sentimientos persistentes de desesperanza o culpa, así como pensamientos relacionados con la autolesión o el suicidio. La identificación temprana de estas señales de alerta favorece la intervención oportuna, reduciendo el riesgo de complicaciones [3].

En este contexto, la Inteligencia Artificial (IA) tiene mucho que ofrecer como herramienta de atención a la salud mental. Mediante el análisis de grandes volúmenes de datos clínicos, conductuales y biométricos, la IA puede apoyar en gran medida, a la detección temprana de síntomas y factores de riesgo, así como facilitar el seguimiento de los pacientes y contribuir a la toma de decisiones clínicas. No obstante, la evidencia científica y los organismos internacionales coinciden en que estas tecnologías deben emplearse únicamente como herramientas complementarias dentro de un modelo de atención centrado en la persona, respetando principios de ética, privacidad, transparencia y supervisión profesional. Incluso las propias IA enfatizan lo anterior y han incluido *avisos de descargo de responsabilidad* al final de sus respuestas sobre preguntas relacionadas a salud mental o medicamentos.

En México, muchas de las instituciones interesadas en el tema ya han incluido IA. El **Instituto Nacional de Psiquiatría Ramón de la Fuente Muñiz** es el principal centro de investigación en salud mental. Sus grupos de investigación desarrollan proyectos relacionados con Inteligencia artificial, minería de datos y telemedicina como pilares para diagnóstico, seguimiento y predicción de trastornos mentales [4]. La **Universidad Nacional Autónoma de México** (UNAM) desarrolla investigaciones interdisciplinarias desde la Facultad de Psicología, la Facultad de Medicina y el Instituto de Investigaciones en Matemáticas Aplicadas y en Sistemas (IIMAS). Sus proyectos incluyen procesamiento del lenguaje natural aplicado a evaluación psicológica, análisis de datos clínicos, salud digital y estudios sobre las implicaciones éticas del uso de IA en psicología clínica. La UNAM también ha impulsado investigaciones sobre asistentes conversacionales y alfabetización digital para profesionales de la salud mental [5].

Finalmente, la evidencia científica demuestra que la Inteligencia Artificial posee un enorme potencial para fortalecer la salud mental mediante diagnósticos tempranos, seguimiento continuo y tratamientos personalizados. No obstante, como se ha mencionado, el uso de esta tecnología debe desarrollarse bajo principios de ética, protección de datos, validación clínica y supervisión médica especializada. **KS**

3. https://www.who.int/es/news-room/fact-sheets/detail/depression

4. https://sidofqa.segob.gob.mx/notas/getDoc/5769857

5. http://doi.org/10.22201/ceide.16076079e.2024.25.5.10

©2026 SMIA | ISSN 2007-069



COLUMNA

Sakbe

El ecosistema de la IA generativa: dónde aprender, experimentar y crear

Laura Cruz Reyes, Claudia Guadalupe Gómez Santillán y Laura Gómez Cruz

sakbe@komputersapiens.org

¿*Alguna vez has sentido que la Inteligencia Artificial (IA) es exclusiva para expertos?* La realidad hoy es otra: para cualquier persona, sin importar su nivel educativo, existe un ecosistema completo de herramientas y plataformas gratuitas que permiten **aprender, experimentar y crear,** con modelos avanzados, desde el navegador de su computadora. La IA generativa es aquella capaz de **producir contenido nuevo**: texto, imágenes, música, código o datos, a partir de lo que aprendió con grandes colecciones de ejemplos [1]. Herramientas como ChatGPT, Gemini o Midjourney son los ejemplos más visibles, y detrás de ellos existe un ecosistema vibrante de recursos abiertos que espera ser explorado.

1. Inicia sin instalar nada, si nunca has programado, estas plataformas ofrecen el camino más accesible:

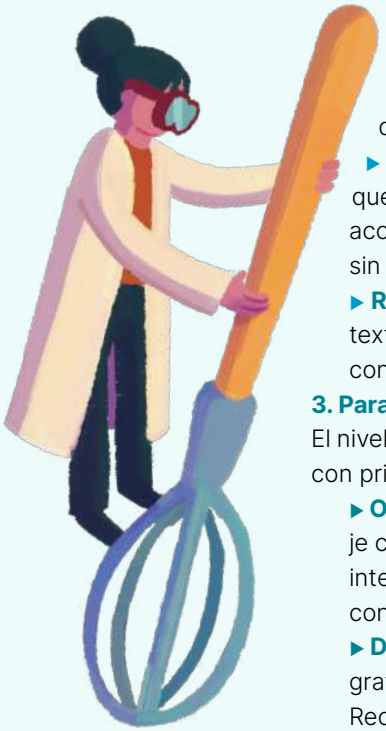
Google Cloud Skills Boost (cloudskillsboost.google), ofrece más de 11 cursos gratuitos sobre IA generativa, desde una introducción básica hasta técnicas avanzadas de generación de imágenes [2]. No se requiere experiencia previa. Al terminar cada módulo se obtiene una insignia digital.

- **Kaggle Learn (kaggle.com/learn),** es una plataforma de Google con cursos cortos, gratuitos y con certificado sobre Python, Aprendizaje Automático e IA generativa. Todo funciona en la nube, sin instalar software [3]. Es ideal para quienes quieren aprender haciendo.
- **fast.ai (fast.ai).** Uno de los cursos más respetados del mundo para aprender Machine Learning de forma práctica. Su filosofía es aprender de arriba hacia abajo: primero construyes proyectos reales, luego entiendes la teoría que los sustenta [3].

2. Experimenta con el laboratorio en tu navegador, una vez que tienes las bases, el siguiente paso es **ensuciarte las manos** con modelos reales. Estas plataformas funcionan como laboratorios abiertos:

- **Hugging Face (huggingface.co).** Es la biblioteca más grande del mundo de modelos de IA de código abierto: más de 900,000 modelos, 200,000 datasets y miles de aplicaciones interactivas llamadas

©2026 SMIA | ISSN 2007-069



'Spaces', donde puedes probar desde chatbots hasta generadores de imágenes sin escribir una sola línea de código [3]. También ofrece su propio curso gratuito de Procesamiento de Lenguaje Natural.

▸ **Google Colab (colab.research.google.com)**. Entorno de programación en la nube que permite escribir y ejecutar código Python directamente desde el navegador, con acceso gratuito a procesadores gráficos (GPU) [4]. Ideal para ejecutar modelos de IA sin necesitar una computadora potente.

▸ **Replicate (replicate.com)**. Plataforma para probar cientos de modelos de imagen, texto y audio con un clic. Permite experimentar con los modelos más recientes sin configuraciones técnicas.

3. Para crear: lleva la IA a tu propia computadora

El nivel más avanzado del ecosistema permite correr modelos directamente en tu equipo, con privacidad total y sin depender de servidores externos:

▸ **Ollama (ollama.com)**. Herramienta gratuita que permite ejecutar modelos de lenguaje como Llama 3.3, Mistral o Phi-3 directamente en tu computadora, sin necesidad de internet ni de pagar por una API [5]. Con 16 GB de memoria RAM es posible conversar con modelos de inteligencia comparable a los servicios comerciales.

▸ **DeepLearning.AI (deeplearning.ai)**. Plataforma de Andrew Ng con cursos cortos y gratuitos sobre técnicas avanzadas como LangChain, RAG (Generación Aumentada por Recuperación) e ingeniería de prompts. Es el puente entre el aprendizaje y el desarrollo de aplicaciones reales [3].

4. ¿Por dónde empezar si soy principiante absoluto?

La ruta más recomendada es la siguiente: (1) toma el curso de Introducción a la IA Generativa de Google en Cloud Skills Boost (dura menos de una hora); (2) explora los 'Spaces' de Hugging Face para ver qué es posible crear; (3) abre un notebook en Google Colab y ejecuta tu primer modelo con unas pocas líneas de código. **El 78% de los usuarios de IA generativa comienzan con planes gratuitos** antes de decidir invertir en herramientas de pago [4], lo que confirma que el ecosistema abierto es más que suficiente para explorar y aprender.

Lo más sorprendente de este ecosistema no es solo su potencia técnica, sino su **apertura radical**. Las mismas herramientas que usan los investigadores del MIT o del IPN están disponibles para cualquier persona con curiosidad y una conexión a internet. Aunque las plataformas y los modelos evolucionan constantemente, aprender a explorar este ecosistema facilitará la adaptación a las nuevas herramientas que vayan surgiendo. Más que una lista definitiva de herramientas, esta ruta representa una forma de acercarse a un ecosistema en constante evolución. El camino blanco está abierto. Solo falta dar el primer paso. **KS**

Referencias

1. [1] Google Cloud Training. (2025). Introduction to Generative AI [Curso en línea]. Coursera / Cloud Skills Boost. Disponible en: cloudskillsboost.google
2. [2] Infobae Tecno. (2025). Cursos gratuitos de IA de Google: paso a paso para comenzar. Disponible en: infobae.com/tecno/2025/06/16
3. [3] OpenReplay Blog. (2025). Recursos gratuitos de aprendizaje de IA para desarrolladores. Disponible en: blog.openreplay.com/es/recursos-aprendizaje-ai-gratis-desarrolladores
4. [4] Escuela de Programación. (2026). Las mejores herramientas de IA gratis para aprender en 2026. Disponible en: escueladeprogramacion.net
5. [5] Javadex. (2026). Aprender IA desde cero gratis: ruta completa para principiantes. Disponible en: javadex.es/blog/aprender-ia-desde-cero-gratis
6. [6] Machinelearnear. (2024). Curso de IA generativa y LLMs [Repositorio GitHub]. Disponible en: github.com/machinelearnear/curso-ia-generativa-y-llms
7. [7] Domestika. (2024). Top herramientas y plataformas gratuitas de IA. Disponible en: domestika.org/es/blog/13553
8. [8] Sociedad Mexicana de Inteligencia Artificial (SMIA). (2025). Komputer Sapiens: Revista de Divulgación. Disponible en: komputersapiens.smia.mx

©2026 SMIA | ISSN 2007-069

ARTÍCULO

Nueva arquitectura conceptual de una Ciudad Inteligente para combatir la obesidad sarcopénica

Mirta Fuentes Ramos, Irahan Otoniel José Guzmán, Carlos Alfonso Tovilla Zárate y Eddy Sánchez De la Cruz

Obesidad sarcopénica



La obesidad sarcopénica es una condición en la que coexisten el exceso de grasa corporal y la pérdida de masa y calidad muscular. Este desequilibrio entre grasa y músculo provoca alteraciones metabólicas y disminuye la fuerza y la funcionalidad, ya que el músculo se reduce y acumula grasa en su interior, afectando su desempeño. Esta patología se desarrolla a partir de un conjunto de alteraciones internas que incluyen inflamación crónica de bajo grado, resistencia a la insulina y cambios hormonales. Estos procesos se potencian entre sí, favoreciendo la pérdida de masa muscular y la acumulación de grasa en lugares donde no debería estar, como dentro del propio músculo. Como consecuencia, disminuye la fuerza y se altera el metabolismo, incluso en personas que pueden tener un peso corporal elevado. La masa magra disminuye con el paso de los años, mientras que la grasa (visceral y subcutánea) aumenta hasta la edad media. La edad avanzada se asocia con disminución en la grasa subcutánea (paralela a la pérdida de masa corporal magra) y la aparición de grasa ectópica en el músculo pero también en otros órganos [1,2] (Figura 1).

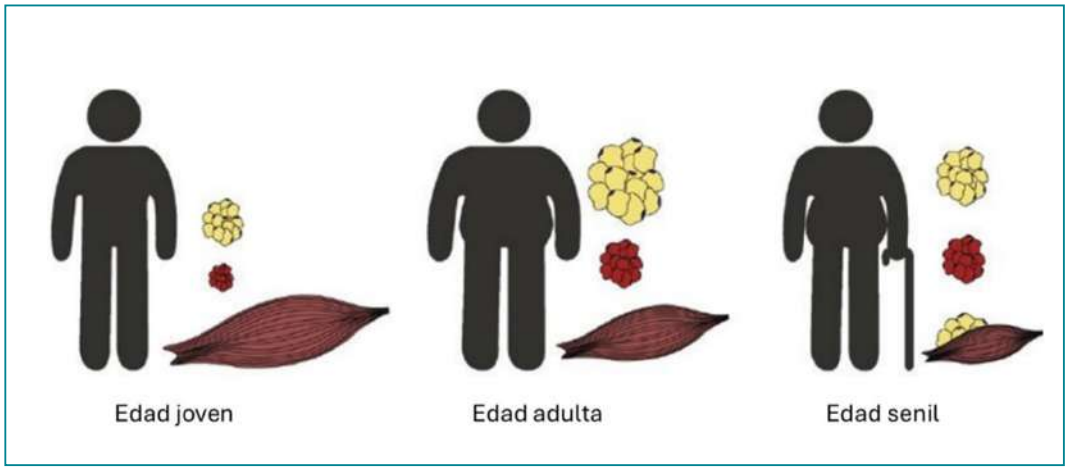


Figura 1. *Cambios masa muscular y masa grasa (células amarillas: grasa subcut´anea, células rojas: grasa visceral, células amarillas dentro del músculo: ectopia y lesiones grasas).*

Esta condición no solo afecta la composición corporal, sino también la calidad de vida y se asocia con mayor riesgo de enfermedades cardiometabólicas, deterioro funcional y mayor mortalidad. Su diagnóstico requiere evaluar tanto la cantidad de músculo y grasa como la capacidad funcional de la persona. Debido a su complejidad, el tratamiento debe ser integral, combinando ejercicio, alimentación adecuada y control metabólico para frenar su progresión y reducir sus complicaciones.

Ciudades Inteligentes, inteligencia artificial y salud pública

Las ciudades inteligentes (o Smart Cities) son urbes que utilizan tecnología para funcionar de manera más eficiente, sostenible y centrada en las personas. A través de sensores, dispositivos conectados y plataformas digitales, recopilan datos en tiempo real sobre aspectos como el tráfico, el consumo de energía, la calidad del aire o los servicios públicos. Esta información permite a las autoridades tomar decisiones más rápidas y precisas, mejorando la gestión urbana y la calidad de vida de sus habitantes. Uno de los principales beneficios de las ciudades inteligentes es que transforman los datos en soluciones concretas. Por ejemplo, pueden optimizar el transporte público para reducir tiempos de traslado, regular automáticamente la iluminación para ahorrar energía o mejorar la recolección de residuos mediante rutas más eficientes (ver Figura 2). Además, fomentan la participación ciudadana mediante aplicaciones móviles y plataformas digitales que facilitan la comunicación entre la población y el gobierno [3].

La inteligencia artificial desempeña un papel cada vez más relevante en el ámbito de la salud pública dentro de las ciudades inteligentes. Mediante algoritmos de aprendizaje automático y análisis avanzado de datos, es posible procesar grandes volúmenes de información provenientes de historiales clínicos, dispositivos médicos, sensores ambientales y sistemas de vigilancia epidemiológica. Esto permite identificar patrones de riesgo, predecir brotes de enfermedades, optimizar la asignación de recursos sanitarios y personalizar estrategias de prevención. Asimismo, la inteligencia artificial facilita el monitoreo remoto de pacientes mediante dispositivos portátiles, la detección temprana de anomalías en indicadores de salud y la generación de alertas automáticas para profesionales médicos y autoridades sanitarias [6,7].

Sin embargo, el desarrollo de estas ciudades inteligentes también implica desafíos importantes, como garantizar la seguridad de la información y proteger la privacidad de las personas. Por ello, las estrategias de ciberseguridad y la gobernanza digital son fundamentales para asegurar un funciona-



Figura 2. *Ejemplo de convergencia entre dispositivos a través de interconectividad y flujo de datos en una ciudad inteligente.*

miento confiable. En conjunto, las ciudades inteligentes representan una apuesta por un modelo urbano más innovador, sostenible y preparado para enfrentar los retos del crecimiento y el cambio climático.

Antecedentes

A continuación se muestran algunos trabajos relacionados que tratan de palear la problemática de identificar la obesidad sarcopénica mediante el uso de tecnologías emergentes.

Zhang et al., evaluaron la sarcopenia utilizando aprendizaje automático y sensores portátiles del Internet de las cosas (IoT). Para la construcción de la base de datos estudiaron 53 adultos mayores de 65 años mediante el análisis de la marcha utilizando sensores duales que extrajeron diecinueve características. Se implementaron algoritmos de clasificación para categorizar a los participantes como i) sanos, ii) con riesgo de nivel 1, ii) riesgo de nivel 2 y iii) riesgo de nivel 3 de sarcopenia, alcanzando una correcta identificaión multiclase de 94.67%, también realizaron una clasificación binaria de personas sanas frente a personas propensas a la sarcopenia alcanzando el 97.41% [4].

Gong et al., evaluaron la obesidad mediante un estudio bibliométrico de 3,286 publicaciones de Web of Science entre 2004 y 2023 relacionada con el aprendizaje automático. Los algoritmos más representativos fueron los de aprendizaje profundo, las máquinas de vectores de soporte y algunos modelos predictivos ensamblados, además se detectó un crecimiento exponencial en la producción científica de esta línea de estudio. Se identificó a Estados Unidos como líder en estas publicaciones, con Leo Breiman como el autor más influyente y Scientific Reports como la revista más productiva [5].

Bernal et al., evaluaron el envejecimiento humano, un proceso biológico complejo afectado por múltiples factores y que representa un desafío creciente en las sociedades con poblaciones de edad avanzada. Realizaron una revisión sistemática que incluyó 77 artículos sobre el uso de la inteligencia artificial en la investigación sobre envejecimiento. Los algoritmos representativos fueron los de aprendizaje profundo aplicados a datos de imágenes, genómicos, conductuales y contextuales. Los resultados muestran que la inteligencia artificial puede predecir resultados relacionados con la edad, desarrollar biomarcadores y determinar factores vinculados al envejecimiento saludable [6].

Uno de los principales beneficios de las ciudades inteligentes es que transforman los datos en soluciones concretas.

An et al., evaluaron la obesidad como una de las principales causas de muerte evitable en 46 artículos donde se aplican algoritmos de aprendizaje automático y aprendizaje profundo en datos tabulares, imágenes y textos. La mayoría de los estudios (18/22, 82%) informaron de una mayor precisión predictiva con inteligenciar artificial en comparación con métodos estadísticos convencionales, mientras que algunos (5/46, 11%) mostraron resultados mixtos, permitiendo la detección de patrones clínicamente relevantes y la asociación de covariables con los resultados de peso, optimizando la investigación y el tratamiento de la obesidad [7].

Ribeiro *et al.*, evaluaron la asociación entre la inflamación, la obesidad y la fuerza muscular en 247 adultos mayores (¿=60 años) con riesgo de dinapenia y sarcopenia. La dinapenia se diagnosticó según el EWGSOP2 y se utilizó una regresión cuantílica multivariante para analizar la relación entre las citocinas inflamatorias y la fuerza muscular. Los resultados mostraron que el 74.4% de las personas con dinapenia eran hombres, con niveles elevados de IL-10 (0,95 pg/ml) y fuerza de prensión reducida, mientras que la obesidad predominaba en las personas sin dinapenia (45.3%; IC del 95%: 37,7-53). Se identificó una asociación negativa significativa entre la IL-10 y la fuerza muscular, lo que demostró la interacción entre la inflamación, la obesidad y la dinapenia [8].

Bedrikovetski *et al.*, evaluaron la segmentación muscular manual en tomografías computarizadas para el análisis de la com-

posición corporal y el diagnóstico de sarcopenia. Revisaron 24 estudios, en 15 de ellos utilizaron aprendizaje profundo para automatizar la segmentación, estos algoritmos analizaron variables del músculo esquelético, el tejido adiposo subcutáneo y visceral, y los huesos en diversos sujetos de estudio. Los resultados mostraron un coeficiente de similitud de Dice de 0.941 para el músculo esquelético y entre 0.963 y 0.970 para el tejido adiposo y los huesos, lo que indica una alta precisiónl lo cual sugiere que la inteligencia artificial puede optimizar la evaluación de la composición corporal y el diagnóstico de la sarcopenia [9].

Onishi *et al*., evaluaron la medición manual de la masa muscular en tomografías computarizadas para diagnosticar la sarcopenia en 3,096 casos hasta la tercera vértebra lumbar entre los años 2011 y 2021. Se implementaron algoritmos de *Deeplabv3* para la detección de regiones corporales y *EfficientNetV2-XL* para el diagnóstico de sarcopenia. Se logró una sensibilidad de 82.3%, una especificidad de 98.1%, un valor predictivo positivo del 89.5% y una detección de regiones corporales con un IoU de 0.93, lo cual indica que la inteligencia artificial es una alternativa fiable y eficaz a los métodos convencionales [10].

Lauretani *et al*., evaluaron que el envejecimiento de la población aumenta la prevalencia de la sarcopenia como factor de discapacidad. Analizaron un cohorte representativa de la región de Chianti, Italia, de adultos mayores sin patologías neurológicas, evaluando indicadores como el torque isométrico de la rodilla, la fuerza de prensión manual, la potencia muscular de las extremidades inferiores y el área muscular de la pantorrilla. Los resultados muostraron que la prevalencia aumenta con la edad en ambos sexos, con un mayor aumento de la potencia muscular y un menor aumento del área muscular de la pantorrilla [11]. Timmins *et al*., evaluaron el problema de la limitada incorporación de los macrodatos en estudios de obesidad, a pesar de su potencial en la medicina y la salud pública, utilizando datos de ventas minoristas, transporte, redes sociales, dispositivos portátiles y programas comerciales de control de peso. Se identificaron aplicaciones relevantes mediante algoritmos de búsqueda en bases de datos y análisis narrativo. Los resultados cuantitativos mostraron la utilidad para estimar las compras de nutrientes, caracterizar entornos y evaluar intervenciones, aunque siguen existiendo limitaciones éticas y metodológicas [12].

Con base en la información previamente mostrada, se encontró el nicho de oportunidad para diseñar una arquitectura conceptual que se valga de las tecnologías emergentes, tales como algoritmos de in-



Figura 3. *Arquitectura de ciudad inteligente propuesta para la identificación de la obesidad sarcopénica.*

teligenciar artificial, así como sensores y dipositivos moviles, para palear la patología de obesidad sarcopénica.

Nuestra propuesta de solución

¿Cómo puede una ciudad inteligente ayudar a detectar y atender tempranamente una condición médica como la obesidad sarcopénica? En esta sección, proponemos un modelo conceptual para tratar la obesidad sarcopénica en el contexto de una ciudad inteligente (Figura 3), basado en sensores biomédicos y aprendizaje automático. En el diagrama, un sujeto de estudio lleva dispositivos inteligentes (reloj y teléfono móvil) que monitorizan continuamente parámetros fisiológicos y funcionales. Los datos se analizan en tiempo real y se transmiten a un hospital inteligente, donde se generan alertas clínicas cuando se detectan anomalías. El sistema integra la respuesta coordinada de los servicios de emergencia, las farmacias y los familiares, lo que facilita una intervención oportuna. En resumen, se define un ecosistema de salud digital interoperable orientado a la detección temprana, la monitorización continua y la optimización de la atención clínica, que cuenta con un flujo de atención de ocho ejes en caso de emergencia en una ciudad inteligente.

La arquitectura propuesta contiene ocho ejes de seguimiento y atención:

1. **Monitorización continua:** el paciente lleva dispositivos inteligentes (reloj y teléfono móvil) que registran continuamente variables fisiológicas (frecuencia cardíaca, variabilidad de la frecuencia cardíaca, actividad física, patrones de movilidad) y variables funcionales asociadas a la obesidad sarcopénica.
2. **Adquisición y transmisión de datos:** los datos capturados por los sensores se transmiten de forma segura, a través de redes inalámbricas, a una plataforma de salud digital integrada en la infraestructura de la ciudad inteligente.
3. **Análisis de aprendizaje automático:** los algoritmos de aprendizaje automático procesan la información en tiempo real para identificar desviaciones de los patrones de referencia, estimar el riesgo clínico y detectar eventos potencialmente críticos (caídas, fatiga extrema, descompensación cardiometabólica).
4. **Generación de alertas clínicas:** cuando se superan los umbrales de riesgo predefinidos, el sistema activa automáticamente una alerta de emergencia, que se envía al hospital inteligente y al centro de coordinación de servicios médicos.
5. **Validación clínica y priorización:** El personal sanitario recibe la alerta junto con el historial médico del paciente y valida el evento, priorizando la atención según la gravedad estimada y las comorbilidades asociadas.
6. **Activación de la respuesta médica:** Se envía inmediatamente una ambulancia y, si es necesario, se habilitan recursos adicionales, como drones médicos, para el suministro de material o la prestación de asistencia inicial.
7. **Comunicación con la red de apoyo:** El sistema notifica simultáneamente a los familiares o cuidadores a través de aplicaciones móviles o videollamadas, informándoles de la situación y de las medidas que se están tomando.
8. **Coordinación con la farmacia y seguimiento:** si se requiere tratamiento farmacológico, se genera una alerta de prescripción a la farmacia vinculada, mientras que el sistema continúa monitoreando y registrando el evento para el análisis clínico y la mejora continua del modelo predictivo.

Desafíos y buenas prácticas

La aplicación de tecnologías de una ciudad inteligente para identificar y monitorear la obesidad sarcopénica plantea varios desafíos. Uno de los principales es lograr que los diferentes dispositivos como: relojes inteligentes, teléfonos móviles, sensores biomédicos y plataformas hospitalarias, puedan comunicarse entre sí de manera eficiente. También es fundamental asegurar que los datos recolectados sean precisos y confiables, ya que de ellos dependen las alertas médicas y las decisiones clínicas. A esto se suma la necesidad de proteger la privacidad de los pacientes, debido a que el sistema maneja información de salud en tiempo real. Finalmente, integrar es-

tas tecnologías en los sistemas de salud existentes requiere infraestructura digital adecuada, capacitación del personal médico y estrategias que permitan aprovechar el análisis de datos y la inteligencia artificial en la atención sanitaria.

Para que este tipo de soluciones funcione de manera efectiva, es importante seguir ciertas buenas prácticas. Entre ellas se encuentra el uso de estándares tecnológicos que permitan que distintos dispositivos y sistemas compartan información sin dificultades. También es clave implementar mecanismos sólidos de seguridad digital para proteger los datos de los usuarios. Otro aspecto relevante es validar los modelos de aprendizaje automático con especialistas en salud antes de aplicarlos en entornos reales. Asimismo, la colaboración entre médicos, ingenieros, científicos de datos y responsables de políticas públicas resulta esencial para desarrollar soluciones integrales. Finalmente, diseñar aplicaciones sencillas y accesibles ayuda a que los pacientes utilicen estas tecnologías con mayor facilidad, favoreciendo el monitoreo continuo y la detección temprana.

Aspectos éticos y filosóficos

El uso de tecnologías de monitoreo continuo en el contexto de ciudades inteligentes plantea importantes consideraciones éticas. Por un lado, es fundamental garantizar la protección de la privacidad y la confidencialidad de los datos de salud de los pacientes, ya que estos sistemas recopilan información personal de manera constante a través de dispositivos y sensores. También es necesario asegurar el consentimiento informado de los usuarios y que comprendan cómo se utilizan sus datos y con qué finalidad. Además, se debe evitar cualquier forma de discriminación o exclusión derivada del uso de algoritmos de aprendizaje automático, garantizando que las decisiones asistidas por tecnología sean transparentes, justas y siempre supervisadas por profesionales de la salud.

Desde una perspectiva filosófica, la integración de tecnologías inteligentes en el cuidado de la salud invita a reflexionar sobre la relación entre el ser humano, la tecnología y el bienestar. En el caso de la obesidad sarcopénica, el uso de sensores, plataformas digitales y sistemas de inteligencia artificial redefine la manera en que se comprende el monitoreo del cuerpo y la prevención de enfermedades. Estas herramientas no solo amplían la capacidad de los sistemas de salud para anticipar riesgos, sino que también plantean preguntas sobre la autonomía del paciente, la dependencia tecnológica y el papel de la inteligencia artificial en la toma de decisiones médicas. En este sentido, las ciudades inteligentes pueden entenderse como entornos donde la tecnología actúa como un apoyo para mejorar la calidad de vida, siempre que se mantenga un enfoque centrado en la persona y en el cuidado integral de la salud.

Conclusión

La incorporación de tecnologías inteligentes en el ámbito de la salud abre nuevas posibilidades para comprender, prevenir y tratar condiciones complejas como la obesidad sarcopénica. En el contexto de las ciudades inteligentes, el uso de sensores, dispositivos portátiles y sistemas de inteligencia artificial permite monitorear de forma continua diferentes indicadores de salud, facilitando la detección temprana de riesgos y la toma de decisiones más informadas por parte de los profesionales sanitarios. Este enfoque contribuye a impulsar un modelo de atención más preventivo, personalizado y basado en datos.

No obstante, el desarrollo de estas soluciones tecnológicas debe ir acompañado de una reflexión sobre su impacto social, ético y humano. El reto no consiste únicamente en innovar desde el punto de vista tecnológico, sino en garantizar que estas herramientas se utilicen de manera responsable, respetando la privacidad de las personas y fortaleciendo su autonomía. De esta manera, las ciudades inteligentes pueden consolidarse como espacios donde la tec-

©2026 SMIA | ISSN 2007-069

nología se convierte en un aliado para mejorar la calidad de vida y promover una atención sanitaria más integral y sostenible. KS

REFERENCIAS

1. Polyzos, S. A., y Margioris, A. N. (2018) "Sarcopenic obesity". Hormones, 17(3), 321-331.
2. Barazzoni, R., et al. (2018) "Sarcopenic obesity: time to meet the challenge". Obesity facts, 11(4), 294-305.
3. Batty, M., et al. (2012) "Smart cities of the future". The European Physical Journal Special Topics, 214(1), 481-518.
4. Zhang, H., et al. (2025) "Assessing Sarcopenia-Prone Risk through Daily Activity of Gait With AI-Powered Wearable IoT Sensors". IEEE Internet of Things Journal.
5. Gong, X. W., et al (2024) "Study of obesity research using machine learning methods: A bibliometric and visualization analysis from 2004 to 2023". Medicine, 103(36).
6. Bernal, M. C., et al (2024) "Artificial intelligence for the study of human ageing: a systematic literature review".
7. An, et al., (2022) "Applications of artificial intelligence to obesity research: scoping review of methodologies". Journal of Medical Internet Research, 24(12).
8. Ribeiro, J. C., et al., (2021) "Associations between inflammatory markers and muscle strength in older adults according to the presence or absence of obesity". Experimental Gerontology, 151.
9. Bedrikovetski, S., et al., (2022) "Artificial intelligence for body composition and sarcopenia evaluation on computed tomography: a systematic review and meta-analysis". European journal of radiology, 149.
10. Onishi, S., et al., (2025) "Artificial intelligence for body composition assessment focusing on sarcopenia". Scientific Reports, 15(1), 1324.
11. Lauretani, F., et al., (2003) "Age-associated changes in skeletal muscles and their effect on mobility: an operational diagnosis of sarcopenia". Journal of applied physiology, 95(5), 1851-1860.
12. Timmins, K. A., et al., (2018) "How has big data contributed to obesity research? A review of the literature". International journal of obesity, 42(12), 1951-1962.

Declaración de uso de IA generativa. : Durante la preparación de este trabajo, los autores utilizaron herramientas de inteligencia artificial generativa como apoyo auxiliar para la elaboración de las Figuras2 y 3, y la resolución de aspectos técnicos relacionadoscon la edición en LaTeX. Todo el contenido generado o sugerido mediante estas herramientas fue revisado, editado y validado por los autores, quienes asumen plena responsabilidad por la versión final del trabajo.

Sobre los autores



Mirta Fuentes Ramos es estudiante del Doctorado en Ciencias de la Ingeniería y Maestra en Sistemas Computacionales por el Instituto Tecnológico Superior de Misantla, Veracruz, México, es Licenciada en Enfermería por el Instituto de Ciencias y Estudios Superiores de Tamaulipas. Sus áreas de interés son la Ciencia de Datos aplicada al área de la Salud y a la rehabilitación física y emocional.



Irahan Otoniel José Guzmán es Doctor en Sistemas Computacionales por La Universidad del Sur, Maestro en Sistemas Computacionales por el Instituto Tecnológico Superior de Misantla e Ingeniero en Sistemas Computacionales por el Instituto Tecnológico de Ciuad Madero; actualmente es Jefe de la carrera de Ingeniería en Sistemas Computacionales y Coordinador del Doctorado en Ciencias de la Ingeniería en el Instituto Tecnológico Superior de Misantla. Sus áreas de interés son el desarrollo de software inteligente y la ciencia de datos.



Carlos Alfonso Tovilla Zárate es Doctor en Ciencias Genómicas por la Universidad Autónoma de la Ciudad de México, pertenece al Sistema Nacional de Investigadoras e Investigadores (SNII), nivel 3; actualmente es profesor-investigador en la División Académica Multidisciplinaria de Comalcalco en la Universidad Juárez Autónoma de Tabasco. Sus áreas de interés son los meta-análisis de psiquiatría, genética y suicidio.



Eddy Sánchez De la Cruz es Doctor en Sistemas Computacionales por La Universidad del Sur, Maestro en Sistemas Computacionales y Licenciado en Informática Administrativa por la Universidad Juárez Autónoma de Tabasco. El Dr. Sánchez De la Cruz es miembro del SNII, nivel 1; actualmente es profesor-investigador en la División de Posgrado e Investigación del Instituto Tecnológico Superior de Misantla. Sus áreas de interés son las metodologías de aprendizaje automático con un enfoque multidisciplinario.

ARTÍCULO

¿Qué se esconde en el pixel? El árbol que le pregunta a las imágenes

Adriana Laura López Lobato y Héctor Gabriel Acosta Mesa

¿Cómo ven las computadoras?

¿Alguna vez te has preguntado cómo le enseñan los expertos en Inteligencia Artificial (IA) a las computadoras a ver el mundo comolo hacemos nosotros? Esa es una de las cosas más fascinantes, y a la vez más complicadas de la IA y de la visión por computadora. Para nosotros es sencillo identificar en una fotografía a una persona al ver su rostro, decir si el animal fotografiado es un perro o un gato, o delinear un objeto, pero para las computadoras no es igual, principalmente porque las computadoras sólo pueden procesar información representada mediante números. Entonces ¿cómo puede una computadora ver algo tan complejo como una fotografía?

Las computadoras son capaces de analizar imágenes con la información que se encuentra en sus píxeles, esos diminutos cuadritos que conforman una imagen y que guardan valores numéricos, de color o transparencia, como se muestra en la Figura 1.



Figura 1. *Radiografía de tórax y representación decómo una computadora interpreta la información dela imagen a nivel de píxel.*

©2026 SMIA | ISSN 2007-069

Para poder analizar una imagen, las computadoras necesitan herramientas que las ayuden a extraer características de la imagen, como bordes, cambios de color, líneas, etc. Las redes neuronales convolucionales (CNNs, por sus siglas en inglés) son en la actualidad las mejores herramientas para el análisis de imágenes por computadora, ya que con ellas se obtienen muy buenos resultados en muchas aplicaciones diferentes. Aunque, tienen un "pero" muy grande, a menudo son llamadas "cajas negras" ya que, aunque dan resultados precisos, es casi imposible saber cómo han llegado a las conclusiones a las que llegan [1]. Son como un mago que hace un truco, pero no revela el secreto.

Hay varias áreas de la ciencia donde la confianza y la transparencia de las herramientas empleadas para analizar imágenes son muy importantes, por ejemplo, en medicina, en economía o en el ámbito militar. Por esta razón se han buscado modelos alternativos que nos ayuden a entender los procesos que llevan a cabo las CNNs y se han propuesto otros que sean directamente "interpretables" o "transparentes" en las diferentes tareas referentes al análisis de imágenes, donde el verdadero desafío no es que la computadora solo "vea" una imagen, sino que entienda lo que ve, idenfitique secciones de interés y obtenga conclusiones solventadas con la información analizada.

En particular, una tarea relevante en el área de visión por computadora es la segmentación de imágenes. Este proceso consiste en enseñarle a la computadora a diferenciar objetos o estructuras que nos interesan de una imagen [2]. Por ejemplo, para el área médica, en la Figura 2, se muestra una radiografía de tórax y el proceso de segmentación, donde se busca identificar los pixeles que pertenecen a los pulmones en color blanco y en color negro al resto de la imagen.

En general, el proceso de segmentación es un proceso complejo, cuyo objetivo es diferenciar la información relevante dentro de una imagen, aquella que puede aportar indicios importantes sobre la presencia de enfermedades. En este contexto, las herramientas de segmentación pueden ayudar al personal médico a identificar estas señales mediante un análisis preciso a nivel de píxel, permitiendo distinguir entre regiones de interés, que permitan identificar patologías.
En este escrito se muestra una propuesta transparente para el proceso de segmentación de imágenes, los árboles de decisión convolucionales, o CDTs por sus siglas en inglés.

Árbol de Decisión Convolucional (CDT)

El árbol de decisión convolucional es una herramienta para llevar a cabo el proceso de segmentación de imágenes [3][4]. Su nombre puede parecer muy complejo, pero en esta sección describiremos sus dos estructuras base:

1. Árbol de decisión
2. Proceso de convolución

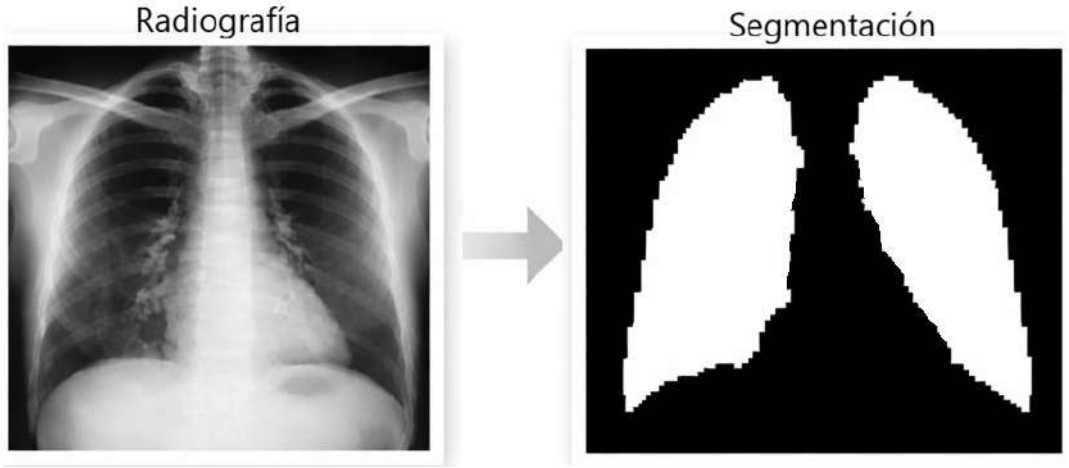


Figura 2. *Radiografía de tórax (izquierda) y susegmentación (derecha).*

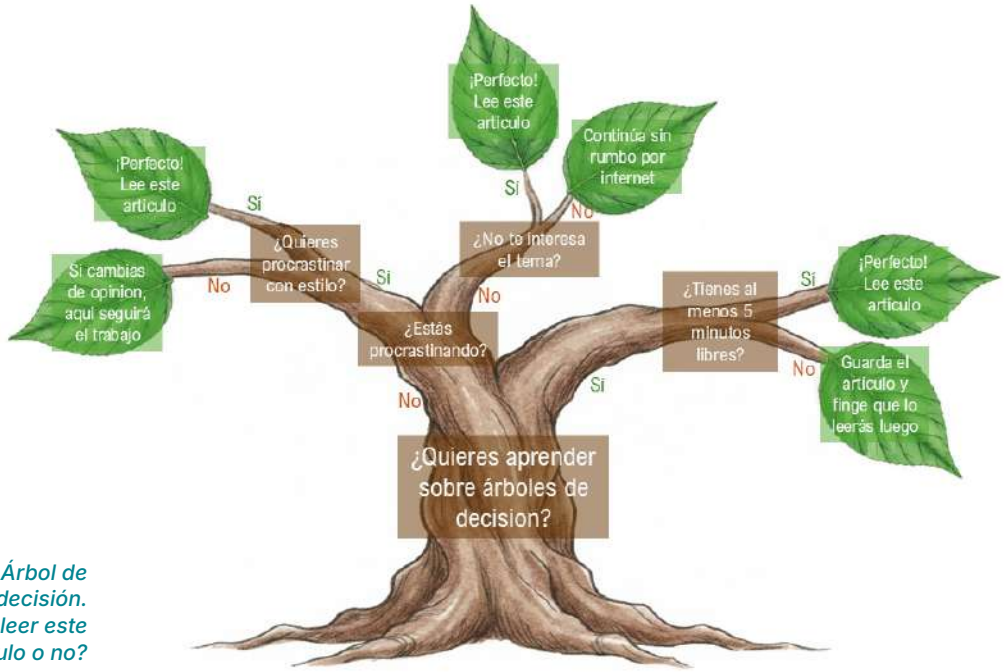


Figura 3. *Árbol de decisión. ¿Debería leer este artículo o no?*

Un **árbol de decisión** es, en esencia, una forma muy organizada de tomar decisiones paso a paso mediante una cadena de preguntas sencillas que, juntas, conducen a una respuesta clara [5]. En la Figura 3, se muestra un ejemplo de árbol de decisión. Básicamente es un diagrama con ramas, como un árbol. En cada bifurcación hay una pregunta. Según tu respuesta (sí o no), sigues una rama distinta. Al final de cada rama hay una hoja, que representa una decisión final. Esperamos que la decisión final que obtuviste sea "¡Perfecto! Lee este artículo".

Pero, ¿por qué utilizamos árboles de decisión? Porque un árbol explica cómo llegó a una conclusión. A diferencia de modelos más complejos, como las CNNs, un árbol hace preguntas simples, sigue un camino claro y muestra exactamente los criterios que usó. Es como un investigador que toma notas y nos deja ver su razonamiento.

Por otro lado, el **proceso de convolución** puede ser visto como pasar una pequeña ventana por una imagen para buscar algo [6]. Imagina que una lupa cuadrada muy pequeña es colocada sobre una imagen, observa lo que hay dentro de su campo de visión, registra de alguna manera lo que encuentra ahí, y luego se mueve un poquito a la derecha. De nuevo mira, registra, y se vuelve a mover hacia la derecha. Y así recorre la imagen completa. Eso es el proceso de convolución, analizar una imagen por secciones pequeñas para crear un "mapa" de lo que encuentra, como se muestra en la Figura 4.

Esta lupa, usualmente llamada kernel o filtro convolucional, no es cualquier lupa, es una lupa entrenada para buscar algo en específico en la imagen. El término filtro hace referencia a que deja pasar únicamente la información relacionada con el patrón que fue diseñada para detectar e ignora, en gran medida, el resto. Puede ser experta en detectar rayas horizontales, o bordes de objetos, o texturas, es decir, es una lupa que ve "patrones" en la imagen. Entonces, cada vez que la lupa se coloca sobre una pequeña sección de la imagen, compara lo que ve con lo que fue entrenada para buscar y produce un número que indica si encontró su patrón preferido o no, generando algo así como un mapa de pistas que marca los lugares donde vio lo que buscaba. A este mapa se le llama "mapa de características". Si la lupa buscaba bordes, el mapa de características muestra dónde vio bordes; si buscaba texturas, el mapa muestra dónde había textura. De esta manera, con el proceso de convolución, las computadoras pueden observar ciertas

©2026 SMIA | ISSN 2007-069

características en una imagen y procesar la información que les sea de utilidad para la tarea que estén realizando.

Ahora, ¿cómo se combinan estos procesos en los árboles de decisión convolucionales (CDTs)?

Para entender la estructura de los CDTs, imagina que existe un grupo de detectives conformado por dos tipos de expertos: el grupo de los kérneles detecta patrones y el detective guía que dirige el interrogatorio. El grupo de detectives tiene una tarea específica: segmentar los pulmones de una persona en una radiografía de tórax, como en la Figura 1.

Antes de que el detective guía comience el interrogatorio, los kérneles recorren cada rincón de la imagen en busca de pistas, uno detecta bordes, otro detecta líneas, otro detecta zonas oscuras. El resultado es un conjunto de informes visuales que resumen las características relevantes de la imagen.

Con todos estos informes sobre la mesa, el detective guía entra en acción, se concentra en un píxel de la imagen en específico y comienza a hacer preguntas de forma ordenada con respecto a los patrones que se observan en la región que encierra a dicho pixel, como se muestra en la Figura 5. ¿En esta sección se encuentra un borde? ¿se observa una zona oscura? ¿hay estructuras blancas? Todas estas preguntas pueden ser respondidas con los mapas de características obtenidos por los kérneles. Cada pregunta es una bifurcación donde las únicas respuestas son “Sí” o “No”, y cada respuesta guía a otra pregunta. De esta manera se tiene la estructura de los árboles de decisión, donde cada pregunta puede ser respondida con los valores obtenidos por un kernel de convolución específico. El interrogatorio continúa hasta llegar a una respuesta final: el pixel es parte de un pulmón o el pixel es parte del fondo de la imagen.

La imagen segmentada se obtiene al llevar a cabo este interrogatorio en el orden establecido por el árbol para cada pixel de la imagen, coloreando el correspondiente pixel de negro si se trata del fondo de la imagen y de blanco si es parte del pulmón que queremos segmentar.

Ahora, ¿cómo encontramos los kérneles adecuados para que el árbol de decisión haga las preguntas correctas? Curiosamente, la respuesta proviene de un lugar que podría parecer ajeno a la informática: la naturaleza.

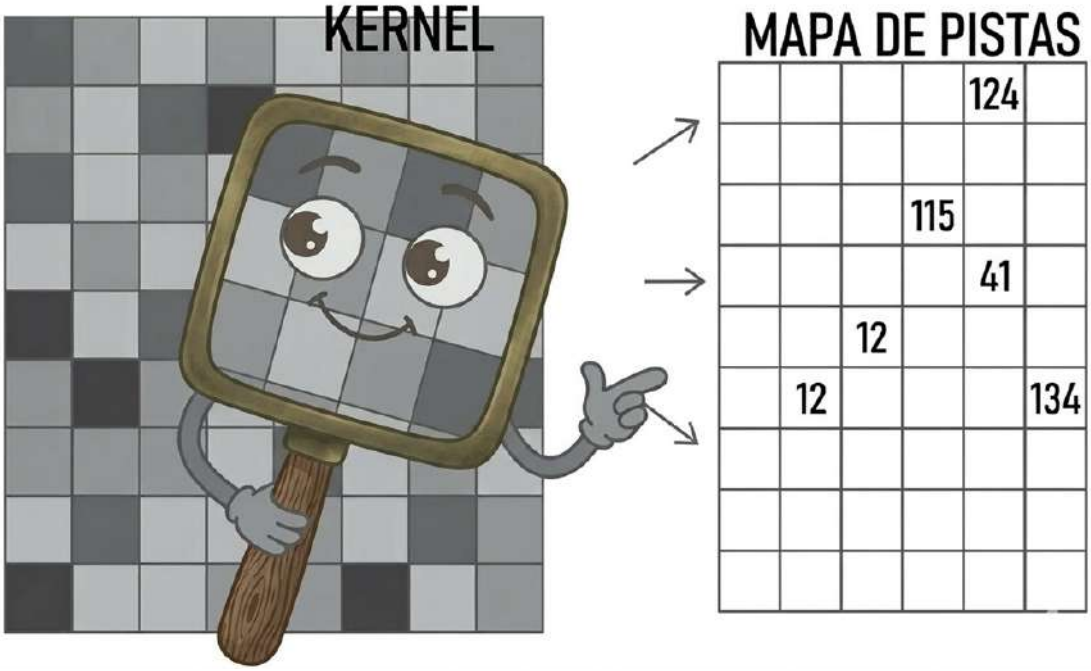


Figura 4. *El proceso de convolución. La lupa cuadrada (kernel) que crea un mapa de pistas.*

En biología evolutiva existe una idea ampliamente conocida: la supervivencia del más apto, donde los organismos que mejor se adaptan a su entorno tienen mayores probabilidades de sobrevivir, reproducirse y transmitir sus características a la siguiente generación. Con el paso del tiempo, este proceso va moldeando las poblaciones y favoreciendo aquellas características que resultan más ventajosas. Inspirados en este mecanismo, los científicos desarrollaron métodos computacionales que imitan este proceso evolutivo para resolver problemas complejos. Uno de ellos es la evolución diferencial, un algoritmo de optimización que hace "competir" a múltiples soluciones posibles hasta encontrar la más adecuada.

El árbol de decisión convolucional (CDT) usa sus kérneles para formular preguntas precisas y revelar información oculta en cada píxel.

Los árboles de decisión convolucionales utilizan el método de evolución diferencial para ajustar progresivamente los valores de los kérneles, hasta identificar aquellos que permiten analizar y segmentar con mayor precision las imágenes de interés [7][8].

Evolución diferencial: encontrar soluciones inspirados en la naturaleza

La Evolución Diferencial (*Differential Evolution*, DE) es un método computacional utilizado para encontrar buenas soluciones a problemas de optimización [9][10]. Funciona con una población de posibles soluciones que se mejora iterativamente mediante tres operadores: mutación, cruza y selección.

A diferencia de otros métodos matemáticos, la evolución diferencial no necesita información compleja sobre el problema, como derivadas. En su lugar, evalúa cada solución mediante una función de ajuste (*fitness*), que indica qué tan bien resuelve el problema. A partir de estas evaluaciones, el algoritmo conserva soluciones que muestran un mejor desempeño.

Una manera de entender este proceso es imaginar a un grupo de exploradores que intentan alcanzar la cima de una montaña, sin conocer previamente el terreno, como se muestra en la Figura 6.

Población: comenzar la exploración.

El proceso inicia con varios exploradores distribuidos al azar en la superficie (Figura 6(a)). Algunos estarán en zonas bajas, otros más cerca de la cima, pero ninguno sabe aún

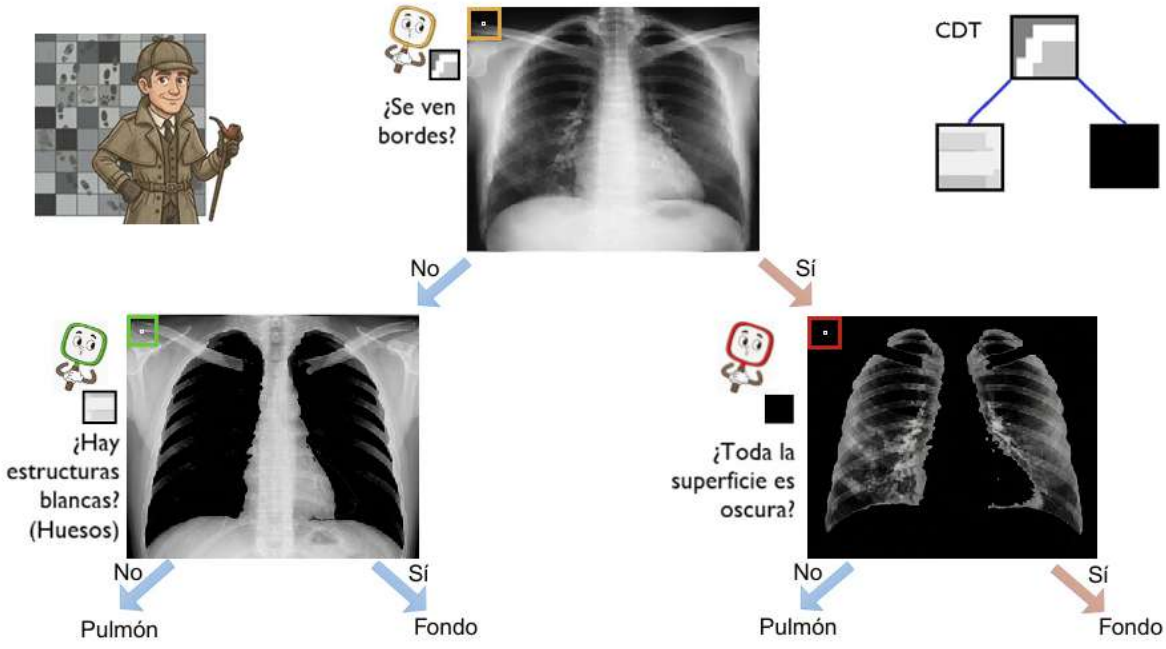


Figura 5. *ACDT: los kérneles detectan patrones en la imagen y el árbol de decisión, como un detective, usa esas pistas para clasificar cada píxel.*

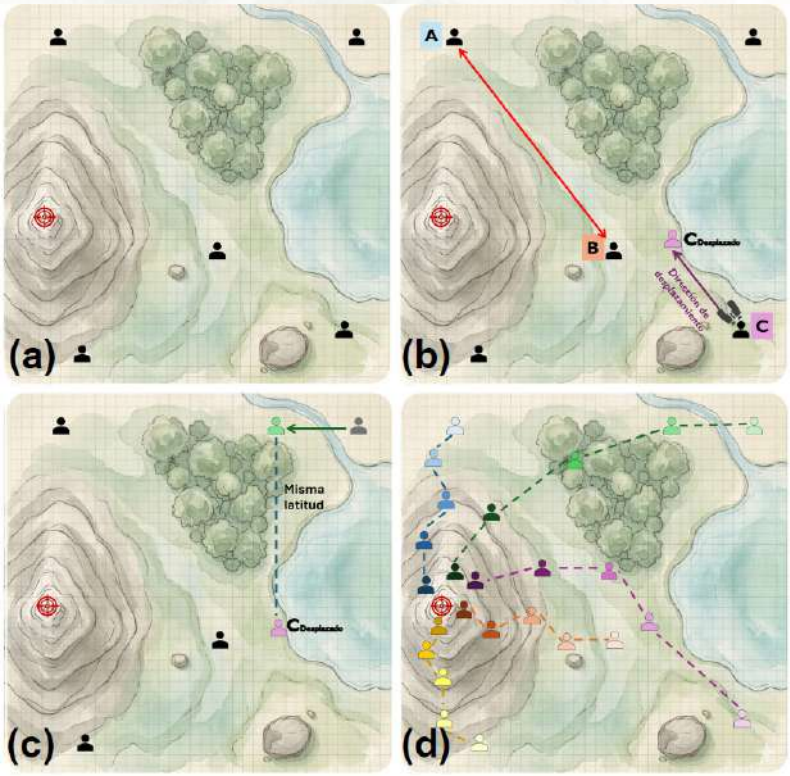


Figura 6. *Algoritmo de evoluci´on diferencial mediante la analogía de exploradores: (a) población inicial distribuida al azar, (b) mutación, (c) cruza y (d) selección de las mejores posiciones.*

cuál es la mejor ruta. Para el proceso evolutivo, cada uno de los exploradores representa una posible solución al problema de optimización. Estas posibles soluciones son intentos iniciales que constituyen el punto de partida del proceso evolutivo.

Reproducción: generar nuevas rutas.
Una vez que existe una población inicial, las soluciones deben generar nuevas variantes que mejoren a las anteriores. En evolución diferencial, este proceso ocurre mediante dos mecanismos principales: mutación y cruza.

Mutación: Siguiendo la analogía de los exploradores, para mejorar sus rutas, estos comparten información y prueban nuevas formas de avanzar. En la mutación, podemos imaginar que un explorador (C) observa a dos de sus compañeros (A y B) con unos binoculares (Figura 6(b)). Al comparar sus posiciones, nota qué tan lejos están entre sí, y utiliza esa diferencia para decidir qué tan grande debe ser su siguiente movimiento. Así, C camina en una nueva dirección basado en esa información.

La mutación no es un cambio completamente aleatorio, sino una forma de aprender de las diferencias entre otros exploradores para explorar nuevas zonas de la montaña de manera más informada.

Cruza: Después ocurre la cruza, que puede entenderse como la creación de un "recorrido híbrido". Otro explorador (D) combina su ruta actual con la nueva propuesta generada en la mutación con el explorador C: por ejemplo, decide adoptar la coordenada de latitud de C, pero mantiene su longitud original (Figura 6(c)). El resultado es una posición intermedia que mezcla lo viejo y lo nuevo. En otras palabras, el explorador prueba parcialmente la nueva idea sin abandonar por completo su trayectoria anterior, generando así un nuevo camino potencial hacia la cima.

Selección: quedarse con las mejores posiciones. El explorador D compara su posición actual con su posición anterior utilizando un altímetro en un "duelo de altura", ya que la idea es acercarse más a la cima de la montaña al ir construyendo su recorrido. El criterio es directo: la posición con mayor

AÑO 18, NO. 3 | SEP-DIC| 2026 | KOMPUTER SAPIENS

altura (mejor valor de *fitness*) es la que permanece, mientras que la otra se descarta. Si la nueva ruta logra llevar al explorador a un punto más alto, reemplaza a la anterior; si no, se mantiene en la original.

Esta competencia asegura que la exploración solo avance cuando realmente hay una mejora, haciendo que, paso a paso, el grupo de exploradores se acerque cada vez más a las zonas más altas de la montaña.

Un proceso de mejora continua

Este ciclo se repite muchas veces. Con cada iteración, los exploradores se agrupan cada vez más cerca de las zonas altas, refinando sus rutas y descartando las menos efectivas. Con el tiempo, el grupo converge hacia la cima o hacia una muy buena aproximación a ella (Figura 6(d)). De este modo, un principio inspirado en la evolución permite a las computadoras buscar soluciones óptimas en problemas complejos, como el encontrar la mejor configuración de un CDT para el problema de segmentación de imágenes.

La evolución diferencial guía a los CDTs hacia filtros más precisos para segmentar imágenes.

Evolución diferencial en los CDTs

Después de entender cómo funciona la evolución diferencial, surge una pregunta natural: ¿qué representan exactamente esas "posiciones en la montaña" en nuestro problema? En el caso de los árboles de decisión convolucionales (CDTs), cada explorador es un árbol completo con una configuración específica de kérneles. Es decir, cada punto en la montaña representa una posible manera de analizar la imagen: qué filtros usar y cómo organizarlos dentro del árbol para tomar decisiones. Desde esta perspectiva, la "altura" que mide qué tan cerca está un explorador de la cima, corresponde a qué tan bien ese árbol segmenta la imagen. Por ejemplo, qué tan correctamente identifica los pulmones en una radiografía.

Así, la evolución diferencial actúa como un proceso de búsqueda inteligente: La población inicial corresponde a muchos CDTs generados al azar. La mutación y la cruza combinan y ajustan sus kérneles para crear nuevos árboles. La selección conserva aquellos que logran una mejor segmentación. Con cada iteración, los "exploradores" (es decir, los CDTs) se mueven hacia configuraciones cada vez más efectivas. El resultado final es un árbol cuyos kérneles han sido ajustados automáticamente para extraer la información más relevante de las imágenes.

Conclusiones

Los árboles de decisión convolucionales (CDTs) representan una forma interesante de combinar tres ideas poderosas en inteligencia artificial. Por un lado, los árboles de decisión aportan interpretabilidad, ya que organizan el proceso en una secuencia de "preguntas" que permiten entender cómo se toma una decisión. Por otro, la convolución permite analizar imágenes a nivel local, píxel por píxel, identificando patrones relevantes como bordes o texturas. Finalmente, la evolución diferencial ofrece un mecanismo para ajustar estos modelos, explorando distintas configuraciones hasta encontrar aquellas que mejor resuelven el problema.

En conjunto, estos elementos permiten construir modelos capaces de analizar imágenes de manera precisa y comprensible, algo especialmente valioso en contextos donde no solo importa el resultado, sino también entender cómo se obtuvo, como en el ámbito médico. En particular, la capacidad de segmentar regiones específicas (como los pulmones en una radiografía) abre la puerta a herramientas de apoyo para el diagnóstico clínico, facilitando una interpretación más rápida de las imágenes y contribuyendo a agilizar la detección de posibles anomalías por parte de los especialistas.

©2026 SMIA | ISSN 2007-069

Más allá de este caso, los CDTs ilustran una idea central en la inteligencia artificial moderna: la combinación de métodos simples puede dar lugar a sistemas complejos y potentes. Al integrar interpretación, análisis local de imágenes y estrategias de optimización inspiradas en la naturaleza, se logra un equilibrio entre rendimiento y claridad. En este sentido, los CDTs no solo son una herramienta técnica, sino también un ejemplo de cómo distintas áreas del conocimiento (la lógica, el procesamiento de imágenes y la biología) pueden converger para resolver problemas reales. KS

REFERENCIAS

1. Molnar C. (2022) "Interpretable Machine Learning: A Guide for Making Black Box Models Explainable (2nd Edition)". Disponible en: https://christophm.github.io/interpretable-ml-book
2. Minaee S., Boykov Y., Porikli F., Plaza A., Kehtarnavaz N. y Terzopoulos D. (2021) "Image Segmentation Using Deep Learning: A Survey". IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 44, No. 7, pp. 3523–3542.
3. Barradas Palmeros J. A., Mezura Montes E., Acosta Mesa H. G., Márquez Grajales A. y Rivera López R. (2023) "Induction of Convolutional Decision Trees with Differential Evolution for Image Segmentation". En: Proc. Congreso Mexicano de Inteligencia Artificial, Vol. 8.
4. López-Lobato A.-L., Acosta-Mesa H.-G. y Mezura-Montes E. (2025) "Induction of Convolutional Decision Trees for Semantic Segmentation of Color Images Using Differential Evolution and Time and Memory Reduction Techniques". Mathematical and Computational Applications, Vol. 30, No. 3, p. 53.
5. Bishop C. M. (2006) "Pattern Recognition and Machine Learning". Springer.
6. Gonzalez R. C. (2009) "Digital Image Processing". Pearson Education India.
7. López-Lobato A.-L., Acosta-Mesa H.-G. y Mezura-Montes E. (2024) "Blood Cell Image Segmentation Using Convolutional Decision Trees and Differential Evolution". En: Advances in Computational Intelligence. MICAI 2023 International Workshops, pp. 315–325. Springer Nature Switzerland.
8. López-Lobato A.-L., Acosta-Mesa H.-G. y Mezura-Montes E. (2024) "Computational Time Reduction in the Induction of Convolutional Decision Trees". En: Proc. Mexican International Conference on Artificial Intelligence, pp. 99–111. Springer.
9. Eiben A. E. y Smith J. E. (2015) "Introduction to Evolutionary Computing". Springer.
10. Ahmad M. F., Isa N. A. M., Lim W. H. y Ang K. M. (2022) "Differential Evolution: A Recent Review Based on State-of-the-Art Works". Alexandria Engineering Journal, Vol. 61, No. 5, pp. 3831–3872.

Declaración: Durante la preparación de este trabajo, los autores utilizaron Gemini Nano Banana para generar algunos componentes de las imágenes presentadas en el artículo. Después de utilizar esta herramienta, los autores revisaron y editaron el contenido de las imágenes según fuera necesario, y asumen plena responsabilidad por lo publicado.

Sobre los autores



Adriana Laura López Lobato es investigadora posdoctoral en el Instituto de Investigaciones en Inteligencia Artificial de la Universidad Veracruzana. Obtuvo los grados de Licenciatura, Maestría y Doctorado en Matemáticas en la Facultad de Matemáticas de la misma universidad. Su trabajo se centra en las matemáticas aplicadas, el modelado matemático y la optimización, integrando herramientas computacionales y de programación. Sus intereses incluyen el desarrollo de modelos interdisciplinarios para la aplicación de métodos matemáticos en áreas como la medicina y el análisis de alimentos.



Héctor Gabriel Acosta Mesa. Doctor en inteligencia artificial con especialidad en análisis de imágenes por la Universidad de Sheffield, Inglaterra (2003). Profesor-Investigador de tiempo completo del Instituto de Investigaciones en Inteligencia Artificial de la Universidad Veracruzana desde 2004. Miembro del Sistema Nacional de Investigadores desde 2005, actualmente nivel I. Vocal de la Sociedad Mexicana de Ciencia de la Computación. Autor de diversos artículos de investigación especializados en el área de análisis de imágenes médicas utilizando visión computacional. Actualmente trabaja en el proyecto de investigación: Redes Neuronales Convolucionales Aplicadas al Análisis de Imágenes Biomédicas.

ARTÍCULO

IA Verde: El arte de cocinar algoritmos sin calentar el planeta

Nancy Pérez Castro y Efrén Mezura Montes

La IA que todos ven, y la que casi no se menciona



Hoy en día, cuando se habla de inteligencia artificial (IA),muchas personas piensan primero en chatbots (como ChatGPT, Claude, Gemini), asistentes virtuales (como Alexa o Siri) o generadores de imágenes.Sin embargo, la IA es mucho más amplia que sus formas más visibles.Así como un árbol tiene muchas ramas, la IA agrupa familias de métodos muy distintos entre sí que resuelven problemas diferentes.

Algunas de las familias que se pueden encontrar dentro de la IA son el aprendizaje automático, aprendizaje profundo, sistemas expertos, lógica difusa, visión por computadora, robótica, procesamiento del lenguaje natural, algoritmos bioinspirados, entre otras. Las IAs generativas como los chatbots o los generadores de imágenes, son las más conocidas hoy en día, y se apoyan principalmente de redes neuronales de gran escala y del procesamiento de lenguaje natural.

Independientemente de la familia de métodos que se esté usando, de las más populares o no, lo que pocas veces se menciona es que detr´as de cada respuesta generada, de cada imagen creada o de cada bu´squeda inteligente existe un costo invisible, el costo de energía asociado al uso de enormes centros de datos, servidores de menor tamaño o una simple computadora de escritorio. Este consumo deja una marca que puede ser medida y que impacta directamente al medio ambiente, esa medida esconocida como huella de carbono.

Usualmente se expresa como dióxido de carbono equivalente (CO_2 eq), aunque esta medida puede incluir otros gases de efecto invernadero. Pero, ¿qué es el efecto invernadero? En términos sencillos, es un fenómeno natural en el que ciertos gases presentes en la atmósfera retienen parte del calor que proviene del Sol y ayudan a mantener una temperatura adecuada para la vida en la Tierra [1].

El problema surge cuando las actividades humanas incrementan la concentración de estos gases, haciendo que se atrape más calor del necesario y favoreciendo el aumento de la temperatura global. La Figura 1 muestra de forma ilustrativa el fenómeno del efecto invernadero y cómo

©2026 SMIA | ISSN 2007-069

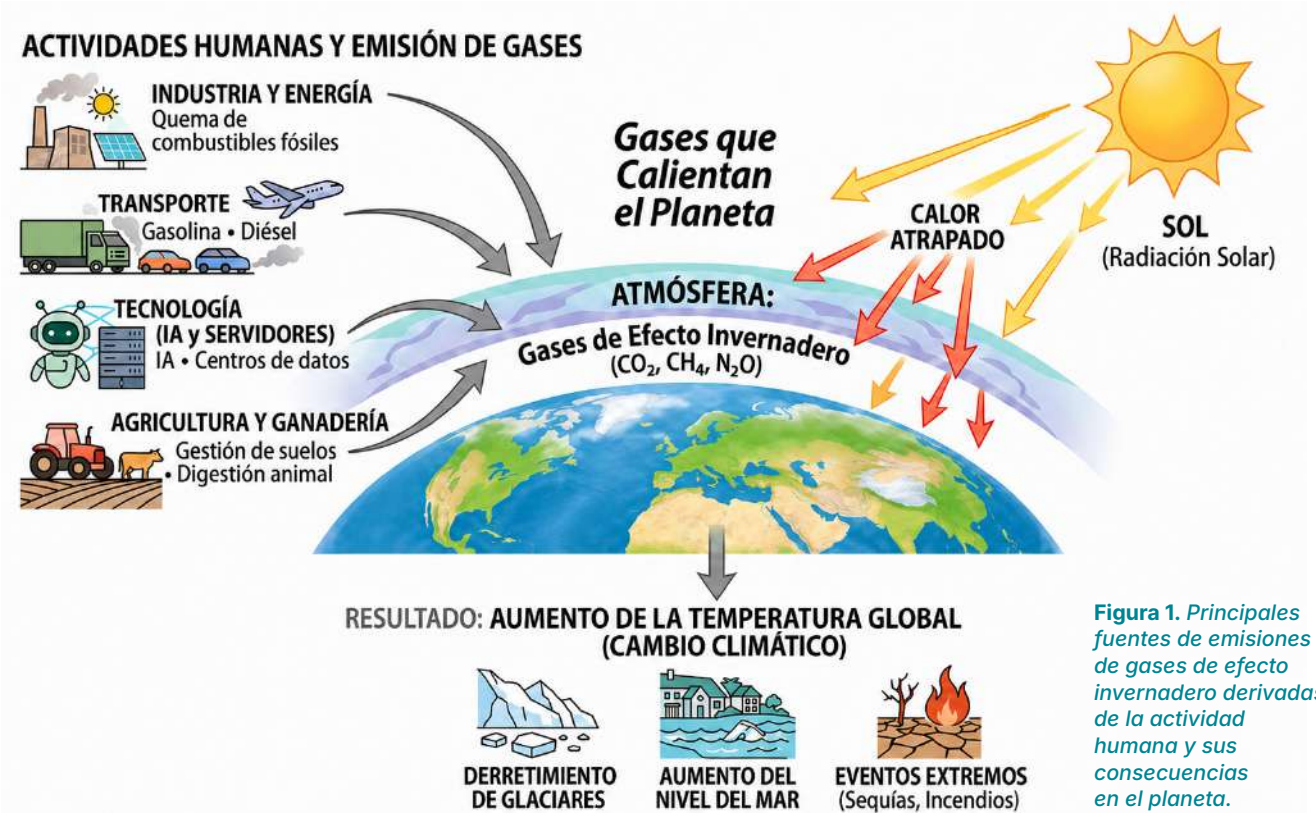


Figura 1. *Principales fuentes de emisiones de gases de efecto invernadero derivadas de la actividad humana y sus consecuencias en el planeta.*

distintas actividades humanas, incluidas la tecnología y la inteligencia artificial, contribuyen a la emisión de CO_2 eq. En este contexto surge la IA verde, que se define como un paradigma que busca desarrollar sistemas más respetuosos con el medio ambiente e inclusivos, priorizando la obtención de resultados precisos sin aumentar los costos computacionales ni la huella de carbono. Este enfoque se divide en dos estrategias principales: la *Green-in AI*, que se centra en el diseño de algoritmos y modelos inherentemente eficientes desde su creación,y la *Green-by AI*, que utiliza la IA como una herramienta para resolver desafíos ambientales y optimizar la sostenibilidad en diversos sectores [2].

La popularidad de las IA generativas y su elevada demanda computacional han motivado estudios orientados a cuantificar su huella ambiental [3]. La Figura 2 presenta la comparación de seis modelos representativos en un análisis más amplio que evaluó más de 70 modelos. Entre ellos, Gemini Ultra (≈37,620 t CO_2 eq) y GPT-4 (≈21,890 t CO_2 eq) destacan por registrar algunos de los niveles de emisiones más altos reportados. Estos resultados son relevantes porque permiten dimensionar el costo ambiental del desarrollo de esta tecnología y respaldan la necesidad de establecer límites o criterios de sostenibilidad. Conviene precisar que estos valores corresponden únicamente a una sola ejecución de entrenamiento.

También existen algoritmos diseñados para resolver problemas difíciles de otra naturaleza, como buscar configuraciones óptimas, planificar rutas, ajustar diseños o tomar decisiones entre miles o millones de posibilidades. En ese grupo destacan los algoritmos evolutivos, que, aunque son menos famosos que la IA generativa, resultan especialmente poderosos para encontrar buenas soluciones en escenarios complejos. Su importancia radica en que amplían el alcance de la inteligencia

La huella de carbono mide gases de efecto invernadero emitidos directa o indirectamente por actividades humanas.

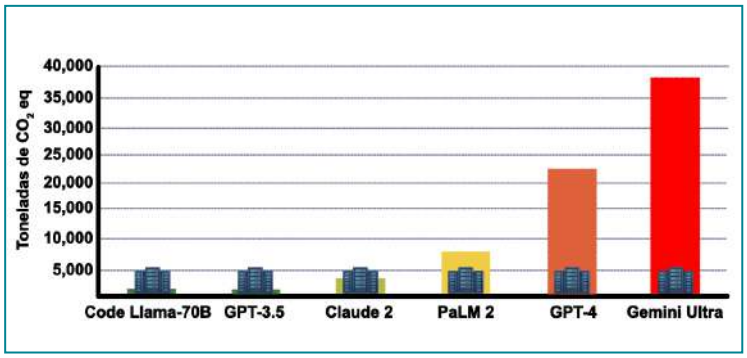


Figura 2. *Emisiones de carbono generadas por una sola ejecución de entrenamiento de modelos de IA seleccionados [3].*

artificial más allá del contenido generado y la convierten en una herramienta útil para resolver retos reales en la ciencia, ingeniería e industria. Dado que también requieren energía para operar, forman parte de la conversación sobre el impacto ambiental de la IA. Entre estos métodos,uno de los más representativos es el algoritmo genético (AG), cuyo funcionamiento y relevancia ambiental se describirán en las siguientes secciones.

¿Qué es y cómo funciona un AG?

Los AGs son una familia de métodos de búsqueda y optimización inspirados en la evolución biológica, por lo que forman parte de los llamados algoritmos evolutivos dentro del campo de la IA. Su desarrollo moderno se asocia al investigador John Holland, quien los propuso en la década de 1970 [4]. Se les considera métodos "inteligentes" porque pueden explorar por sí mismos una gran cantidad de soluciones posibles y, apartir de mecanismos parecidos a la selección natural, ir conservando y combinando las más prometedoras hasta encontrar soluciones de muy buena calidad.

A diferencia de otras herramientas de IA más conocidas, como las que reconocen tu voz o recomiendan películas, que necesitan aprender de miles o millonesde ejemplos previos, los AG no requieren haber visto antes la respuesta correcta. Brillan cuando el problema es demasiado grande para revisarse opción por opción, o cuando no hay datos históricos de dónde aprender. Lo que sí necesitan es una forma de representar el problema y una manera de medir qué tan buena escada solución posible. Así, un AG no explora cada alternativa de solución, una por una, sino que va evolucionando y aprendiendo hasta encontrar una buena solución.

Para entender de manera sencilla cómo funciona un AG, imaginemos un concurso de cocina en el que se busca encontrar la receta perfecta de enchiladas, un platillo tradicional mexicano, sin saber desde el inicio cuál es la mejor forma de prepararlas ni cómo deberían lucir. En este concurso, varias recetas compiten, se prueban, se comparan y se van ajustando poco a poco, demodo que en cada rondas urgen propuestas cada vez mejores. Con esta analogía, a continuación se explican las principales etapas de un algoritmo genético, resumidas en la Figura 3.

Etapa de pre-concurso.

Representación y restricciones: Antes de encenderla estufa, se preparan los ingredientes.Cada receta se representa como una listade números, por ejemplo,los gramos de cada ingrediente, y se fijan límites razonables, como un máximo de 30 minutos de fuego, para garantizar que ninguna propuesta resulte imposible de preparar.

Procedimiento del concurso.

1. Primer lote al azar: Se generan veinte recetas aleatorias.Ninguna es perfecta todavía, pero juntas forman el punto de partida sobre el que todo lo demás evoluciona.
2. Ciclo generacional: Mientras no se alcance la receta ganadora:
   - Cata de eficiencia: El jurado califica cada receta premiando el mejor sabor con el menor consumo de gas o electricidad.
   - Selección de finalistas: Las recetas más eficientes tienen más posibilidades de generar variantes. Ocasionalmente se permite participar a alguna menos destacada para mantener la variedad del recetario.
   - Mezcla de secretos: Las recetas seleccionadas se combinan por parejas, generando versiones que heredan proporciones de ambas.
   - El toque inesperado: Se introduce un cambio pequeñoy aleatorio en

©2026 SMIA | ISSN 2007-069

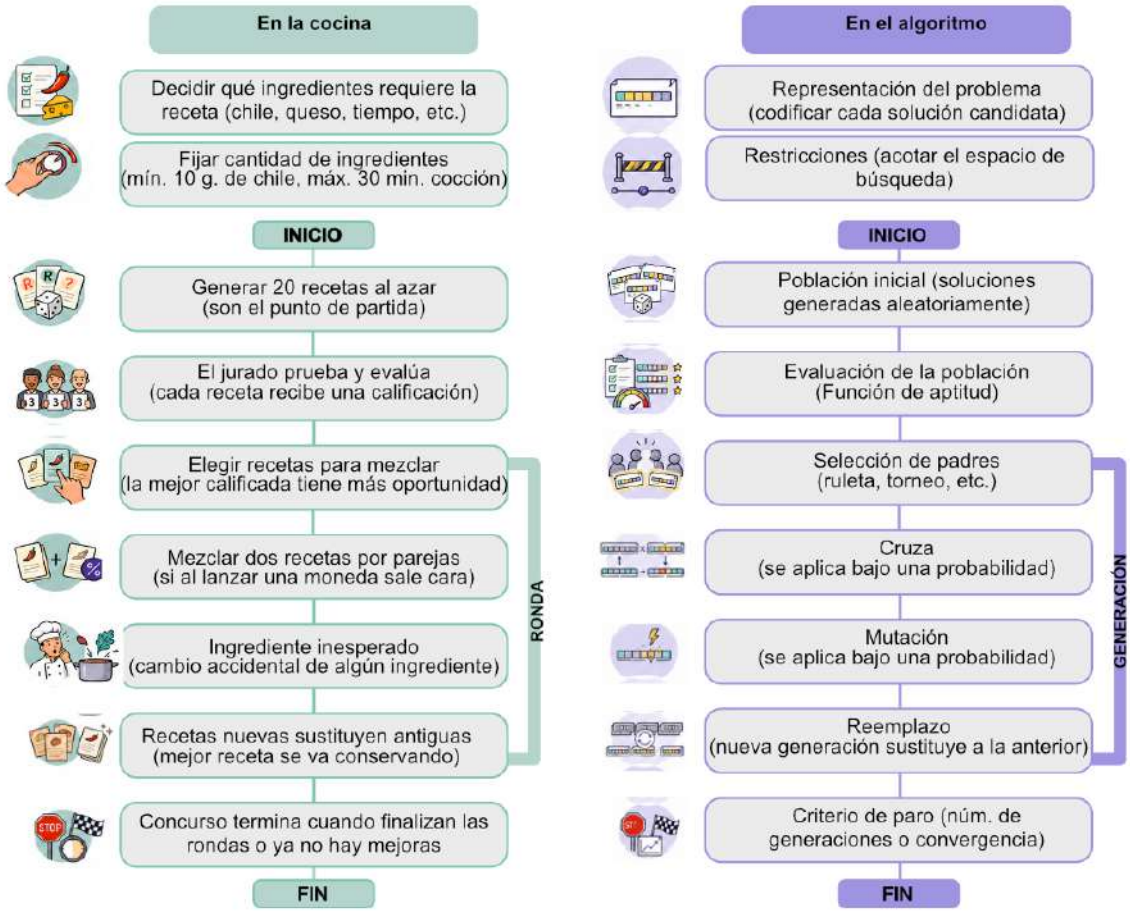


Figura 3. *De la cocina al algoritmo, analogía evolutiva para encontrar la receta ideal.*

algún ingrediente para evitar que todas las recetas converjan hacia la misma fórmula.

- **Nueva generación:** Las recetas variantes o descendientes sustituyen a las anteriores.Si alguna resulta menos eficiente que la mejor del ciclo previo, esa se conserva para no perder el avance logrado.

3. **Receta ganadora.** Tras cientos de generaciones, el algoritmo entrega la receta que mejor equilibra sabor y ahorro energético.

Así, lo que comenzó con unpuñado de ingredientes al azar se convierte, tras muchas rondas de prueba y error, en la receta ideal. El AG no es más que un chef digital incansable que, al heredar los mejores sabores de una generación a otra, encuentra soluciones brillantes en un mar de posibilidades.

Midiendo el humo de la cocina digital

Imagina que preparar un solo plato de enchiladas en casa consume apenas una pizca de gas y electricidad. Sin embargo, el secreto de los AGs es que no cocinan una sola vez; para encontrar la receta perfecta, el concurso debe repetirse durante decenas, cientos o incluso miles de veces (iteraciones o generaciones). En el mundo digital, este esfuerzo constante de la computadora no es gratuito. Cada vez que el algoritmo evalúa una solución, mezcla ingredientes o introduce un cambio al azar, la computadora consume energía eléctrica. Aunque no vemos humo saliendo del procesador, esa energía proviene de fuentes que, en su mayoría, liberan gases a la atmósfera, lo que conocemos como huella de carbono, como se muestra en la Figura 4.

Si bien el impacto de una sola receta puede parecer insignificante, cuando estos algoritmos se usan a gran escala para resolver problemas complejos en la industria o la ciencia, esos pequeños consumos se acumulan. Es aquí donde surge una pregunta vital para

AÑO 18, NO. 3 | SEP-DIC| 2026 | KOMPUTER SAPIENS

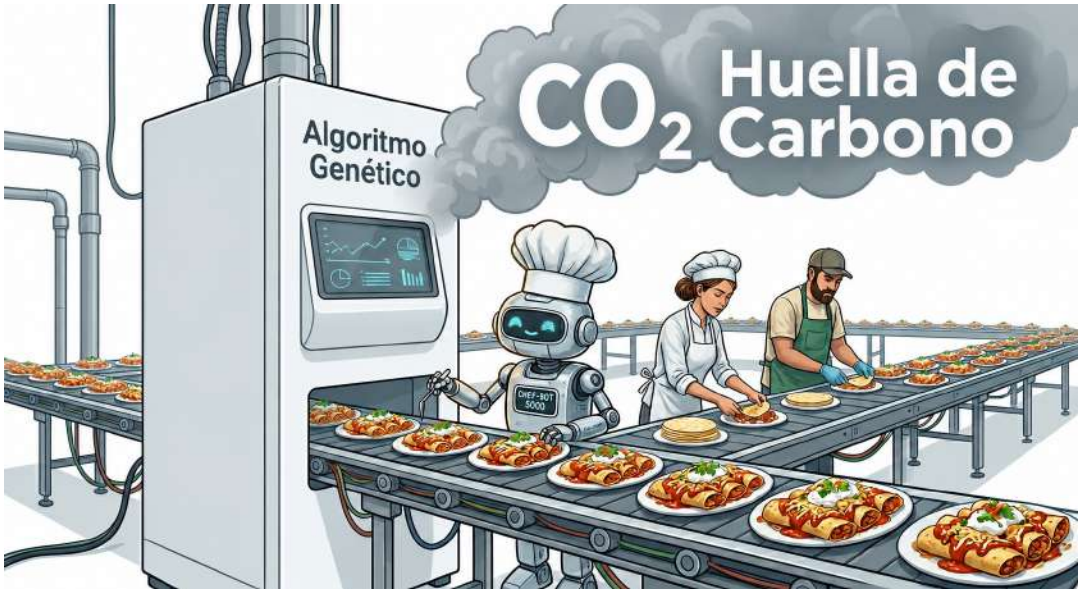


Figura 4. El "humo digital" como una analogía del impacto ambiental de la IA.

la IA Verde: ¿estamos gastando más energía de la necesaria por no elegir bien nuestros ingredientes digitales?

Como hemos visto, en este concurso de cocina digital no todo el humo es visible. Medir el impacto ambiental de un algoritmo, es decir, su huella de CO_2 eq, implica considerar variables técnicas como el consumo energético del hardware, el tiempo de ejecución, el tipo de equipo utilizado y la matriz energética del lugar donde se realiza el cómputo. A partir de estos elementos es posible estimar las emisiones generadas.En términos generales, estas emisiones pueden estimarse a partir de una relación entre la energía consumida y el factor de emisión asociado a la fuente eléctrica local empleada, como semuestra en la siguiente fórmula: CO_2 eq=E x I_c. Donde E es la energía consumida (en kWh) e $I_c$es la intensidad de carbono de la red eléctrica local (en gCO_2 eq/kWh). En la Figura 5, se puede ver el índice de emisión de algunos países representativos.El índice de emisión de carbono en México se sitúa aproximadamente entre 438 y 463 gramos de

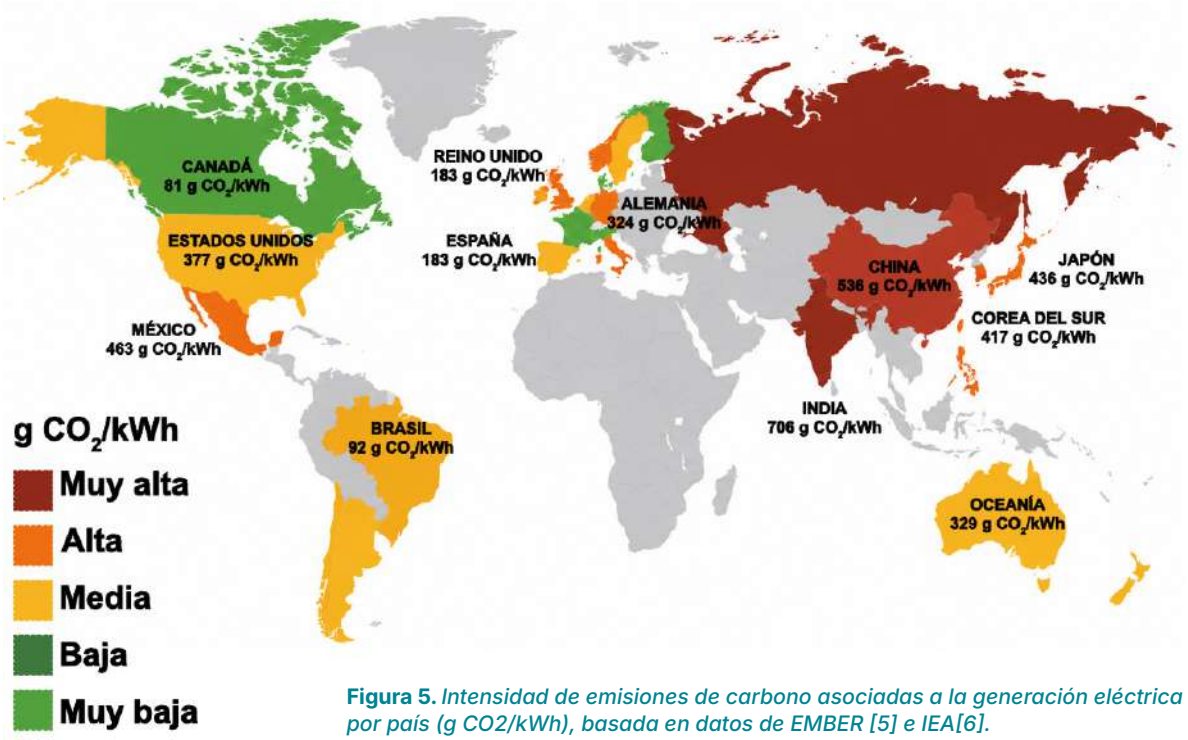


Figura 5. *Intensidad de emisiones de carbono asociadas a la generación eléctrica por país (g CO2/kWh), basada en datos de EMBER [5] e IEA[6].*

©2026 SMIA | ISSN 2007-069

CO_2 eq por kWh consumido de la red nacional, según datos de la CFE y estimaciones técnicas.

Por ello, la emisión de carbono de un algoritmo varía según el país donde se ejecute. Debido a la complejidad del cálculo, se han desarrollado herramientas especializadas que automatizan la estimación de CO_2 eq en la ejecución de código. La Figura 6 presenta cuatro herramientas representativas para este propósito[7].



Figura 6. *Comparación de herramientas para estimar emisiones en carbono: enfoques de medición en código (CodeCarbon, CarbonTracker) frente a estimaciones externas (Green Algorithms, MLCO2).*

¿Qué pasos de la cocina ensucian más el aire? Un estudio real

Ahora que conocemos las reglas de nuestro concurso de cocina digital, es fácil notar que el proceso no es gratuito. Para encontrar la receta ganadora, la computadora debe mantener la cocina encendida durante cientos o incluso miles de generaciones, repitiendo el ciclo de evaluación, mezcla y cambio una y otra vez. Este esfuerzo constante consume ciertos recursos, lo que se traduce en una huella de carbono que depende de qué tan limpia sea la red eléctrica de nuestro país. Para saber exactamente cuánto "humo digital" produce esta cocina, llevamos acabo un estudio empírico y a publicado [8], donde medimos la emisión de carbono mediante la herramienta CodeCarbon.

Montaje del concurso: El experimento se planteó como un concurso controlado de enchiladas, donde el rGA actuá como el equipo de cocineros que mejora recetas por prueba, combinación y ajuste. Se consideraron cuatro problemas con diferentes niveles de dificultad, representados como cuatro platillos de enchiladas con formas distintas, como se representan en la Figura 8. Cada platillo corresponde a un escenario de evaluación y permite analizar qué tan bien el algoritmo logra encontrar la mejor "receta". Para ello, se realizaron hasta 500,000 evaluaciones por prueba, es decir, se prepararon y compararon numerosas versiones antes de seleccionar la mejor. Además, se midió el CO_2 eq generado durante el proceso, representado en la analogía como la cantidad de "humo digital" producida al preparar todas esas versiones.

Pusimos a prueba seis formas de combinar las recetas (operadores de cruza): 1) SA, mezcla dos recetas en distintas proporciones, 2) TA, integra todos sus ingredientes, 3) INT, crea una versión intermedia, 4) 1P, intercambia ingredientes después de



Figura 7. *Operadores de cruza y mutación ilustrados con la analogía de recetas de enchiladas.*

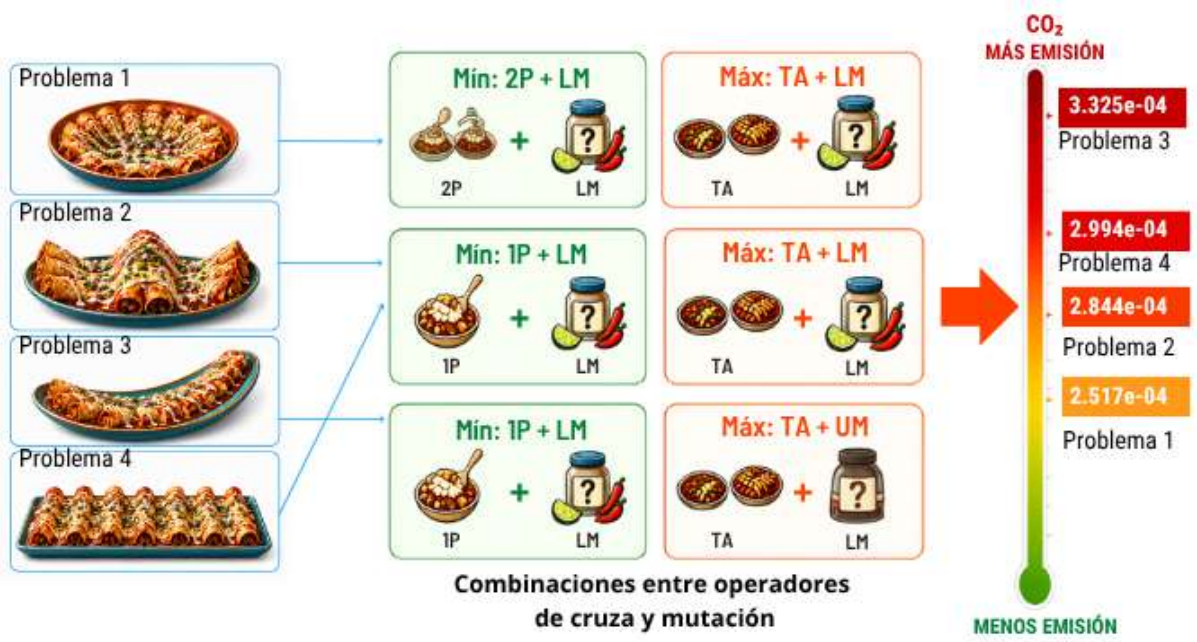


Figura 8. *Resultados del experimento donde se midieron las emisiones de carbono del rGA.*

un corte, 5) 2P, intercambia la sección entre dos cortes y 6) UNI, elige al azar qué conservar de cada receta. También evaluamos cuatro formas de introducir cambios (operadores de mutación): 1) UM, modifica ingredientes al azar, 2) NUM, realiza ajustes cada vez menores, 3) LM, lleva un ingrediente a su valor mínimo o máximo y 4) PM, genera cambios de distintamagnitud. Las siglas provienen de los nombres de los operadores en inglés y se ilustran en la Figura 7. Al combinar cada operador de cruza con cada operador demutación, se obtuvieron 24 combinaciones diferentes. Para representar la combinación de un operador de cruza con uno de mutación, se usa un guión bajo entre sus siglas, por ejemplo, 2P_LM indica la cruza de dos puntos combinada con la mutación de límite. Para asegurar que los datos no fueran obra de la casualidad, cada combinación se repitió 25 veces de forma independiente. Mientras los chefs digitales trabajaban, la herramienta CodeCarbon monitoreaba el consumo eléctrico del procesador y la memoria, calculando la huella de carbono según la intensidad eléctrica local, en México.

El veredicto del concurso:

Tras mútiples rondas del concurso, la Figura 8 presenta los resultados mediante un "termómetro de emisiones". Aunque todas las combinaciones buscaban la mejor receta, la cantidad de "humo digital" generada varió según el problema y los operadores utilizados. Los niveles más bajos de CO_2 eq se obtuvieron principalmente con 2P_LM en el Problema 1 y con 1P_LM eno tros retos, lo que indica que las cruzas de uno o dos puntos, combinadas con la mutación de límite, fueron generalmente las alternativas más eficientes.

En contraste,TA_LM produjo las mayores emisiones en los Problemas 1, 2 y 3, mientras que TA_UM registró el valor máximo en el Problema 4. El nivel más alto del estudio se observó en el Problema 3, con $3{,}325\times10^{-4}$ kg de CO_2 eq. Aunque estas emisiones son pequeñas de manera individual,la diferencia entre las zonas verde y roja del termómetro muestra que la elección de los operadores puede modificar el costo ambiental del proceso de búsqueda. Por lo tanto, seleccionar combinaciones eficientes permite reducir la huella de carbono sin dejar de buscar soluciones de buena calidad.

Conclusiones

En última instancia, nuestro recorrido por esta cocina digital nos ha demostrado que la IA Verde no es solo un concepto teórico, sino

©2026 SMIA | ISSN 2007-069

una responsabilidad práctica que recae en el diseño mismo de la tecnología. El estudio realizado confirma que la forma en que configuramos un algoritmo eligiendo qué utensilios u operadores utilizamos, influye directamente en cuánta energía consume y cuánto "humo digital" se libera en la atmósfera. Hemos aprendido que combinaciones como 1P_LM y 2P_LM no solo son capaces de resolver retos complejos, sino que lo hacen siendo las opciones más respetuosas con el medio ambiente, logrando las emisiones de carbono más bajas de manera constante.Aunque los gramos de CO_2 eq generados en un solo experimento parezcan pequeños, su impacto acumulado cuando estos algoritmos se escalan a nivel industrial puede incrementar. No basta con encontrar el algoritmo más eficaz, el verdadero reto es lograr que su diseño y ejecución no dejen una huella ambiental irreversible en el planeta. KS

REFERENCIAS

1. BBVA (2022)¿Qué es la huella de carbono y cómo entender este indicador ambiental? Disponible en BBVA. Recuperado el 1 de marzo de 2026.
2. Bolón-Canedo V., Morán-Fernández L., Cancela B., Alonso-Betanzos A. (2024) Are view of green artificial intelligence: Towards a more sustainable future. Neurocomputing Vol. 599, 128096.
3. Yu Y., Wang J., Liu Y., Yu P.,Wang D., Zheng P., Zhang M. (2024) Revisit the environmental impact of artificial intelligence: the overlooked carbon emission source?. Front. Environ. Sci. Eng. Vol. 18 (12), 158.
4. Katoch S., Chauhan S.S., Kumar V. (2021) A review ongenetic algorithm: past, present, and future. Multimed. Tools Appl. Vol. 80, 8091–8126.
5. Graham E., Fulghum N., Altieri K. (2025) Global Electricity Review 2025. Ember. https://ember-energy.org/countries-and-regions/world/
6. International Energy Agency (2024) Emission Factors 2024: Data base Documentation. IEA Publications.
7. Bouza L., Bugeau A., Lannelongue L. (2023) How to estimate carbon foot print when training deep learning models? A guide and review. Environ. Res. Commun.Vol. 5(11), 115014.
8. Pérez-Castro N., Mezura-Montes E., Acosta-Mesa H.G. (2026) The Impact of Crossover and Mutation on Carbon Emissions in Real-Coded Genetic Algorithm: An Empirical Study. In: Martínez-Villa señor L., et al. (eds) Advances in Computational Intelligence. MICAI 2025 International Workshops. Lecture Notes in Computer Science, Vol. 16265. Springer, Cham.

Declaratoria de uso de IA:
En la elaboración de este artículo de divulgación se utilizó Claude Sonnet 4.6 (Anthropic) como asistente de revisión ortográfica y estilo del texto. Las imágenes de apoyo visual fueron generadas y editadas con apoyo de ChatGPT, modelo GPT-5.5 Thinking, de OpenAI.

Sobre los autores



Nancy Pérez Castro obtuvo el grado de Doctora en Inteligencia Artificial por la Universidad Veracruzana, donde actualmente es investigadora posdoctoral. Cuenta con el Nivel I del Sistema Nacional de Investigadoras e Investigadores. Es miembro regular de la Academia Mexicana de Ciencias de la Computación y tesorera de la Sociedad Mexicana de Ciencia de la Computación. Sus intereses científicos incluyen la inteligencia artificial verde, la inteligencia computacional y el AutoML.



Efrén Mezura Montes es Director del Instituto de Investigaciones en Inteligencia Artificial de la Universidad Veracruzana. Diseña y estudia algoritmos inspirados en la naturaleza para el aprendizaje computacional y la optimización. Ha publicado más de 200 artículos y cuatro libros, más de 12,600 citas en Google Scholar. Miembro Nivel III del SNII, presidente de la Sociedad Mexicana de Ciencia de la Computación, miembro regular de la Academia Mexicana de Ciencias y de la Academia Mexicana de Computación y miembro del Comité Técnico Asesor de la Red Nacional de Inteligencia Computacional Aplicada. Editor asociado de ocho revistas JCR y miembro de comités de la IEEE en inteligencia artificial. Premio Estatal de Ciencia y Tecnología 2023 en Veracruz y Medalla al Mérito de la Universidad Veracruzana 2024.

ARTÍCULO

¿Sabes cómo preguntar a la IA? Oportunidades y desafíos éticos en la escritura académica

Jonathan Rojas Simón, Yulia Ledeneva, Verónica Neri Mendoza y René Arnulfo García-Hernández

El rol de la IA generativa en la escritura académica

En los últimos años, la Inteligencia Artificial (IA) generativa se ha vuelto una herramienta de mayor uso en el ámbito educativo. Estudiantes y profesores la utilizan para redactar resúmenes y ensayos, estructurar argumentos, formular preguntas, generar ideas y organizar contenidos. Sin embargo, su verdadero potencial no depende solo de lo que puede generar, sino en **cómo se le pregunta**. La forma en que se diseñan las consultas o *prompts* influye en la calidad, coherencia y propósito del texto producido.

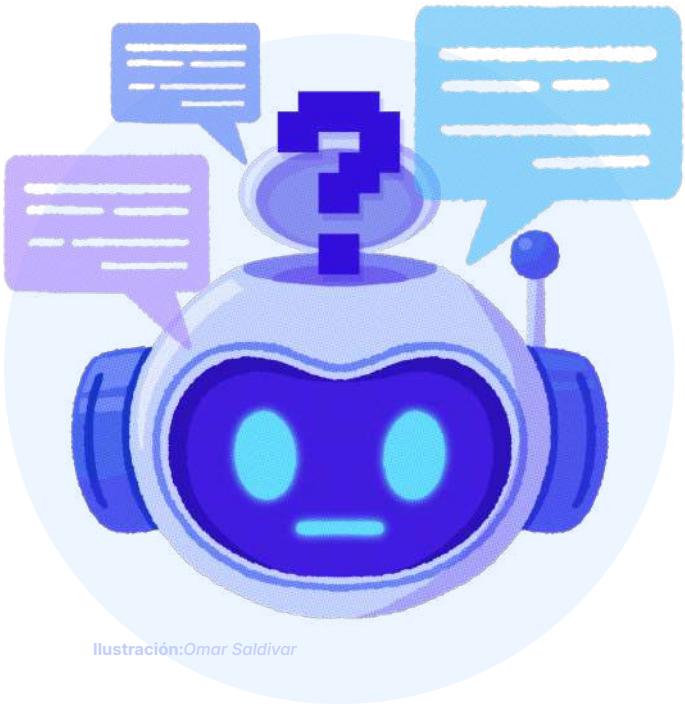


Ilustración: *Omar Saldivar*

Esta forma de interactuar con la IA no solo abre oportunidades para mejorar la escritura, organizar ideas y ampliar el acceso al conocimiento, sino que plantea desafíos éticos y académicos. Su uso también se ha asociado con la falta de originalidad, conflictos relacionados con los derechos de autor y una disminución del pensamiento crítico. Por ello, estas herramientas también son percibidas como una amenaza, ya que pueden fomentar dependencia tecnológica, superficialidad intelectual y prácticas deshonestas, generando un dilema que debe analizarse con responsabilidad y rigor científico.

Con base en lo anterior, este artículo tiene como propósito comunicar cómo la IA generativa influye en la escritura académica mediante el uso de distintos tipos de *prompts,* así como analizar sus principales ventajas y desventajas. Asimismo, invita al lector a una reflexión crítica sobre su uso en el ámbito educativo. De esta manera, se busca fomentar una comprensión más consciente, ética y fundamentada sobre los procesos de aprendizaje y generación de conocimiento.

©2026 SMIA | ISSN 2007-069

¿Qué es la IA generativa y cómo escribe resúmenes y ensayos?

Imagina que estás escribiendo un mensaje en el celular y el teclado comienza a sugerir la siguiente palabra. Ahora imagina este mismo sistema, pero mucho más avanzado, ya que es capaz de no solo escribir palabras o frases, sino párrafos enteros con sentido. De esta manera funcionan muchas herramientas de IA generativa.

La IA generativa es aquel conjunto de técnicas capaces de escribir textos, imágenes, o audios a partir de patrones aprendidos de grandes volúmenes de información [1]. En el caso del texto, estos sistemas aprenden con millones de libros, artículos, páginas web y otros materiales escritos disponibles en la Internet. Gracias a ello, pueden reconocer cómo se organiza un texto, identificar que palabras suelen estar juntas y cómo se desarrollan las ideas.

Detrás de estas herramientas se encuentran los modelos de lenguaje a gran escala (LLMs, por sus iniciales en inglés), como ChatGPT, Gemini, Claude, DeepSeek o Copilot. Estos modelos son redes neuronales avanzadas que funcionan como un "autocompletado inteligente". Reciben una instrucción del usuario y generan textos palabra por palabra, eligiendo en cada paso la opción más probable según lo que aprendieron durante su entrenamiento con millones de textos [2], [3].

Es importante señalar que la IA no entiende el contenido como lo haría una persona. Tampoco tiene conciencia ni pensamiento propio. Sin embargo, reconoce patrones de lenguaje y los utiliza para generar textos de calidad. Por lo tanto, este proceso es suficiente para producir textos que pueden parecer escritos por un humano. Por ejemplo, cuando se le pide a una IA que genere un resumen, esta realiza las siguientes tareas:

1. Identifica ideas principales del texto.
2. Reconoce conceptos clave.
3. Elimina información repetitiva o poco relevante.
4. Reorganiza el texto en una versión más breve.

Existen tres formas en que la IA generativa puede resumir textos: de manera *extractiva* (selecciona y reorganiza las oraciones importantes), *abstractiva* (genera oraciones diferentes a las del texto original) o *híbrida* (combina ambas estrategias) [4]

La IA no comprende ni piensa como una persona, pero genera textos coherentes mediante patrones de lenguaje.

En el caso de ensayos, el proceso es más complejo que escribir resúmenes. Por lo tanto, la IA debe:

1. Interpretar el/los temas solicitados.
2. Reconocer la intención del usuario (describir, argumentar, comparar etc.).
3. Organizar el texto en una estructura clara (introducción, desarrollo y conclusión).
4. Relacionar conceptos, ejemplos y definiciones.
5. Escribir el texto en un tono formal, académico, divulgativo, reflexivo, etc.

A pesar de que estas herramientas pueden generar resúmenes y ensayos de calidad, aún dependen de cómo se pide la información.

Por ejemplo, no es lo mismo escribir:

Elabora un ensayo sobre las ventajas y desventajas de la IA en la educación.

que indicar:

Redacta un ensayo académico de 800 palabras que resalte el impacto de la IA en la escritura académica, incluyendo beneficios, riesgos y proporcione puntos de vistas éticos sobre su uso.

En el segundo caso, la instrucción es más clara, específica y detallada. Esto ayuda a que la IA genere un texto más completo y afín a lo esperado. Por esta razón, la IA generativa no sustituye el trabajo intelectual del usuario. Más bien, responde al nivel de claridad, precisión y profundidad con el que se formula el *prompt*.

AÑO 18, NO. 3 | SEP-DIC| 2026 | KOMPUTER SAPIENS

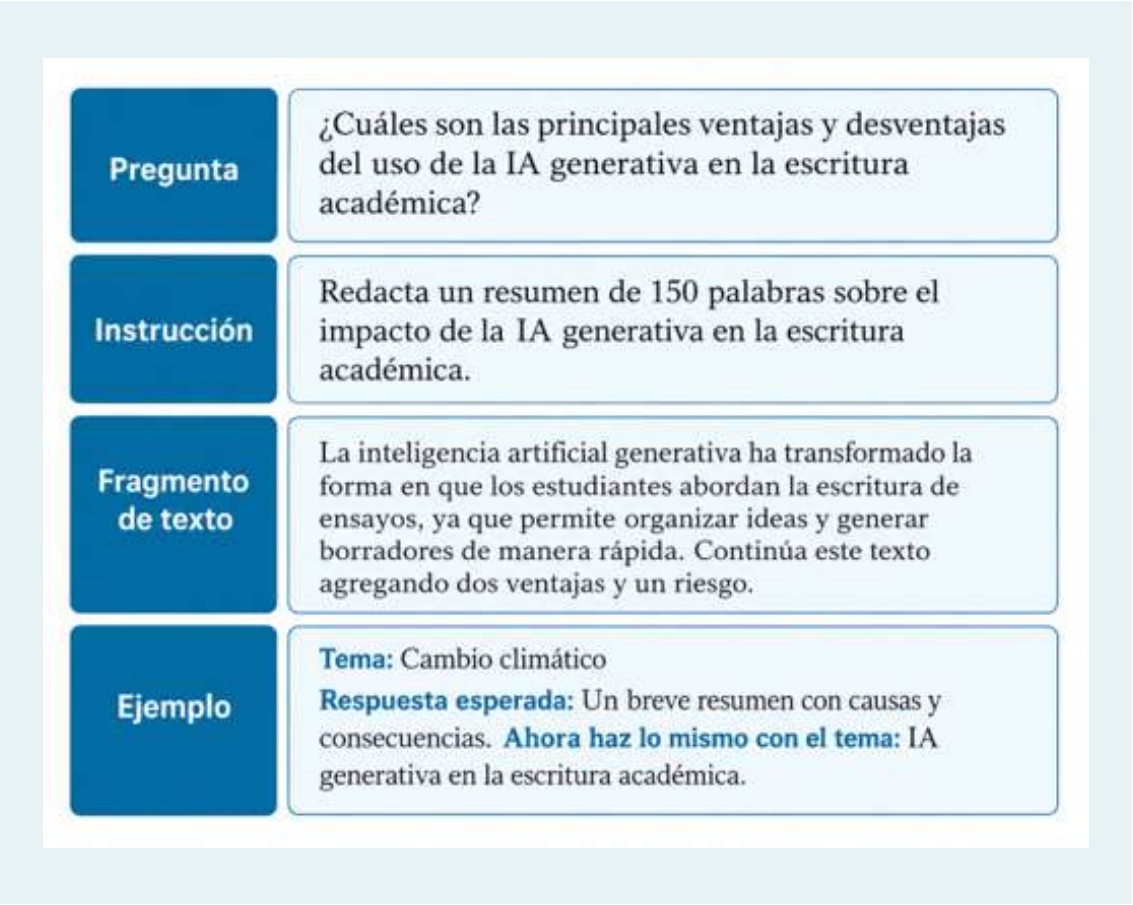


Figura 1. *Tipos de prompts.*

El rol del *prompt* en la interacción

Pedirle algo a una IA no es diferente a pedir ayuda a otra persona. La forma en hacer la pregunta puede cambiar completamente la respuesta que se recibe. No es lo mismo decir *"explícame esto"* que dar una instrucción clara con ejemplos y contexto.

Para cualquier herramienta de IA generativa, el *prompt* es el punto de partida de toda interacción. Este puede ser una pregunta, una instrucción, un fragmento de texto o un ejemplo que la IA debe seguir. Por lo tanto, cuanto más claro y específico sea, mejores serán los resultados. La Figura 1 ilustra cuatro *prompts* en un contexto académico.

Como se observa en los ejemplos anteriores, cada *prompt* cumple una función específica. El *prompt* en forma de pregunta busca obtener información directa y explorar conceptos. Por otro lado, el *prompt* en forma de instrucción solicita a la IA realizar una tarea concreta, delimitando con claridad el resultado esperado. Por su parte, el *prompt* presentado como fragmento de texto funciona como contexto inicial, para que la IA continue desarrollando la idea. Finalmente, el *prompt* basado en ejemplos ofrece un modelo de respuesta que la IA debe imitar, controlando las características del texto generado.

La interacción entre el usuario y la IA generativa varía, según la intención y el nivel de orientación proporcionado. Para comprender estas diferencias, se han identificado distintas formas de dar instrucciones a la IA, de acuerdo con la cantidad de ejemplos que recibe. Las más comunes son: *zero-shot, one-shot y few-shot.*

En investigaciones recientes [5], especialmente en el Procesamiento del Lenguaje Natural y la generación automática de resúmenes, estas formas de instruir a la IA han sido objeto de análisis. A continuación, se presenta una breve descripción de cada una.

Zero-shot: pedir sin dar ejemplos. El enfoque ***zero-shot*** ocurre cuando se le pide algo a la IA sin proporcionarle ningún ejemplo

©2026 SMIA | ISSN 2007-069

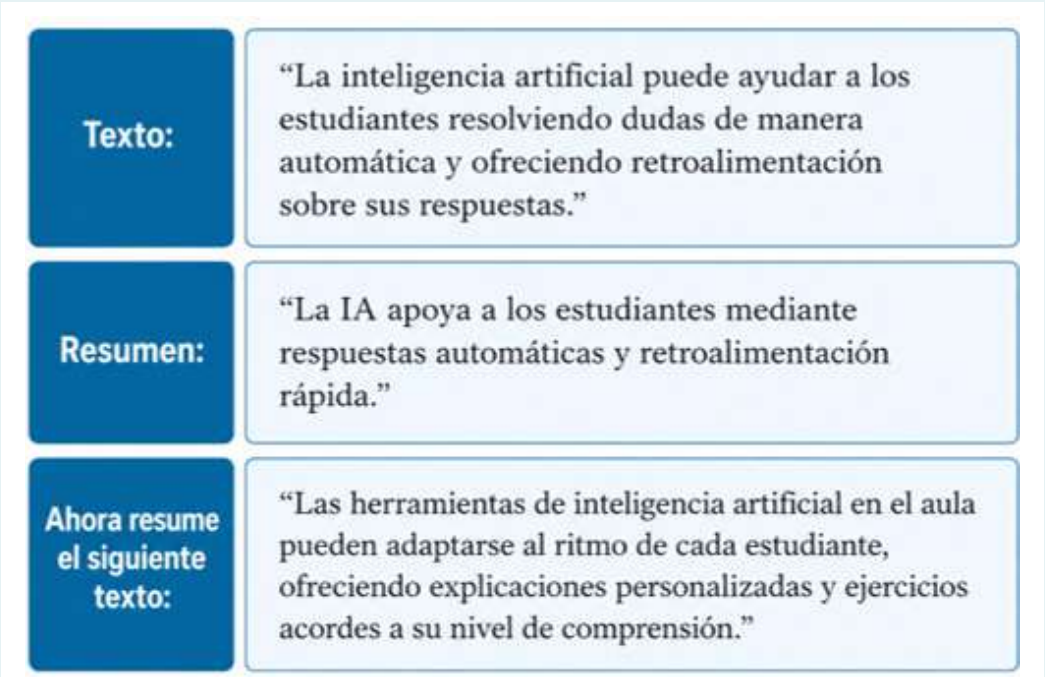


Figura 2. *Ejemplo de prompt de tipo one-shot.*

previo. Es como pedirle a alguien que haga una tarea solo con una instrucción general. Por ejemplo:

Redacta un resumen de 100 palabras sobre la IA en la educación.

En este caso, la IA responde utilizando únicamente la información que ya conoce. Este tipo de *prompt* es útil para obtener respuestas rápidas y generales. Sin embargo, al no incluir instrucciones específicas, los resultados pueden ser poco precisos o no coincidir con lo que el usuario esperaba.

One-shot: mostrar un ejemplo. A diferencia del caso anterior, este tipo de instrucción proporciona a la IA un ejemplo antes de solicitar una tarea similar. Es comparable a mostrar cómo se desea realizar una actividad antes de pedir que se repita. La Figura 2 muestra un ejemplo de cómo al *prompt* se le ha dado un resumen, para que la IA pueda construir otro con características similares.

Aquí, el ejemplo funciona como una referencia. Le indica a la IA qué tipo de respuesta se espera, cómo debe resumir y qué tan breve debe ser. Esto suele mejorar la calidad del resultado, ya que reduce la ambigüedad.

Few-shot: aprender con varios ejemplos. Este tipo de instrucción va un paso más allá del *one-shot*, ya que proporciona varios ejemplos en lugar de uno solo. Esto permite que la IA identifique patrones con mayor claridad. En la vida real es como cuando un profesor muestra varios ejercicios resueltos a sus alumnos antes de pedirles que hagan uno por su cuenta. Cuantos más ejemplos relevantes tenga la IA, más fácil "entenderá" qué se espera. La Figura 3 muestra un ejemplo de un *prompt* de tipo *few-shot*.

En la escritura académica y genérica [5], esta interacción ha demostrado mejorar la calidad de los resúmenes, ya que la IA generativa cuenta con referencias más amplias para comprender el estilo, el nivel de complejidad y la intención de la tarea. Sin embargo, también requiere mayor esfuerzo por parte del usuario, ya que implica diseñar cuidadosamente los ejemplos.

Estas formas de interactuar muestran que la IA generativa no trabaja de manera com-

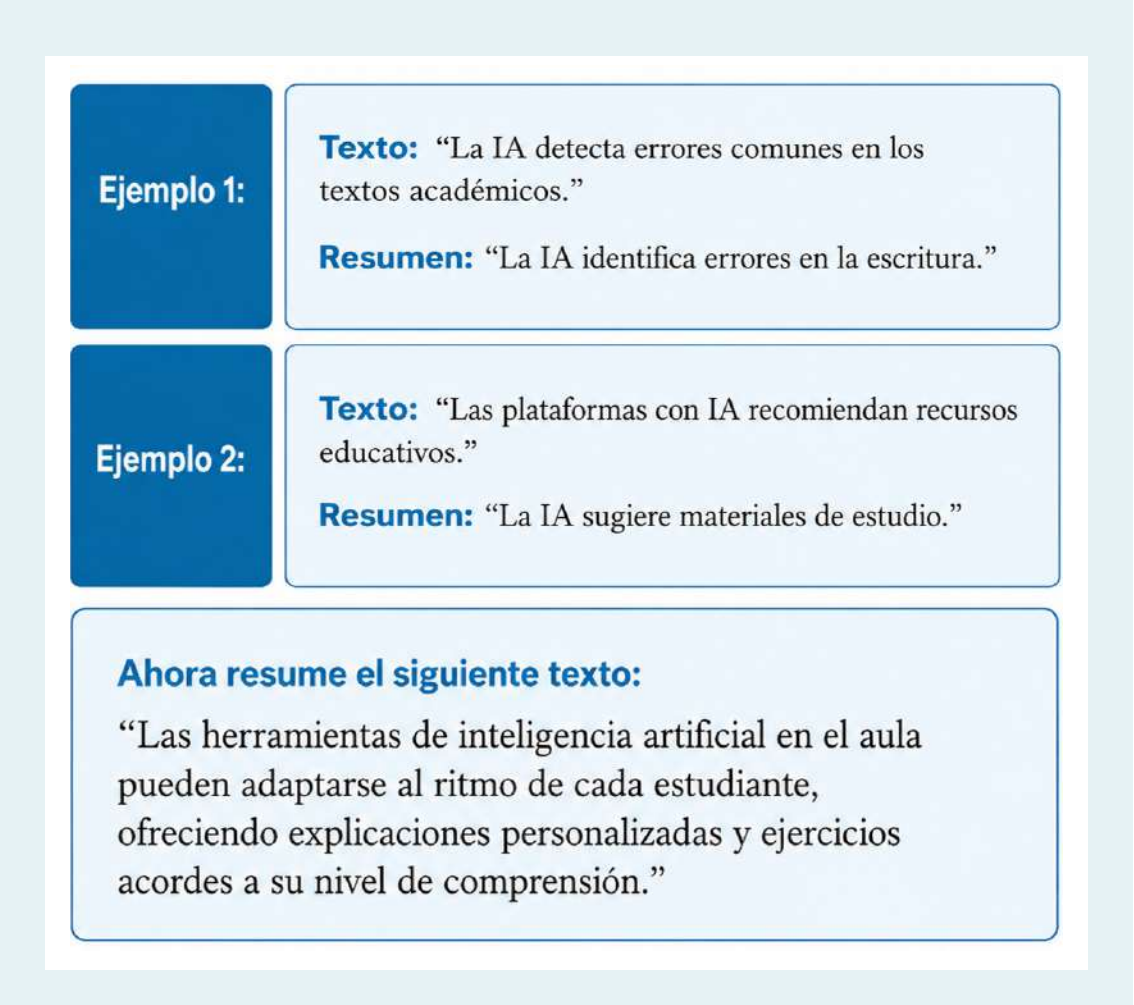


Figura 3. *Ejemplo de prompt de tipo few-shot.*

pletamente automática. Su desempeño depende de la claridad y calidad de las instrucciones que recibe. En otras palabras, usar bien la IA no consiste solo en obtener respuestas, sino en saber cómo hacer las preguntas adecuadas. Esto convierte la formulación de *prompts* en una habilidad clave dentro de la ingeniería de *prompts* [6], especialmente en contextos educativos.

El desempeño de la IA generativa depende de la claridad y calidad de las instrucciones que recibe.

Al mismo tiempo, este poder también plantea un desafío: si se usa sin cuidado, la IA puede pasar de ser una herramienta de apoyo a un sustituto del esfuerzo intelectual. Por eso, aprender a interactuar con ella de manera crítica y responsable es tan importante como conocer sus beneficios.

Ventajas del uso de la IA generativa en la escritura académica

Este tipo de tecnologías se han consolidado como una herramienta que, utilizada de manera responsable y adecuada con diferentes tipos de *prompts*, ofrecen varias oportunidades para mejorar la escritura de ensayos y fomentar el aprendizaje de los estudiantes. Una de las principales ventajas de la IA generativa es su capacidad para apoyar a la organización de ideas.

En este sentido, muchos estudiantes enfrentan dificultades para redactar un resumen o ensayo, organizar temas y subtemas, o simplemente formular una introducción. Ante ello, la IA puede servir como herramienta de apoyo al sugerir estructuras temáticas, ordenar conceptos principales y proponer formas claras de iniciar un texto [7]. De esta manera, contribuye a enfrentar al "síndrome de la hoja en blanco" [8], el cual se refiere a la dificultad para iniciar

©2026 SMIA | ISSN 2007-069

un texto cuando no se tienen ideas claras o una estructura definida.

Otra ventaja relevante es el ahorro de tiempo en tareas preliminares. Es decir, la IA puede generar borradores iniciales, resúmenes de textos largos o listas de ideas clave en cuestión de segundos [9] Esto permite que los estudiantes dediquen más tiempo al análisis crítico, revisión de la información y fortalecimiento de sus argumentos, en lugar de invertir su esfuerzo en tareas repetitivas.

Asimismo, la IA generativa puede favorecer la comprensión de temas complejos. Al solicitar explicaciones con distintos niveles de dificultad o ejemplos prácticos, los estudiantes pueden abordar un mismo contenido desde diferentes perspectivas. Esto resulta especialmente útil en la elaboración de ensayos académicos, ya que fortalece la comprensión necesaria para construir argumentos.

Riesgos y desafíos éticos de la IA en el entorno académico

La integración de IA generativa en la educación plantea dilemas éticos y desafíos que deben abordarse con responsabilidad para preservar la integridad del aprendizaje y la evaluación académica. Estos problemas están relacionados a la autenticidad, la equidad y el desarrollo de habilidades esenciales.

La dependencia tecnológica es un riesgo evidente. Si los estudiantes confían demasiado en esta herramienta, pueden presentar pérdida de habilidades cognitivas [10]. Por esta razón, la IA podría obstaculizar el pensamiento crítico, la habilidad para estructurar ideas y la capacidad de sintetizar información. Por lo tanto, esto puede transformar a la educación en un ejercicio de verificación de resultados generados por máquinas.

Por otro lado, el desafío más inmediato es la redefinición de plagio y autoría. Cuando un ensayo es generado total o parcialmente por una IA, la línea entre el apoyo legítimo y el engaño se hace cada vez más difícil de establecer. Determinar quién es el autor se vuelve complicado, socavando el principio de que el trabajo presentado debe reflejar el conocimiento y habilidades del estudiante.

Conclusiones

El uso de la IA generativa en la escritura académica ofrece beneficios, pero también plantea desafíos éticos. Uno de los principales riesgos es el plagio involuntario, ya que los textos generados pueden replicar ideas o información sin una atribución adecuada. Esto puede afectar principios esenciales de la actividad académica, como la honestidad y la originalidad.

Además, existe el riesgo de una dependencia excesiva de estas herramientas, lo que puede afectar el desarrollo de habilidades esenciales como la lectura crítica, la argumentación, la síntesis de información y la escritura autónoma. Cuando la IA sustituye el esfuerzo cognitivo del estudiante, se debilita el aprendizaje y se limita la construcción del conocimiento propio.

El uso ético de la IA generativa también depende del tipo de *prompt* utilizado. Mientras el enfoque *zero-shot,* requiere instrucciones claras y precisas por parte del usuario, los enfoques *one-shot* y *few-shot* emplean uno o varios ejemplos para orientar mejor las respuestas. Comprender estas diferencias, favorece un uso más consciente y responsable de la IA en la escritura académica. En última instancia, su valor no depende solo de la tecnología, sino de cómo las personas deciden utilizarla KS

Referencias

1. Feuerriegel S., Hartmann J., Janiesch C., and Zschech P., (2024) “Generative AI”. Bus. Inf. Syst. Eng., vol. 66, no. 1, pp. 111–126.
2. Myers D. et al. (2024) “Foundation and large language models: fundamentals, challenges, opportunities, and social impacts”. Cluster Comput., vol. 27, no. 1, pp. 1–26.

3. W. X. Zhao et al. (2025) "A Survey of Large Language Models".
4. El-Kassas W. S., Salama C. R., Rafea A. A., and Mohamed H. K. (2024) "Automatic text summarization: A comprehensive survey," Expert Syst. Appl., vol. 165, p. 113679.
5. Onan A. and Alhumyani H. (2025) "Assessing the Impact of Prompt Strategies on Text Summarization with Large Language Models," in Communications in Computer and Information Science, vol. 2242 CCIS, Springer Science and Business Media, pp. 41–55.
6. White J. et al. (2023) "A Prompt Pattern Catalog to Enhance Prompt Engineering with ChatGPT," PLoP '23 Proc. 30th Conf. Pattern Lang. Programs, pp. 1–31.
7. Montes V. M., Solórzano U. B., and Calderón C. V. (2024) "La Escritura Académica en el Hacer Docente del Siglo XXI," Rev. Digit. Escriba. Esc. Escritores., vol. 5, no. 1, pp. 28–51.
8. Ruiz M. (2024) "El Síndrome de la Hoja en Blanco: causas, efectos y estrategias para superarlo," Reflexión Académica en Diseño y Comun., vol. 58, pp. 192–195.
9. Kasneci E. et al. (2023) "ChatGPT for good? On opportunities and challenges of large language models for education," Learn. Individ. Differ., vol 103, p. 102274.
10. Kosmyna N. et al. (2025), "Your Brain on ChatGPT: Accumulation of Cognitive Debt when Using an AI Assistant for Essay Writing Task," Massachussets, USA.

Declaración del uso de la IA generativa.
Durante la preparación de este trabajo, los autores utilizaron Grammarly y ChatGPT para mejorar la redacción del documento. Después de utilizar estas herramientas, los autores revisaron y editaron el contenido según fuera necesario y asumen plena responsabilidad de lo publicado.

Sobre los autores



Jonathan Rojas-Simón es Doctor en Ciencias de la Computación por la Universidad Autónoma del Estado de México (UAEMéx). Ha sido distinguido con la Presea Ignacio Manuel Altamirano (2020 y 2023) de la UAEMéx y el premio "José Negrete Martínez" de la Sociedad Mexicana de Inteligencia Artificial por sus aportaciones en la Inteligencia Artificial. Actualmente, es profesor de licenciatura y posgrado en el Centro Universitario UAEM Tianguistenco, miembro del Sistema Nacional de Investigadores (Nivel C) e investigador en el programa Cátedras COMECyT. Es autor de varios artículos científicos en revistas de alto impacto y un libro en una editorial reconocida. Sus líneas de investigación incluyen minería de textos, procesamiento del lenguaje natural, computación evolutiva y métodos estadísticos.



Yulia Ledeneva es Doctora en Ciencias de la Computación por el Centro de la Investigación en Computación del Instituto Politécnico Nacional (CIC-IPN). En 2009, la Dra. Yulia Ledeneva recibió la presea Lázaro Cárdenas de las manos del presidente de México. Actualmente, es profesora investigadora de la UAEMex, miembro del Sistema Nacional de Investigadores (Nivel II) y autora de más de 90 publicaciones científicas en revistas de alto impacto y congresos internacionales. Sus principales temas de investigación son: lingüística computacional, procesamiento del lenguaje natural, minería de textos, métodos basados en grafos y algoritmos genéticos.



Verónica Neri Mendoza es Doctora en Ciencias de la Computación por la UAEMex. En el 2024, recibió la presea Ignacio Manuel Altamirano (otorgado por la UAEMex) por sus contribuciones en la Inteligencia Artificial. Actualmente, es investigadora posdoctorante de la SECIHTI en el Centro Universitario UAEM Tianguistenco, miembro del Sistema Nacional de Investigadores (Nivel C) y autora de artículos científicos en revistas de alto impacto y congresos nacionales e internacionales. Sus principales temas de investigación incluyen lingüística computacional, procesamiento del lenguaje natural, minería de textos y reconocimiento de patrones.



René A. García Hernández es Doctor en Ciencias de la Computación por el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE). Actualmente, es profesor investigador de la UAEMex, miembro del Sistema Nacional de Investigadores (Nivel II) y autor de más de 90 publicaciones científicas en revistas de alto impacto y congresos internacionales. Además, ha recibido primeros lugares en competencias SOCO de reutilización de código fuente. Sus principales temas de investigación son: reconocimiento de patrones, computación evolutiva, minería de textos y procesamiento del lenguaje natural.

©2026 SMIA | ISSN 2007-069

ARTÍCULO

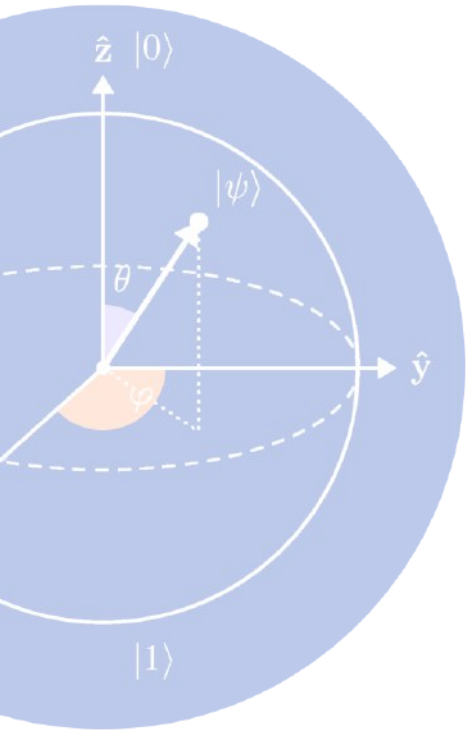
Codificación Cuántica de Imágenes: Una Nueva Frontera para la Inteligencia Artificial

Emmanuel Martínez Guerrero, Guo-Hua Sun y Shi-Hai Dong

Cuando la visión artificial se encuentra con lo cuántico

La visión computacional y el reconocimiento de patrones en imágenes constituyen pilares centrales de la inteligencia artificial moderna. Sistemas de reconocimiento facial desbloquean nuestros dispositivos, redes neuronales etiquetan automáticamente fotografías en plataformas sociales, y algoritmos de aprendizaje profundo asisten a radiólogos analizando miles de estudios médicos diariamente. Todos estos avances comparten un punto de partida común: la representación eficiente de información visual que las computadoras puedan procesar [1].

Los enfoques actuales de aprendizaje automático operan sobre computadoras clásicas, descomponiendo cada imagen en millones de píxeles individuales. Una fotografía promedio contiene 12 millones de píxeles que deben almacenarse y procesarse independientemente. Este modelo ha impulsado avances extraordinarios en las últimas décadas. Sin embargo, enfrenta limitaciones crecientes conforme la escala de datos visuales crece exponencialmente y los problemas de procesamiento se vuelven más complejos [1][2].



Aquí es donde la computación cuántica entra en escena, ofreciendo una alternativa que podría cambiar radicalmente cómo representamos y procesamos información visual [3][4]. Pero existe un desafío clave: las arquitecturas cuánticas no operan con píxeles convencionales. Hablan el lenguaje de los *qubits* y la superposición cuántica, un paradigma completamente distinto al procesamiento clásico. Conectar ambos mundos requiere métodos de *codificación cuántica de imágenes:* estrategias para traducir representaciones visuales clásicas al espacio cuántico preservando información para su procesamiento cuántico o clásico-cuántico [5]. Estas estrategias han sido investigadas durante las últimas dos décadas, y determinan si podremos aprovechar ventajas cuánticas en aplicaciones reales de visión artificial [4][5].

En este artículo exploraremos las principales estrategias para codificar imágenes en sistemas cuánticos. Comenzaremos entendiendo cómo funcionan los qubits, luego revisaremos distintos enfoques de codificación y las limitaciones que impone el hardware actual. Finalmente, examinaremos aplicaciones emergentes de estas representaciones en inteligencia artificial.

©2026 SMIA | ISSN 2007-069

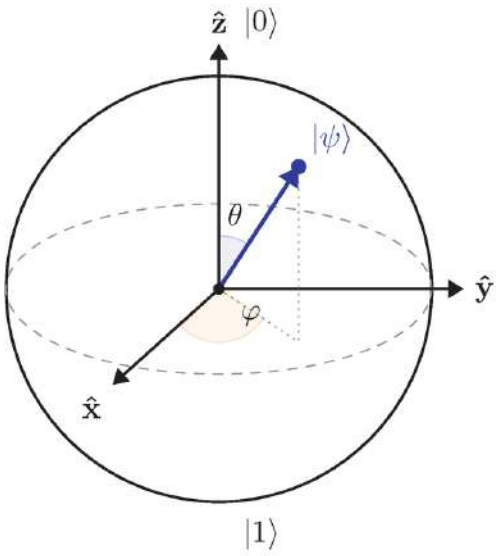


Figura 1.
Esfera de Bloch mostrando la representación geométrica de un qubit.

El procesamiento cuántico de imágenes no es solo una curiosidad teórica: representa una posible revolución en cómo las máquinas aprenden a ver y comprender el mundo visual.

El lenguaje de los qubits

Para entender cómo representar imágenes en computadoras cuánticas, necesitamos conocer a sus protagonistas: los qubits. En las computadoras tradicionales, la unidad más pequeña de información es el bit, que funciona como un interruptor de luz: está encendido (1) o apagado (0), sin punto intermedio. Todo lo que vemos en pantalla (cada píxel, cada color) se reduce finalmente a millones de estos unos y ceros.

Un qubit es el equivalente cuántico, pero con una diferencia decisiva: no tiene que ser definitivamente 0 o 1. Puede existir en ambos estados simultáneamente, fenómeno que los físicos llaman *superposición* [3]. Podemos imaginar una moneda girando. Mientras no la observamos, no sabemos el resultado, pero el qubit va más allá de esta simple incertidumbre. De acuerdo a la mecánica cuántica, realmente existe en ambos estados hasta que lo medimos, cuando resulta en 0 o 1.

Una forma compacta de escribir esta idea es la siguiente [3][4]:

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (1)$$

En esta notación, $|\psi\rangle$ representa al qubit y $|0\rangle$, $|1\rangle$ son los resultados posibles al medirlo. Los números α y β indican el peso de cada resultado; $\alpha|^2$ y $\beta|^2$ son probabilidades que suman 1.

La *esfera de Bloch* (Figura 1) ofrece una ayuda visual para esta idea [3]: cada punto de su superficie representa una combinación posible de $|0\rangle$ y $|1\rangle$. Los polos son estados definidos y los puntos intermedios, superposiciones; manipular un qubit puede imaginarse como rotarlo sobre la esfera.

Cuando un sistema tiene varios qubits, las posibilidades de representar información crecen exponencialmente. Dos qubits pueden estar en superposición de cuatro estados diferentes ($|00\rangle$, $|01\rangle$, $|10\rangle$, $|11\rangle$) simultáneamente. Tres qubits alcanzan ocho posibles estados. Cada qubit añadido duplica las posibilidades. Por ejemplo, con tan solo 10 qubits se alcanzan 1,024 estados en superposición, suficiente para las posiciones de una imagen de 32 × 32 píxeles en codificación tipo amplitud. Con 20 qubits, se supera el millón de estados. Esto no significa que 10 qubits almacenen 1,024 valores como memoria clásica; el procesador opera sobre la superposición antes de medirla, es decir, mediante paralelismo cuántico. Esta explosión exponencial representa tanto la promesa como el desafío de la computación cuántica [3]. Si bien permite representar cantidades enormes de información de manera compacta, preparar y mantener estable el estado correcto es extraordinariamente difícil [6].

Para manipular qubits y crear los estados necesarios para codificar imágenes, se utilizan *circuitos cuánticos:* diagramas donde cada línea horizontal representa un qubit individual y las cajas simbolizan operaciones (compuertas) aplicadas sobre ellos. Se

©2026 SMIA | ISSN 2007-069

leen de izquierda a derecha. La profundidad de un circuito es el número de capas de operaciones ejecutadas sucesivamente. Las operaciones pueden ser rotaciones, mediciones, o interacciones entre qubits [3]. En las figuras siguientes veremos varios ejemplos de estos circuitos, cada uno implementando una estrategia diferente para codificar imágenes.

Ahora que comprendemos cómo funcionan los qubits, surge una pregunta central: ¿cómo usamos estos qubits para representar nuestras imágenes? Las respuestas a esta pregunta son tan diversas como creativas.

Del píxel al qubit: estrategias de codificación

La representación elegida influye en la precisión y eficiencia de las redes neuronales cuánticas y de los sistemas de reconocimiento de patrones.

Suponga que se desea codificar una imagen pequeña de 2 × 2 píxeles (4 píxeles en total). Para mantener las cosas simples, trabajaremos con escala de grises, donde cada píxel toma valores desde negro completo (0) hasta blanco puro (255). Se tienen 4 números que se necesitan traducir al lenguaje cuántico. ¿Cómo se hace? Resulta que hay varias estrategias completamente diferentes para abordar este problema, cada una con sus propias ventajas y complicaciones [5][7].

Codificación directa: bit a qubit. El enfoque más directo, conocido como *codificación en base computacional* (del inglés *Basis encoding*) [5], hace exactamente lo que haría una computadora normal: tomar cada número y representarlo en binario. El número 173, por ejemplo, se escribe como 10101101 en binario. Necesitamos 8 bits (o en este caso, 8 qubits) para representar cada píxel. Para nuestra imagen de 4 píxeles, esto suma 32 qubits. Es transparente y recuperar la información original es sencillo. Sin embargo, esta estrategia no aprovecha la superposición cuántica, la propiedad que distingue a estos sistemas. La Figura 2 ilustra la estructura de este circuito, donde las compuertas X (NOT) codifican valores binarios específicos.

Compresión cuántica: codificación en amplitud. El otro extremo se llama ***codificación en amplitud*** (del inglés *Amplitude encoding)* [7]. Aquí viene la ventaja cuántica: recordemos que n qubits pueden representar 2^n estados diferentes simultáneamente. Para nuestra imagen de 4 píxeles, bastarían apenas 2 qubits para las posiciones ($2^2 = 4$). ¿Y dónde guardamos las intensidades? En las *amplitudes de probabilidad:* números que describen qué tan probable es encontrar el sistema en cada configuración. Cada posición de la imagen tiene asignada una amplitud que codifica cuán brillante u oscuro es ese píxel. Pasamos de necesitar 32 qubits a solo 2, una compresión sustancial.

El problema es que crear ese estado cuántico tan específico requiere muchas operaciones en secuencia, y cada operación tiene una probabilidad pequeña pero real de introducir errores. Además, esas amplitudes de probabilidad no podemos leerlas directamente. Debemos medir el sistema cientos o miles de veces y reconstruir las intensidades originales a partir de estadísticas. La Figura 3 muestra este circuito, donde los ángulos de rotación dependen de las intensidades de cada píxel.

Estrategias intermedias: FRQI y NEQR. Viendo las desventajas de ambos extremos, investigadores han propuesto estrategias intermedias que buscan lo mejor de cada enfoque. Un ejemplo popular es *FRQI (Flexible Representation of Quantum Images)* [8], que aprovecha la superposición cuántica para las posiciones (ahorrando qubits), pero guarda las intensidades usando ángulos de rotación. Para nuestra imagen de 4 píxeles, FRQI necesita solo 3 qubits en total: 2 para las posiciones y 1 para las intensidades. Un balance práctico entre eficiencia y factibilidad. La Figura 4 muestra la estructura del circuito FRQI, donde los ángulos de rotación codifican las intensidades en cada posición.

Otra propuesta es *NEQR (Novel Enhanced Quantum Representation*) [9], que también combina ambos mundos de forma distin-

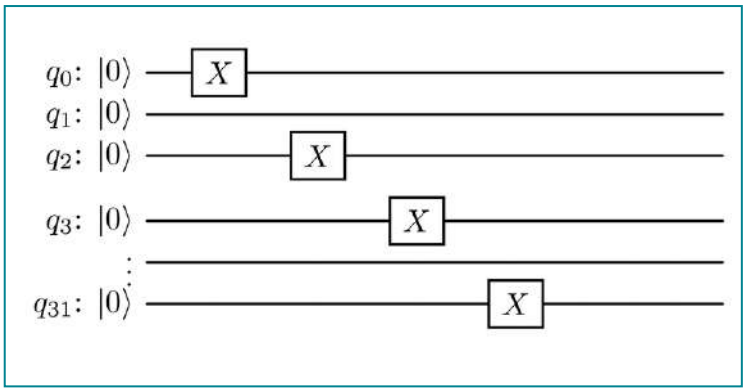


Figura 2. *Circuito cuántico para codificación en base computacional. Cada píxel requiere 8 qubits; las compuertas X (NOT) invierten qubits de $|0\rangle$ a $|1\rangle$ para codificar los valores binarios.*

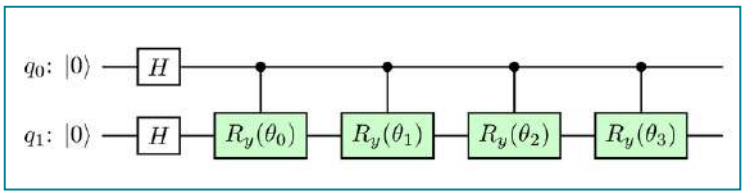


Figura 3. *Circuito cuántico para codificación en amplitud. Este método utiliza solo 2 qubits. Las compuertas Hadamard (H) crean superposición uniforme de estados, y las rotaciones controladas $R_y(\theta_i)$ codifican las intensidades de cada píxel.*

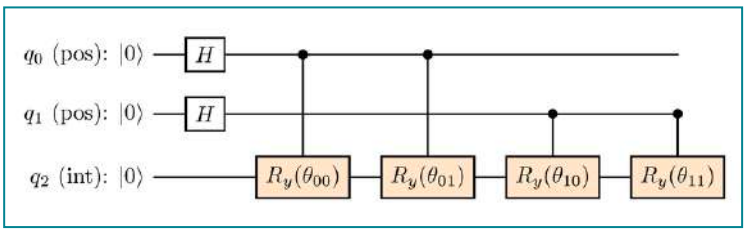


Figura 4. *Circuito cuántico para codificación FRQI. Las compuertas Hadamard (H) en qubits de posición crean superposición uniforme de estados, y las rotaciones $R_y(\theta_{ij})$ codifican la intensidad en cada posición.*

ta. Sigue usando superposición para las posiciones (2 qubits), pero dedica 8 qubits completos para codificar las intensidades en binario directo, permitiendo representar las 256 tonalidades posibles sin perder precisión. En la práctica, la clasificación puede aprovechar representaciones comprimidas, mientras que el procesamiento píxel a píxel favorece métodos como NEQR.

Cada método implica balances distintos: cuántos qubits se requieren, cuál es la profundidad del circuito, qué tan compleja es la extracción de información. La elección óptima depende del hardware disponible y de la aplicación. Sin embargo, todos estos enfoques comparten una suposición problemática: asumen qubits perfectos [5]. La realidad del hardware actual es mucho más complicada.

Hardware cuántico: la era NISQ

Las computadoras cuánticas que podrían ejecutar estos métodos de codificación existen hoy, pero enfrentan desafíos significativos antes de alcanzar aplicaciones prácticas a gran escala. Los procesadores cuánticos actuales pertenecen a la era NISQ (*Noisy Intermediate-Scale Quantum*, por sus siglas en inglés) [3][4][6], caracterizada por tres limitaciones principales que afectan cualquier aplicación práctica, incluyendo el procesamiento de imágenes para inteligencia artificial.

La primera limitación es la disponibilidad de qubits. Los dispositivos más avanzados disponibles a través de servicios en la nube de IBM, Google y otros tienen entre 50 y 150 qubits. Para problemas de visión computacional a escala real eventualmente necesitaremos miles o millones de qubits. La segunda son las tasas de error en operaciones. Cada vez que ejecutamos una operación, como rotar un qubit o crear interacciones entre qubits, existe una tasa de error del orden de 0.1% para operaciones básicas y 1% para operaciones complejas [6]. Un circuito típico para codificar una imagen podría necesitar miles de estas operaciones, por lo que los errores se acumulan. La tercera limitación son los tiempos de coherencia. Los qubits mantienen su información cuántica durante tiempos breves, típicamente microsegundos o, en sistemas avanzados, milisegundos. Pasado ese tiempo, las interacciones con el ambiente degradan la superposición cuántica [4][6].

Estas limitaciones redefinen las prioridades de diseño. Un esquema de codificación que en teoría usa pocos qubits pero requiere secuencias largas de operaciones probablemente acumulará demasiados errores. Por el contrario, un método que usa más qubits pero necesita circuitos cortos (pocas capas de operaciones) podría funcionar mejor en la práctica. Esto desafía la intuición de que siempre debemos minimizar qubits a toda costa.

©2026 SMIA | ISSN 2007-069

¿Por qué ocurre esto? Tiene que ver con cómo los circuitos teóricos ideales se traducen a operaciones en máquinas reales. Los procesadores cuánticos tienen arquitecturas específicas donde no todos los qubits pueden interactuar directamente [6]. Cuando un circuito necesita que dos qubits no conectados interactúen, el sistema debe insertar operaciones extra para mover la información, aumentando la profundidad del circuito y la exposición al ruido. La Figura 5 ilustra este problema. Arriba vemos un circuito teórico ideal que asume que cualquier par de qubits puede interactuar directamente, mientras que abajo se muestra el mismo circuito después de ser compilado para hardware real con conectividad limitada. Las operaciones SWAP adicionales son necesarias para enrutar la información entre qubits que no están físicamente conectados, aumentando la profundidad del circuito.

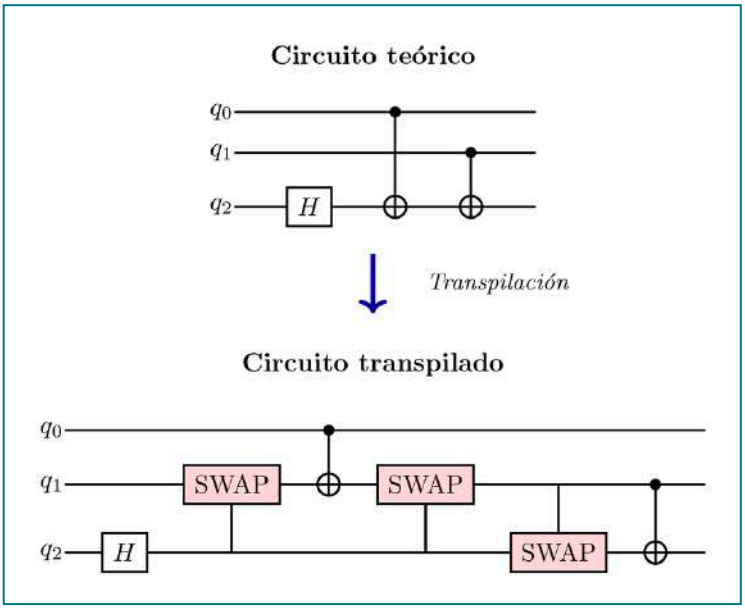


Figura 5. *Transformación de un circuito teórico ideal a uno adaptado para hardware real. Las operaciones SWAP adicionales son necesarias debido a la conectividad limitada entre qubits físicos, aumentando significativamente la profundidad del circuito.*

A pesar de estas limitaciones, ciertos dominios de inteligencia artificial podrían aprovechar los procesadores NISQ actuales.

Aplicaciones emergentes en inteligencia artificial

Hay aplicaciones prometedoras donde la codificación cuántica de imágenes podría ofrecer ventajas significativas para sistemas de inteligencia artificial.

En visión médica asistida por computadora, algoritmos de aprendizaje profundo procesan grandes volúmenes de imágenes diagnósticas (radiografías, tomografías, resonancias magnéticas) buscando patrones indicativos de enfermedades. Los modelos de IA deben examinar extensas bases de datos de imágenes para entrenarse adecuadamente, y cada imagen contiene información visual compleja. Los métodos cuánticos de codificación podrían reducir el costo computacional de preprocesamiento y extracción de características, especialmente para tareas donde representaciones comprimidas preservan la información diagnóstica relevante. Los experimentos iniciales en hardware NISQ, aunque limitados a imágenes de tamaño reducido, han demostrado que es posible implementar estos métodos manteniendo fidelidad suficiente para clasificación básica [10].

Las operaciones de preprocesamiento de imágenes representan otro dominio de interés. Tareas básicas como detección de bordes, filtrado de ruido y extracción de características son componentes esenciales en sistemas de visión artificial. Implementaciones cuánticas de estos algoritmos han sido propuestas y analizadas, mostrando ventajas teóricas en complejidad computacional [5]. La detección de bordes cuántica, por ejemplo, aprovecha operaciones de superposición para procesar múltiples configuraciones de filtros simultáneamente. Aunque estas operaciones aún requieren validación experimental exhaustiva en hardware real, representan casos de uso donde la estructura del problema se alinea naturalmente con capacidades cuánticas.

La búsqueda y recuperación de imágenes por similitud constituye una tercera aplicación relevante. Sistemas de clasificación y reconocimiento de patrones frecuentemente necesitan comparar una imagen de consulta contra bases de datos extensas [4][5]. Algoritmos cuánticos pueden calcular medidas de similitud entre estados

cuánticos que codifican imágenes, potencialmente reduciendo el tiempo de búsqueda. Esta aplicación es particularmente atractiva porque no requiere reconstruir completamente las imágenes originales, solo comparar sus representaciones codificadas, lo cual es más tolerante al ruido del hardware actual.

Para México, estas tecnologías abren oportunidades en sectores estratégicos: análisis de imágenes satelitales para monitoreo agrícola y detección de deforestación mediante procesamiento de datos geoespaciales, e inspección visual automatizada en manufactura. El acceso a procesadores cuánticos a través de plataformas en la nube (IBM Quantum, Amazon Braket, Google Quantum AI) democratiza la experimentación, eliminando la necesidad de infraestructura local costosa. Instituciones mexicanas pueden contribuir desarrollando aplicaciones para contextos regionales, validando métodos con datos locales.

Conclusiones

La investigación en codificación cuántica de imágenes se encuentra en fase de consolidación. Se han propuesto múltiples métodos para representar información visual en qubits. Sin embargo, estamos ante una transición importante que consiste en pasar de modelos teóricos a implementaciones en hardware real. Ya no es suficiente con diseñar un método que, en papel, use menos qubits. Ahora debemos verificar si funciona cuando lo ejecutamos en un procesador IBM o Google con todas sus imperfecciones como ruido en las operaciones, pérdida de coherencia y conectividad limitada. Para aplicaciones de inteligencia artificial, cada tarea de procesamiento visual tolera distintos niveles de imperfección. Si un algoritmo busca imágenes similares para sistemas de recomendación, quizás no importa tanto perder algunos detalles. Pero en diagnóstico médico, cada píxel puede ser determinante. Los métodos de codificación deben adaptarse según las tolerancias específicas de cada aplicación de visión computacional.

Hemos visto que existen estrategias claramente distintas para traducir imágenes al lenguaje cuántico. La codificación directa es transparente pero desaprovecha las propiedades cuánticas. La codificación en amplitud logra compresión impresionante usando superposición, pero requiere circuitos profundos y procesos de medición más complejos. Las estrategias intermedias como FRQI y NEQR buscan balances prácticos. En un mundo ideal con qubits perfectos, los métodos que logran mayor compresión tendrían ventajas evidentes. Pero el mundo real es distinto. Surge algo contraintuitivo: qué tan profundo es el circuito importa tanto o más que cuántos qubits usa, pues más capas significan más oportunidades para que el ruido arruine el resultado. Esta observación modifica las prioridades de diseño y refuerza la necesidad de probar las ideas en hardware real, no solo en simulaciones.

Traducir imágenes al lenguaje de los qubits representa un paso necesario para conectar la visión artificial con la computación cuántica. Las aplicaciones prácticas están en etapas iniciales. El avance será gradual y requerirá colaboración interdisciplinaria. Las ventajas potenciales incluyen nuevas capacidades de procesamiento visual y mejoras de eficiencia que podrían superar a los sistemas clásicos en problemas específicos donde la estructura cuántica se alinea naturalmente con la tarea. Estos métodos constituyen un área de investigación activa donde los desarrollos teóricos deben acompañarse de validación experimental. Cada experimento nos acerca a iden-

©2026 SMIA | ISSN 2007-069

tificar qué estrategias funcionan bajo las limitaciones actuales, preparando el terreno para futuras generaciones de sistemas cuánticos que transformarán el procesamiento de información visual. KS

REFERENCIAS

1. Noor, M. H. M. e Ige, A. O. (2025). A survey on state-of-the-art deep learning applications and challenges. *Engineering Applications of Artificial Intelligence*, 159(B), 111225.
2. Baltrušaitis, T., Ahuja, C. y Morency, L.-P. (2019). Multimodal machine learning: A survey and taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(2), 423–443.
3. Nielsen, M. A. y Chuang, I. L. (2010). *Quantum Computation and Quantum Information*. Cambridge University Press.
4. Biamonte, J., Wittek, P., Pancotti, N. et al. (2017). Quantum machine learning. *Nature*, 549, 195–202.
5. Cai, Y., Lu, X., y Jiang, N. (2018). A survey on quantum image processing. *Chinese Journal of Electronics*, 27(4), 718–727.
6. Preskill, J. (2018). Quantum Computing in the NISQ era and beyond. *Quantum*, 2, 79.
7. Yan, F., Iliyasu, A. M. y Venegas-Andraca, S. E. (2016). A survey of quantum image representations. *Quantum Information Processing*, 15, 1–35.
8. Le, P. Q., Dong, F. y Hirota, K. (2011). A flexible representation of quantum images for polynomial preparation, image compression, and processing operations. *Quantum Information Processing*, 10, 63–84.
9. Zhang, Y., Lu, K., Gao, Y. y Wang, M. (2013). NEQR: A novel enhanced quantum representation of digital images. *Quantum Information Processing*, 12, 2833–2860.
10. Yan, F., Huang, H., Pedrycz, W. et al. (2024). Review of medical image processing using quantum-enabled algorithms. *Artificial Intelligence Review*, 57, 300.

Sobre los autores



Emmanuel Martínez Guerrero es estudiante de doctorado en el Centro de Investigación en Computación del Instituto Politécnico Nacional, donde forma parte del Laboratorio de Ciencias de la Información Cuántica. Obtuvo el grado de licenciatura en Física en la Universidad Autónoma del Estado de Hidalgo y la maestría en Computación y Electrónica. Su investigación se centra en el desarrollo de algoritmos de aprendizaje automático cuántico, explorando la intersección entre física y computación con especial enfoque en aplicaciones de inteligencia artificial generativa.



Guo-Hua Sun es investigadora en el Centro de Investigación en Computación del Instituto Politécnico Nacional, donde dirige el Laboratorio de Ciencias de la Información Cuántica. Obtuvo su licenciatura en Matemáticas en la Universidad de Dalian, China, maestría en Ciencias de la Computación por la UNAM, y doctorado del IPN. Sus líneas de investigación incluyen computación cuántica, información cuántica y matemáticas aplicadas. Es miembro del Sistema Nacional de Investigadores Nivel III, evaluadora de proyectos CONACYT, y forma parte de consejos editoriales de revistas científicas.



Shi-Hai Dong es investigador en el Centro de Investigación en Computación del Instituto Politécnico Nacional. Obtuvo su doctorado en el Institute of High Energy Physics de la Academia China de Ciencias. Ha sido profesor visitante en la Universidad de Oxford, Universidad de Kansas, UNAM y Louisiana State University. Sus líneas de investigación incluyen física teórica, mecánica cuántica y ciencias de la información cuántica. Es miembro del Sistema Nacional de Investigadores Nivel III, miembro de la Academia Mexicana de Ciencias, y forma parte de consejos editoriales de revistas científicas internacionales.

ARTÍCULO

Leer el Frijol sin Dañarlo: una Misión para la Inteligencia Artificial

José Luis Morales Reyes, Elia Nora Aquino Bolaños, Héctor Gabriel Acosta Mesa y Jimena Esther Alba Jiménez

La inteligencia artificial: El nuevo "visor" para nuestros alimentos



¿Imagina la posibilidad de conocer los beneficios de un alimento solo con mirarlo? Puede sonar a ciencia ficción, pero hoy es real gracias a la inteligencia artificial (IA). Y lo más sorprendente es que esta tecnología no solo se aplica a robots o autos autónomos, sino también a algo tan cotidiano como un plato de frijoles.

La inteligencia artificial funciona, en cierto sentido, como un intérprete del mundo. Donde nosotros vemos colores, formas o texturas, una computadora ve números y patrones. Y cuando aprende a relacionarlos correctamente, puede descubrir información que, a simple vista, pasa desapercibida.

El frijol (*Phaseolus Vulgaris* L.) es un ejemplo perfecto de ésto. No solo es un alimento básico en México, sino también parte de nuestra historia. Junto con el maíz y la calabaza, forma parte de la base de la alimentación mesoamericana desde hace miles de años. Es como un legado vivo que permanece en nuestras cocinas [1].

Pero hay algo aún más interesante: México es el lugar donde el frijol se originó y se domesticó. Esto ha dado lugar a una enorme variedad de formas, tamaños y colores. Si los colocáramos todos juntos, sería como ver una paleta de colores naturales: frijoles negros, pintos, bayos, amarillos, e incluso algunos con tonos rojos, morados o azul intenso (ver la Figura 1).

Esta diversidad no es casualidad. Es el resultado del trabajo de generaciones de agricultores que han seleccionado y conservado semillas adaptadas a distintos entornos. Cada tipo de frijol es como una pequeña "historia genética", adaptada a su clima, su suelo y su uso. Ahora bien, más allá de su sabor y su valor cultural, el frijol también resulta interesante por lo que ocurre a nivel microscópico.

Más que comida: Los "escudos invisibles"

Normalmente vemos al frijol como una fuente de energía (carbohidratos) y construcción (proteínas), pero hay algo más: su valor funcional. Un alimento funcional es como una comida que, además de quitarte el hambre, te da "super protección" o escudos extras para tu salud (Figura 2).

En los frijoles de colores oscuros, estos escudos se llaman antocianinas. Piensa en ellas como la "pintura de guerra" de la semilla. Para la planta, son un mecanismo de defensa, pero cuando las comemos, se convierten en antioxidantes.

¿Qué hacen los antioxidantes? En nuestro cuerpo existen unos villanos llamados radicales libres; imagínate pequeñas pelotas de

©2026 SMIA | ISSN 2007-069

demolición que golpean nuestras células y las hacen envejecer o enfermar. Las antocianinas son los "guardaespaldas" que atrapan esas pelotas antes de que causen daño.

La ciencia ha descubierto que estas antocianinas ayudan en misiones muy importantes:

- Misión "anticáncer": Ayuda a detener el crecimiento de células que quieren portarse mal y formar tumores [2].
- Misión "azúcar bajo control": Ayudan al cuerpo a manejar mejor el azúcar en la sangre, previniendo la diabetes [3].
- Misión "corazón fuerte": Mantienen las "tuberías" (vasos sanguíneos) elásticas y limpias de grasa, para que la sangre fluya sin problemas [4].
- Misión "riñones limpios": Evitan que se formen "piedritas" molestas en los riñones [5].

¿Por qué necesitamos que la IA se una a la misión?

Nuestros ojos son como una ventana pequeña por la que miramos el mundo; vemos lo más importante, pero nos perdemos los detalles diminutos. La IA, en cambio, funciona como una súper lupa digital. Mientras nosotros vemos un frijol simplemente "negro", la IA puede ver matices y "luces" invisibles para el humano. Es la diferencia entre ver un bosque a lo lejos y tener un dron que puede ver cada forma de una hoja.



Figura 1. *Ejemplo de semillas de frijol.*

Imagínate que estos compuestos beneficiosos son como mensajes cifrados ocultos en miles de tipos de frijol. Un científico humano, por más inteligente que sea, tardaría años en descifrar solo unos cuantos, porque el cuerpo humano y las plantas son como rompecabezas de billones de piezas.

Aquí es donde entra en juego la IA, actuando como nuestra unidad central de descifrado; un sistema capaz de analizar miles de datos al mismo tiempo para encontrar conexiones que nosotros no vemos a simple vista (Figura 3). Necesitamos que se una a esta exploración porque:

- La IA como una detective ultrarrápida: Puede predecir qué frijoles tienen más "escudos" analizando solo su apariencia externa, ahorrándonos décadas de trabajo en el laboratorio.

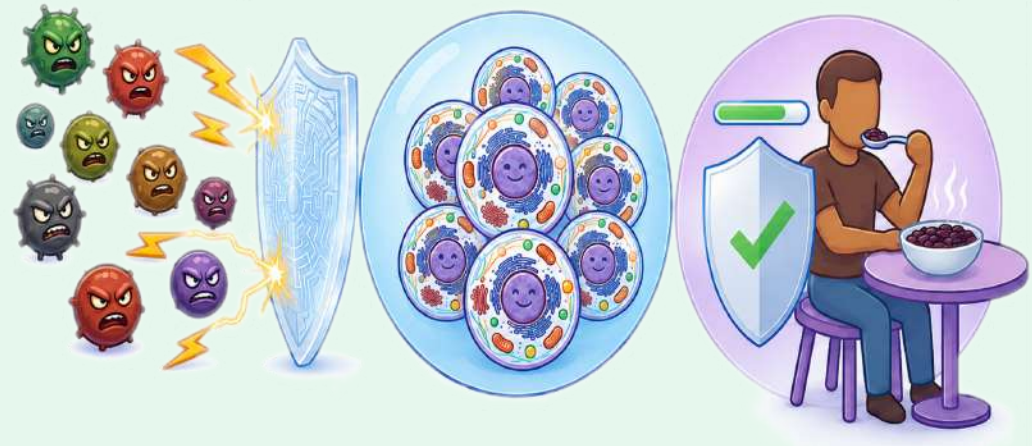


Figura 2. *El frijol es un alimento que, aparte de nutrir, protege nuestra salud.*

- Encuentra tesoros ocultos: La IA puede descubrir nuevas combinaciones de compuestos que podrían ser la clave para crear medicinas naturales más potentes.
- Protege el futuro: Al seleccionar rápidamente las semillas que debemos plantar más para que toda la población esté mejor protegida contra las enfermedades.

La regla es sencilla: entre más colorida y oscura sea la cáscara, ¡más escudos protectores suele tener! Pero aquí hay un truco: a veces dos frijoles se ven igual de negros por fuera, pero por dentro uno tiene muchos más escudos que otro. Solo una inteligencia con "supervisión", como la IA, puede ayudarnos a resolver este misterio.

El desafío del laboratorio: cuando conocer implica destruir

Hasta ahora sabemos que el color del frijol encierra información valiosa. Pero entonces surge una pregunta importante: ¿cómo se mide hoy en día esa información con precisión? La respuesta proviene del laboratorio y, para resolver el misterio, los científicos utilizan métodos químicos muy precisos para medir estos compuestos. Sin embargo, el proceso tiene un inconveniente crucial: para resolver el misterio, hay que destruir la evidencia (Figura 4).

El frijol es un alimento con beneficios a la salud

El frijol se muele, se procesa y se somete a distintos análisis, por lo que al final del proceso, la muestra desaparece por completo [6]. Ya no puede sembrarse, conservarse ni analizarse de nuevo. Es como si, para saber qué hay dentro de una caja, tuviéramos que romperla. Y una vez rota, ya no hay vuelta atrás.

Además de ser destructivo, este proceso requiere equipo especializado, reactivos costosos y personal capacitado. También es lento: analizar una sola muestra puede tomar horas. Ahora imaginemos hacer esto con cientos de variedades de frijol: el proceso se vuelve poco práctico. Esto plantea un dilema, ¿cómo estudiar algo sin perderlo en el proceso?

En el caso del frijol, este problema resulta especialmente relevante. Muchas de las variedades nativas son valiosas no solo por sus propiedades nutricionales, sino también por su importancia cultural y genética. Destruirlas para analizarlas implica, en cierto sentido, perder parte de ese patrimonio. Así que la pregunta sigue abierta: ¿podemos investigar sin destruir? ¿Existe alguna manera de encontrar una solución que no requiera romper la caja, sino aprender a leer lo que se ve desde fuera?

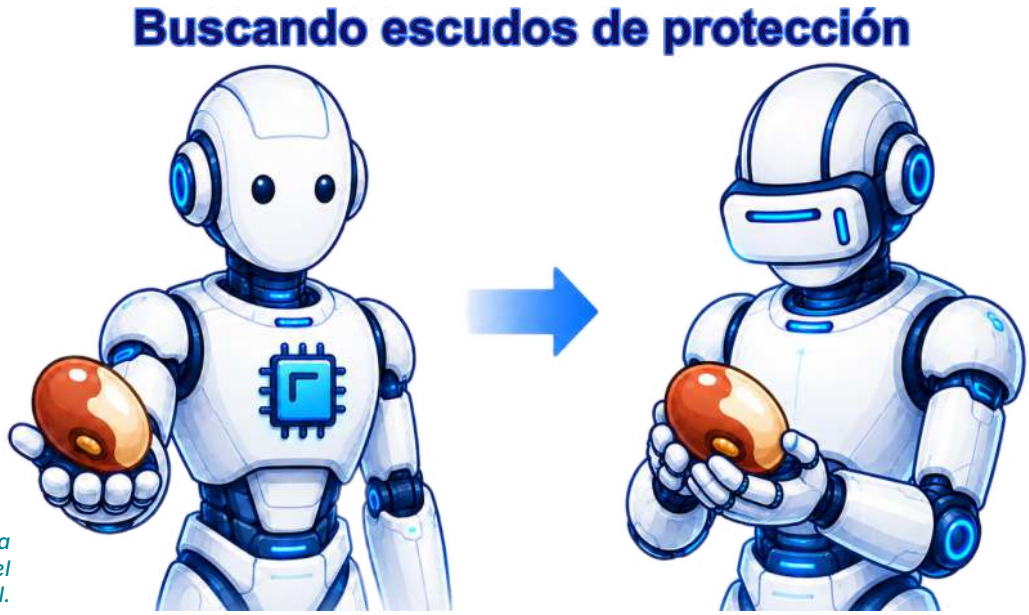


Figura 3. *La Inteligencia Artificial asistiendo en el análisis del frijol.*

©2026 SMIA | ISSN 2007-069

El nuevo detective artificial

Para resolver este misterio sin romper el frijol, imagina un "cerebro digital" que estamos entrenando para que se convierta en un experto en frijoles y mida su potencial de protección. ¿Cómo funciona? Piensa en un grupo de detectives que trabaja en equipo (Figura 5).

Cada detective (o neurona) se encarga de una tarea muy pequeña: uno mira qué tan brillante es la cáscara, otro analiza el tono exacto del color, y otro busca patrones en la textura. Estos detectives están organizados en grupos (capas).

La información pasa de una capa a otra, como si los detectives se pasaran notas por debajo de la mesa hasta llegar al "Jefe de Investigación", quien finalmente dice: "Estos frijoles tienen 85 unidades de escudos protectores".

Lo increíble es que, al principio, este cerebro digital no sabe nada. Pero al mostrarle cientos de fotos de frijoles de los que ya conocemos sus secretos, el cerebro digital aprende a identificar los rasgos invisibles que delatan un frijol saludable. Es como si el cerebro digital desarrollara una "visión de rayos X".

Para que este detective digital aprenda, primero fragmentamos la imagen del frijol. El sistema no ve un frijol como lo hacemos nosotros; lo que percibe son miles de pequeños puntos llamados píxeles. Es aquí donde ocurre la verdadera magia matemática: la IA aprende que la relación numérica entre un píxel café oscuro y uno ligeramente más claro es, en realidad, la firma secreta de un escudo de protección. Al final, la computadora no está viendo colores en el sentido humano, sino que está resolviendo una ecuación compleja a través de los datos de la fotografía para estimar los escudos de protección.



Figura 4. *El proceso destructivo del frijol.*

La IA ofrece una alternativa no invasiva para analizar el frijol.

Pero hay un problema: construir el "cerebro digital" perfecto resulta difícil. Hay millones de formas de organizar a esos detectives (neuronas). Imagina que organizamos un torneo o una competencia de supervivencia de cerebros (Figura 6). Antes tenemos que definir los pasos del proceso de torneo:

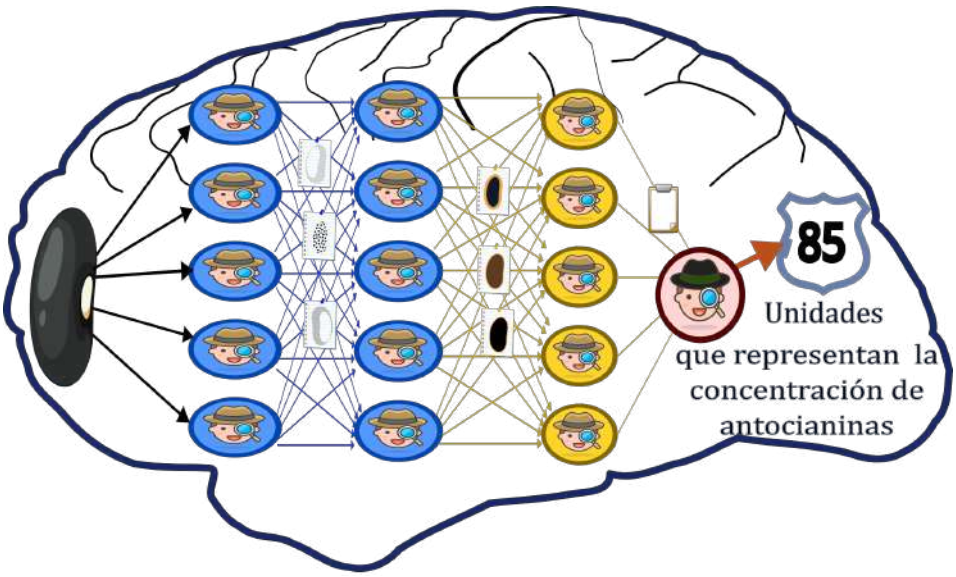


Figura 5. *En búsqueda de los niveles de protección.*

1. El tamaño de la población de participantes: creamos 100 cerebros digitales distintos, cada uno con un diseño diferente.
2. La competencia del torneo: los ponemos a todos a intentar adivinar los nutrientes de un grupo de frijoles.
3. La selección: los cerebros que más se acercan a la respuesta correcta "sobreviven" y pasan a la siguiente ronda. Los que fallan por mucho, quedan fuera del juego.
4. La evolución: los ganadores se "combinan" entre sí para crear una nueva generación de cerebros que heredan lo mejor de sus "padres". Incluso, a veces añadimos una mutación (un cambio sorpresa en su diseño) para ver si eso los hace aún más inteligentes.

Después de repetir este torneo cientos de veces, nos quedamos con el "gran campeón": un modelo de IA optimizado, increíblemente rápido y preciso ¡Es la evolución biológica aplicada a la tecnología! Posteriormente, el campeón se convierte en una herramienta accesible para los productores en el campo [7].

Hemos logrado transformar un proceso de destrucción en uno de observación profunda, pasamos de romper la caja para ver su contenido a descifrar las pistas que la naturaleza ha escrito en su superficie. Esta evolución no es solo tecnológica, es una herramienta de justicia para el campo.

Al usar la IA como una "lupa digital" que no quema lo que observa, podemos conocer la información nutricional sin dañar la muestra biológica. Lo más prometedor es que este mismo procedimiento rompe el ciclo destructivo no solo en el frijol, sino en diversos tipos de alimentos [8].

Mientras que el laboratorio tradicional consume tiempo, químicos dañinos y equipos costosos, nuestro "gran campeón" (la red neuronal optimizada) puede realizar la misma tarea con una simple fotografía. En este nuevo escenario, las muestras permanecen intactas, listas para ser sembradas y cumplir su ciclo biológico o para consumirse como alimento.

En un mundo donde la biodiversidad es nuestro tesoro más grande, aprender a mirar mejor con la IA marca la diferencia entre perder una especie o convertirla en la medicina del mañana. Al final, la clave del progreso no siempre está en abrir el objeto de estudio, sino en aprender a hacer las preguntas correctas sobre lo que ya podemos ver. Es, por primera vez, leer el libro de la naturaleza sin arrancar sus páginas. KS

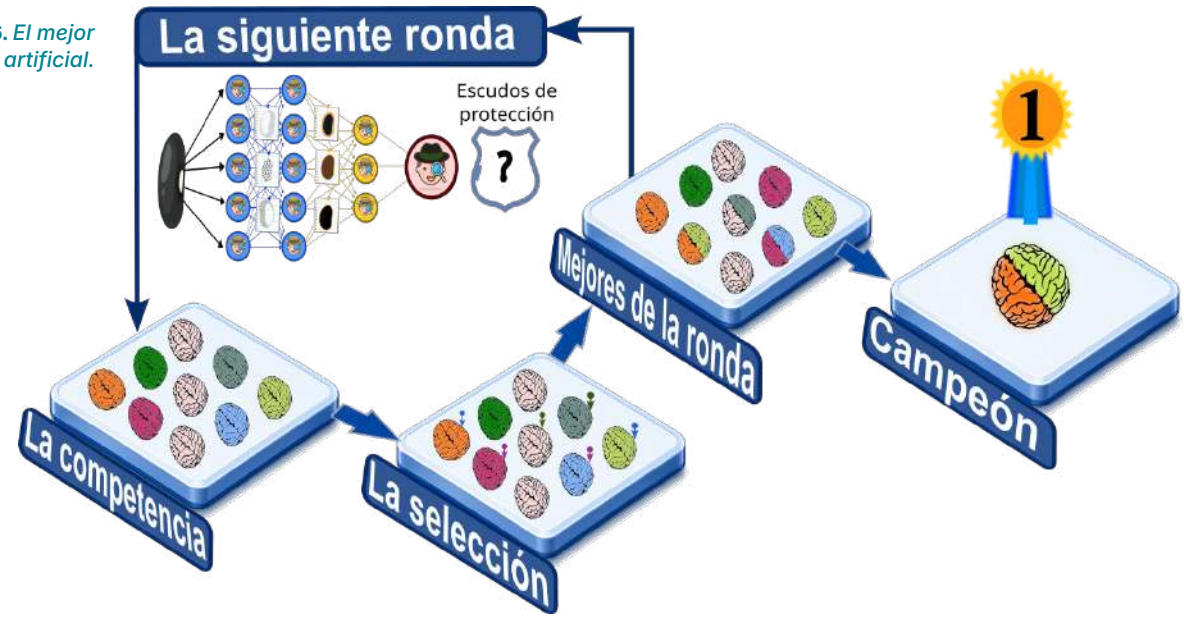


Figura 6. *El mejor detective artificial.*

REFERENCIAS

1. Chávez-Servia J.-L., Heredia-García E., Mayek-Pérez N., Aquino-Bolaños E.-N., Hernández-Delgado S., Carrillo-Rodríguez J.-C., Gill-Langarica H.-R., y Vera-Guzmán A.-M. (2016). Diversity of common bean (*Phaseolus vulgaris* L.) landraces and the nutritional value of their grains. En A. K. Goyal (Ed.), *Grain Legumes*. InTech. https://doi.org/10.5772/63439
2. Chen J., Xu B., Sun J., Jiang X., y Bai W. (2022). Anthocyanin supplement as a dietary strategy in cancer prevention and management: A comprehensive review. *Critical Reviews in Food Science and Nutrition*, *62*(26), 7242–7254. https://doi.org/10.1080/10408398.2021.1913092
3. Tsuda T. (2008). Regulation of adipocyte function by anthocyanins; possibility of preventing the metabolic syndrome. *Journal of Agricultural and Food Chemistry*, *56*(3), 642–646. https://doi.org/10.1021/jf073113b
4. Wallace Taylor C. (2011). Anthocyanins in cardiovascular disease. *Advances in Nutrition*, *2*(1), 1–7. https://doi.org/10.3945/an.110.000042
5. Nirumand M., Hajialyani M., Rahimi R., Farzaei M., Zingue S., Nabavi S., Bishayee A. (2018). Dietary plants for the prevention and management of kidney stones: Preclinical and clinical evidence and molecular mechanisms. *International Journal of Molecular Sciences*, *19*(3), 765. https://doi.org/10.3390/ijms19030765
6. Aquino-Bolaños E.-N., García-Díaz Y., Chávez-Servia J.-L., Carrillo-Rodríguez J., Vera-Guzmán A., Heredia-García E. (2016). Anthocyanins, polyphenols, flavonoids and antioxidant activity in common bean (*Phaseolus vulgaris* L.) landraces. *Emirates Journal of Food and Agriculture*, *28*(8), 581. https://doi.org/10.9755/ejfa.2016-02-147
7. Vargas-Hákim G.-A., Mezura-Montes E., Acosta-Mesa H.-G. (2021). Hybrid encodings for neuroevolution of convolutional neural networks: A case study. En *GECCO '21: Genetic and Evolutionary Computation Conference* (pp. 1762–1770). ACM. https://doi.org/10.1145/3449726.3463133
8. Morales-Reyes J.-L., Aquino-Bolaños E.-N., Acosta-Mesa H.-G., Márquez-Grajales A. (2024). Estimation of anthocyanins in heterogeneous and homogeneous bean landraces using probabilistic colorimetric representation with a neuroevolutionary approach. *Mathematical and Computational Applications*, *29*(4), 68. https://doi.org/10.3390/mca29040068

Declaración sobre uso de IA: En el desarrollo de este trabajo, los autores utilizaron Gemini Nano Banana para sugerencia de algunas imágenes. Tras el uso de esta herramienta, los autores revisaron y modificaron cuidadosamente el contenido y asumen la responsabilidad total de los contenidos de la publicación

Sobre los autores



José Luis Morales Reyes es un estudiante de posdoctorado en el Centro de Investigación y Desarrollo en Alimentos de la Universidad Veracruzana. El obtuvo su grado de doctor en el Instituto de Investigaciones en Inteligencia Artificial de la Universidad Veracruzana en 2022. Sus intereses de investigación incluyen procesamiento de imágenes digitales, visión computacional y aprendizaje automático.



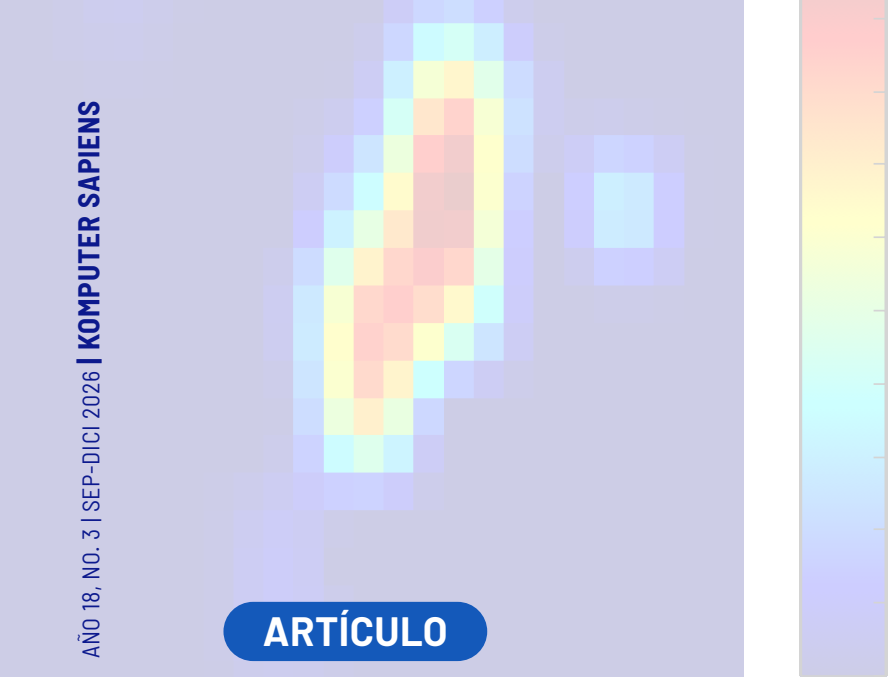
Elia Nora Aquino Bolaños es Doctora en Ciencia y Tecnología de los Alimentos por la Universidad Autónoma de Querétaro, México. Actualmente es investigadora adscrita al Centro de Investigación y Desarrollo en Alimentos de la Universidad Veracruzana. Sus intereses en investigación es alimentos funcionales y la calidad poscosecha de frutas y hortalizas.



Héctor Gabriel Acosta Mesa obtuvo el grado de Doctor en Inteligencia Artificial en la Universidad de Sheffield en Inglaterra en el año de 2003. Actualmente, es miembro del Sistema Nacional de Investigadoras e Investigadores en el nivel I y forma parte del núcleo académico del Instituto de Investigaciones en Inteligencia Artificial. Sus intereses de investigación comprenden la visión por computadora y sus aplicaciones, destacando el dominio de imagenología médica.



Jimena Esther Alba Jiménez es Doctora en Ciencia y Tecnología de los Alimentos por la Universidad Autónoma de Querétaro, México. Actualmente es Investigadora por México de la SECIHTI adscrita al Centro de Investigación y Desarrollo en Alimentos de la Universidad Veracruzana. Su interés en la investigación es la identificación, cuantificación y estabilización de sustancias bioactivas contra enfermedades.



ARTÍCULO

¿Cómo puede la inteligencia artificial escuchar a un motor y decir si está enfermo?

Martín Valtierra Rodríguez

Los motores eléctricos en la industria

Aunque pocas veces se ven, los motores eléctricos están en todas partes. Impulsan bombas que llevan agua a las casas, mueven bandas transportadoras en plantas de manufactura, hacen funcionar sistemas de ventilación, aire acondicionado y elevadores en hospitales y edificios, permitiendo que estas tareas y muchos otros procesos industriales operen de manera continua y eficiente. De hecho, diversos estudios estiman que alrededor del 45% del consumo eléctrico industrial a nivel mundial está asociado a motores eléctricos [1]. En otras palabras, gran parte de la energía que producen las centrales eléctricas termina convirtiéndose en movimiento gracias a estas máquinas. Son el corazón electromecánico de la industria.

Entre los distintos tipos de motores, el más utilizado es el motor de inducción. Su popularidad se debe a que es robusto, relativamente económico, soporta condiciones adversas y requiere menos mantenimiento que otras tecnologías. Su diseño simple y confiable lo ha convertido en la primera opción para las fábricas, sistemas de transporte y una enorme variedad de aplicaciones. Sin embargo, aunque estos motores son robustos, no significa que sean indestructibles. Con el paso del tiempo, las vibraciones mecánicas, las variaciones de carga mecánica, los esfuerzos térmicos y las condiciones ambientales adversas pueden deteriorar sus componentes internos. Algunos daños comienzan de manera casi imperceptible, sin ruidos evidentes ni cambios sustanciales en su funcionamiento. El motor sigue girando, aparentemente normal, no obstante, se comienza a generar un problema que, si no se detecta a tiempo, conducirá a su falla.

©2026 SMIA | ISSN 2007-069

Cuando finalmente el daño se manifiesta de forma evidente, puede ser demasiado tarde. Las consecuencias pueden ir desde pérdidas económicas importantes por paros no programados, hasta la interrupción completa de procesos críticos en sectores como la minería, la manufactura, la energía o la industria alimentaria. En ciertos casos, una falla severa puede incluso comprometer la seguridad del personal o dañar otros equipos conectados al sistema.

Por lo anterior, la comunidad científica se ha preguntado: ¿y si los motores pudieran avisar antes de fallar? ¿y si existiera una forma de escucharlos continuamente, interpretar sus señales internas y detectar anomalías cuando aún son pequeñas? La respuesta a estas preguntas conduce a temas como el procesamiento de señales y la inteligencia artificial (IA).

El daño de barras rotas en el rotor

En la figura 1a se muestra un motor de inducción típico, conectado a un freno dinamométrico para emular la carga mecánica que un motor tiene cuando, por ejemplo, está conectado a una banda transportadora. Uno de sus principales componentes es el rotor (ver figura 1b). En muchos diseños, el rotor está construido en una configuración conocida como jaula de ardilla (ver figura 1c). Esta estructura está formada por barras conductoras, generalmente de aluminio o cobre, dispuestas longitudinalmente y unidas en sus extremos mediante anillos. El conjunto recuerda, efectivamente, a una jaula de ardilla. En ambas figuras (1b y 1c) se observa la perforación realizada de forma intencional y controlada en el rotor con la finalidad de generar el daño de barra rota en un entorno de laboratorio de investigación. En situaciones reales, esta perforación no es visible ni homogénea, ya que la fractura de la barra es interna y no controlada

Cuando el motor opera, el campo magnético generado en el estator induce corrientes eléctricas en estas barras. Como resultado de la interacción electromagnética, el rotor comienza a girar y se produce el movimiento

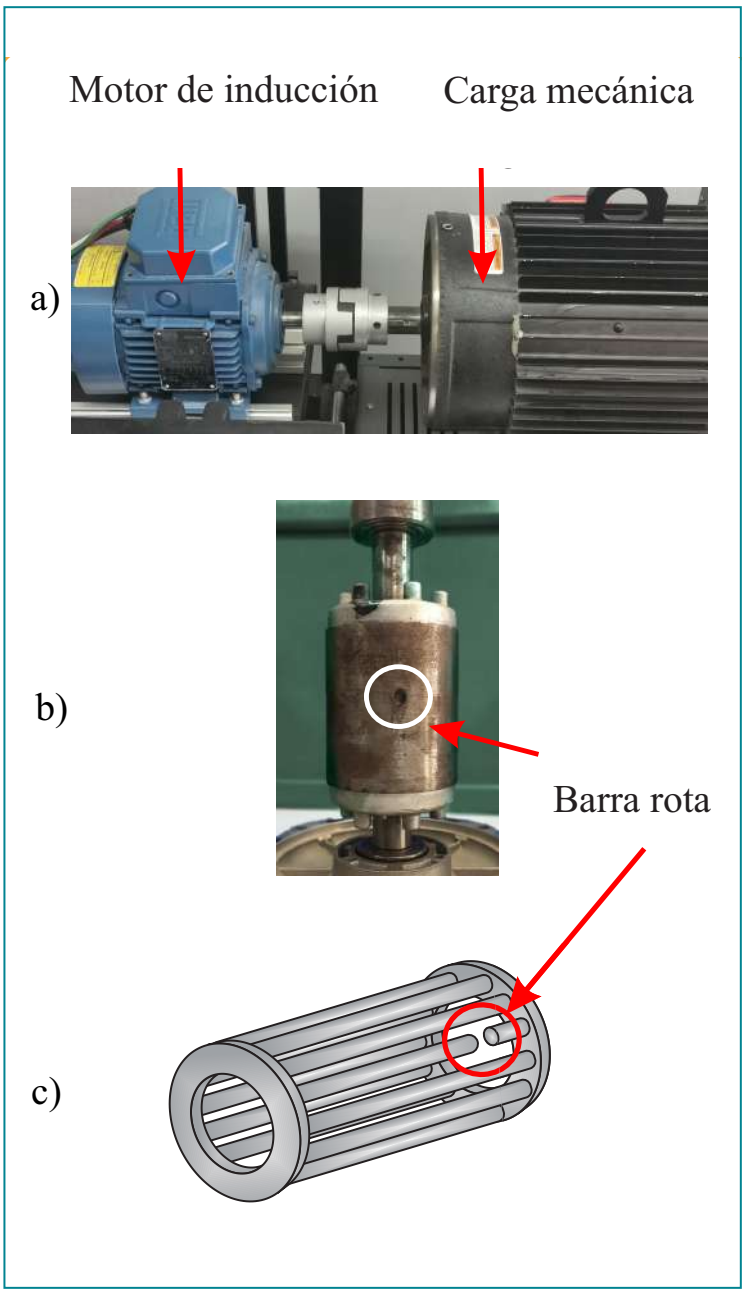


Figura 1. *a) Motor de inducción, b) rotor y c) estructura tipo jaula de ardilla.*

mecánico que finalmente acciona bombas, ventiladores o sistemas industriales completos. Sin embargo, este proceso no ocurre en condiciones ideales. Durante su vida útil, el motor está sometido a esfuerzos mecánicos constantes, vibraciones, arranques frecuentes, sobrecargas, desbalances de tensión, fluctuaciones térmicas e incluso ambientes agresivos con polvo o humedad. Con el tiempo, estas condiciones pueden debilitar las barras del rotor hasta provocar pequeñas grietas o fracturas [2]. Cuando una barra pierde continuidad eléctrica, se

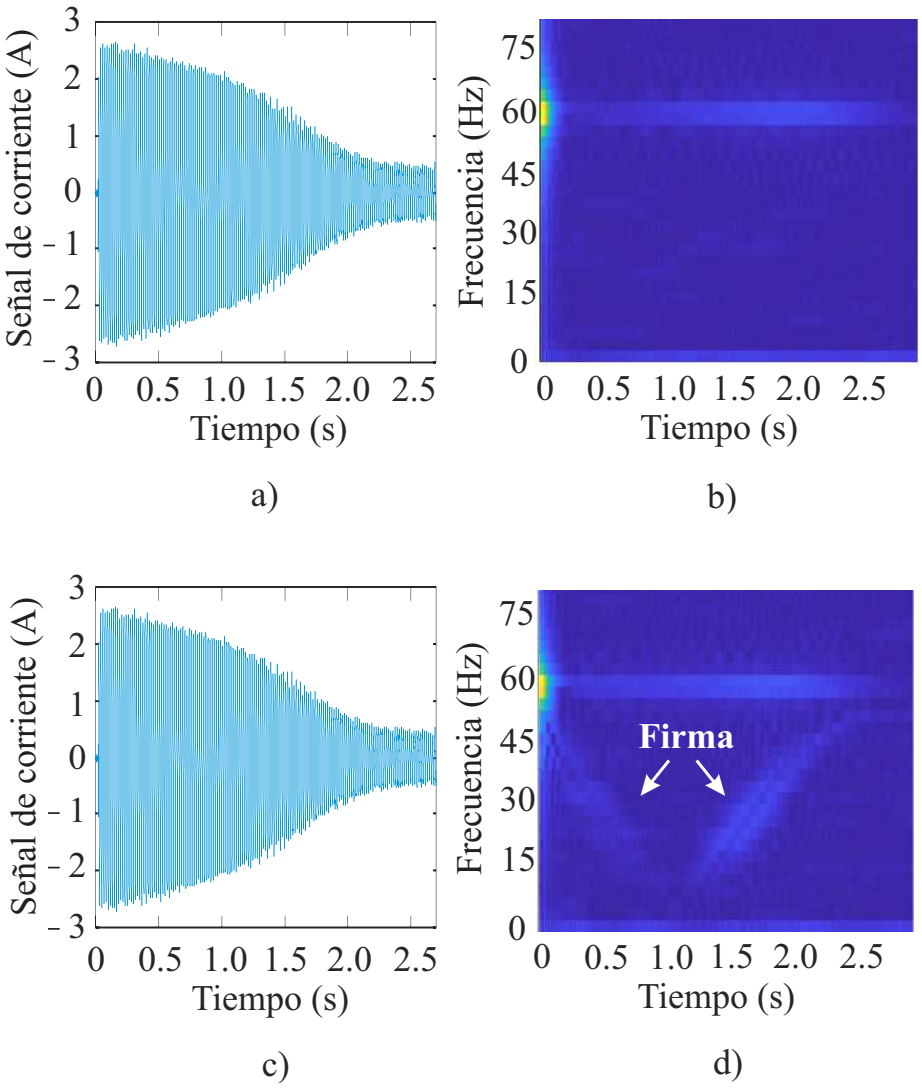


Figura 2. *a) Señal de corriente del motor sin daño y b) su espectrograma. c) Señal de corriente del motor con daño de barra rota y d) su espectrograma.*

El daño por barras rotas deja una firma característica en las señales eléctricas del motor

produce lo que se conoce como daño por barra rota (ver figuras 1b y 1c).

Lo crítico es que este daño rara vez es inmediato o catastrófico en sus primeras etapas. El motor continúa operando, aparentemente normal. No se detiene de forma súbita ni emite señales evidentes de alarma. Sin embargo, internamente el equilibrio electromagnético se altera. El campo magnético deja de ser perfectamente simétrico y comienzan a generarse fuerzas adicionales, vibraciones anómalas y esfuerzos que pueden acelerar el deterioro del rotor. Si no se detecta a tiempo, una sola barra rota puede inducir tensiones adicionales en barras vecinas, favoreciendo un efecto en cadena. Así, lo que comenzó como una pequeña fractura puede evolucionar hacia un daño más severo, pérdida de eficiencia, aumento de temperatura y, eventualmente, la falla del motor.

La señal de corriente habla por el motor

Aunque no se puede ver el rotor directamente, y mucho menos las barras en la jaula de ardilla mientras el motor opera, sí es posible medir algo mucho más accesible: la corriente eléctrica que consume. Esa corriente no es simplemente una señal sinusoidal perfecta; contiene pequeñas variaciones, imperceptibles a simple vista, que reflejan el estado interno del motor. Cuando una barra está rota, aparecen componentes adicionales en ciertas frecuencias específicas. Es como si el motor cambiara ligeramente su voz (es decir, su señal de corriente) para indicar que está presentando un daño [2].

Para el motor de la figura 1a, las figuras 2a y 2c muestran las señales de corriente consumidas por un rotor en buen estado y por un rotor con daño de barra rota, respectivamente. Es importante mencionar que la forma de la señal de corriente corresponde al arranque del motor, ya que al inicio consume una mayor corriente para poder vencer su inercia estática y, poco a poco, esta disminuye hasta alcanzar su estado o velocidad estable. En estas señales de corriente en el dominio del tiempo, es prácticamente imposible identificar variaciones que pudieran asociarse al daño y, en consecuencia, determinar si el motor presenta o no el daño.

©2026 SMIA | ISSN 2007-069

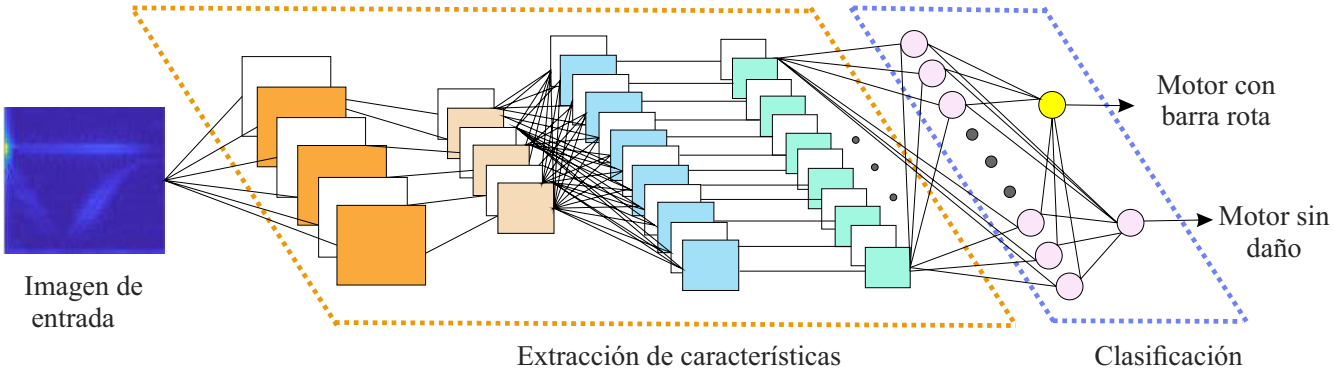


Figura 3. *Arquitectura general de una red neuronal convolucional.*

Convertir la señal de corriente en una imagen

Para contribuir a la solución de la problemática anterior, una herramienta clásica del procesamiento digital de señales es la transformada corta de Fourier (en inglés, short-time Fourier transform, STFT) [3].

De manera sencilla, la STFT permite observar cómo el contenido en frecuencia de una señal cambia a lo largo del tiempo. En lugar de analizar únicamente la forma de la señal en el tiempo, esta herramienta divide la señal en pequeños fragmentos y estudia qué frecuencias están presentes en cada uno de ellos. El resultado es una representación bidimensional conocida como espectrograma, donde un eje corresponde al tiempo, otro a la frecuencia y el color indica la intensidad o energía de cada componente.

Una forma intuitiva de entenderlo es pensar en una canción musical. Si se observa únicamente la señal en el tiempo, se observaría una forma de onda compleja, pero no se podría distinguir fácilmente qué instrumentos están sonando ni en qué momento lo hacen. En cambio, el espectrograma sería similar a una partitura visual que muestra cuándo aparecen los sonidos graves, los agudos o ciertos patrones característicos. En el caso de los motores eléctricos, ocurre algo similar. Durante el arranque o ante la presencia de una falla, las frecuencias presentes en la señal de corriente cambian de manera dinámica. El espectrograma permite visualizar estas variaciones como patrones de energía que evolucionan en el tiempo, revelando comportamientos que resultan prácticamente invisibles al observar solo la señal temporal.

La IA explicativa revela qué patrones sustentan el diagnóstico, aumentando confianza y validación física

Cuando existe una barra rota, aparecen patrones característicos en ciertas regiones del espectrograma (ver figuras 2b y 2d). Es como si la falla dejara una huella digital visual. La barra rota se caracteriza por un patrón en forma de V que aparece al lado de la frecuencia fundamental (60 Hz en México). Para una mejor apreciación, se suprimió la energía de la componente de 60 Hz.

Con estas imágenes, es posible usar herramientas de IA diseñadas para analizar y entender imágenes.

IA: Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN, por sus siglas en inglés, convolutional neural network) se han vuelto famosas por su capacidad para reconocer objetos en fotografías, rostros humanos o incluso tumores en imágenes médicas [4], aprendiendo patrones complejos en imágenes, incluso cuando estos no son evidentes para el ojo humano.

Si la señal de corriente del motor se transforma en un espectrograma (ver figura 3),

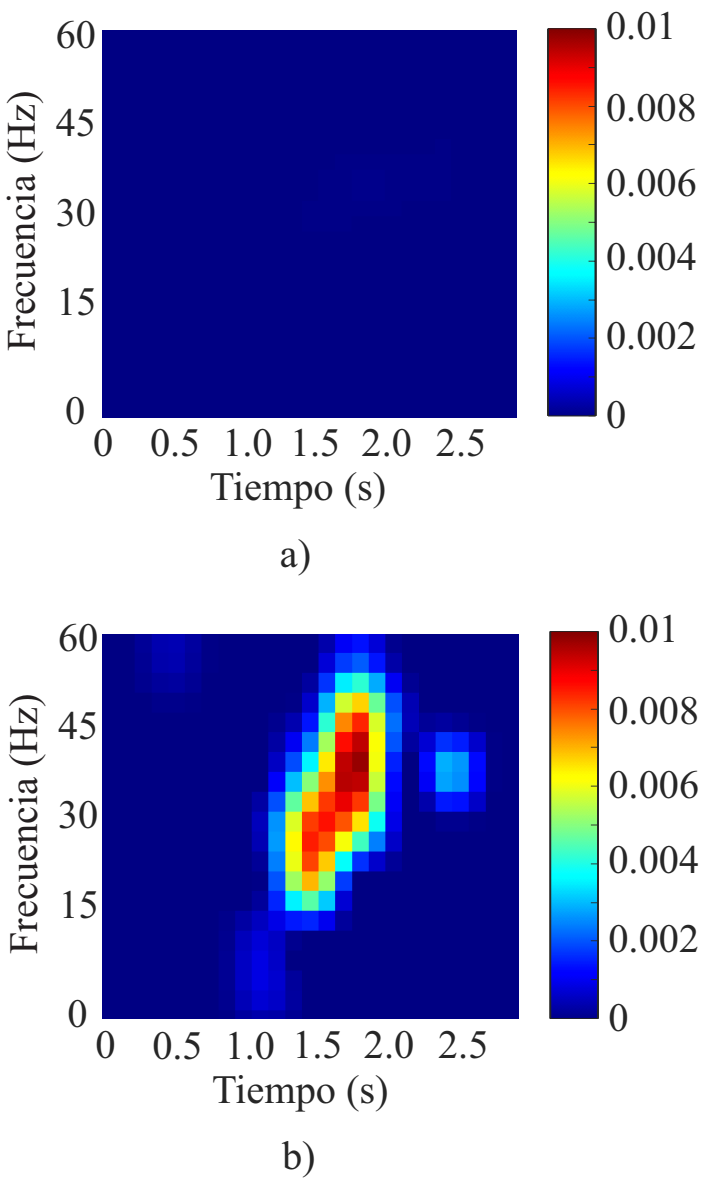


Figura 4. *Resultados de Grad-CAM para a) imagen de espectrograma de motor sin daño y b) un motor con daño de barra rota.*

la CNN puede analizar dicha imagen. Así, la red, después de un proceso de entrenamiento con ejemplos de motores sanos y motores con barras rotas, aprende automáticamente a distinguir entre ambos casos.

Lo más interesante de esta red es que no necesita que se le indique explícitamente qué frecuencia observar o qué fórmula aplicar. Aprende directamente de los datos. De esta manera, una imagen desconocida que pasa por una etapa de extracción de características y de clasificación puede ser asociada automáticamente a un motor sin daño o a un motor con daño de barra rota (ver ejemplo en la figura 3). Todo esto es posible gracias a la combinación del procesamiento de señales clásico con técnicas modernas de IA.

Inteligencia artificial explicativa

Muchos modelos de IA funcionan como cajas negras; es decir, entregan una respuesta, pero no explican cómo llegaron a ella. En aplicaciones industriales, donde las decisiones pueden implicar detener una planta completa, esto podría no ser suficiente.

Aquí entra el concepto de IA explicativa (XAI, por sus siglas en inglés, eXplainable Artificial Intelligence). Las técnicas de IA explicativa permiten visualizar qué regiones del espectrograma influyeron más en la decisión del modelo. En otras palabras, la red no solo dice si hay un daño o no, sino que señala qué patrones específicos activaron su diagnóstico. Esto no solo incrementa la confianza en el sistema, sino que también permite a los ingenieros validar que el modelo está aprendiendo características físicamente coherentes.

La figura 4 muestra, mediante la técnica explicativa de mapas de activación de clase ponderados por gradiente (Grad-CAM, por sus siglas en inglés, Gradient-weighted Class Activation Mapping) [5], qué regiones del espectrograma aportan en mayor medida al diagnóstico de la condición del motor. Considerando la misma escala de magnitud, en la figura 4a se observa un color uniforme, ya que toda la imagen aporta información similar para identificar un motor sin daño. En cambio, para un motor con daño de barra rota (ver figura 4b), el lado derecho del patrón V influye más en su identificación, lo cual es físicamente congruente y refuerza el diagnóstico obtenido.

Conclusión: mantenimiento predictivo inteligente

La combinación de señales eléctricas, transformadas tiempo-frecuencia, redes neuronales convoluciona-

©2026 SMIA | ISSN 2007-069

les y técnicas de IA explicativa abre la puerta a sistemas de diagnóstico más confiables y transparentes.

En lugar de esperar a que el motor falle, este puede monitorearse continuamente y detectar anomalías en etapas tempranas, reduciendo costos, mejorando la seguridad y optimizando la operación industrial en el contexto del mantenimiento predictivo inteligente. Además, este enfoque demuestra que la IA no reemplaza el conocimiento de ingeniería, sino que lo potencia. La física del motor sigue siendo fundamental; la IA actúa como una herramienta avanzada para interpretar la información contenida en las señales.

El futuro del diagnóstico industrial no solo implica máquinas inteligentes, sino máquinas comprensibles; es decir, sistemas capaces de explicar sus decisiones y colaborar con los ingenieros humanos. Los motores eléctricos seguirán siendo el corazón de la industria; pero, gracias al procesamiento digital de señales y a la IA explicativa, ahora se pueden escuchar y entender mejor. **KS**

Referencias

1. Stockton, C. A., McElveen, R. F., y Chastain, E. (2024) "The integral role of electric motors in achieving sustainability". *IEEE Transactions on Industry Applications*. Vol. 60, No. 5, pp. 7949-7957.
2. Halder, S., Bhat, S., Zychma, D., y Sowa, P. (2022) "Broken rotor bar fault diagnosis techniques based on motor current signature analysis for induction motor - A review". *Energies*. Vol. 15, No. 22, pp. 8569.
3. Burriel-Valencia, J., Puche-Panadero, R., Martinez-Roman, J., Sapena-Bano, A., y Pineda-Sanchez, M. (2017) "Short-frequency Fourier transform for fault diagnosis of induction machines working in transient regime". *IEEE Transactions on Instrumentation and Measurement*. Vol. 66, No. 3, pp. 432-440.
4. Li, Z., Liu, F., Yang, W., Peng, S., y Zhou, J. (2021) "A survey of convolutional neural networks: analysis, applications, and prospects". *IEEE transactions on neural networks and learning systems*. Vol. 33. No. 12, pp. 6999-7019.
5. Vinogradova, K., Dibrov, A., & Myers, G. (2020, April), "Towards interpretable semantic segmentation via gradient-weighted class activation mapping (student abstract)". En *Proc. of the Thirty-Fourth AAAI Conference on Artificial Intelligence*. New York, USA, pp. 13943-13944.

Sobre el autor



Martín Valtierra Rodríguez es profesor investigador en la Facultad de Ingeniería de la Universidad Autónoma de Querétaro. Obtuvo el título de Ingeniero en Mecatrónica y el grado de Maestro en Ingeniería Eléctrica por la Universidad de Guanajuato, así como el Doctorado en Ingeniería por la Universidad Autónoma de Querétaro. Sus principales líneas de investigación incluyen el procesamiento digital de señales y la inteligencia artificial aplicados al diagnóstico de daños en sistemas mecánicos y eléctricos, el monitoreo de la salud estructural y el análisis de bioseñales.

ARTÍCULO

Laboratorios, clubes y talleres: estrategias funcionales para involucrar a más niñas y mujeres en STEM e IA.

Marcos Yamir Gómez Ramos y Laura Araceli Guerrero Herrera



Introducción

En las últimas décadas, la participación de las mujeres en la educación superior ha crecido de manera sostenida en la mayoría de los países de América Latina. Sin embargo, este avance no se ha distribuido de forma homogénea entre las distintas áreas del conocimiento. Las carreras relacionadas con ingeniería, tecnologías de la información, matemáticas, física o inteligencia artificial continúan mostrando una subrepresentación femenina persistente [1], [2].

La magnitud del desafío puede observarse en diversos indicadores internacionales. De acuerdo con la UNESCO, las mujeres representan aproximadamente el 35% de la matrícula en carreras STEM, mientras que en áreas relacionadas con tecnologías de la información, computación e inteligencia artificial los porcentajes suelen ser considerablemente menores. En América Latina, aunque la participación femenina en educación superior es elevada, persisten diferencias importantes en disciplinas vinculadas con ingeniería, ciencias computacionales y tecnologías digitales.

Los avances en materia de acceso equitativo a la educación han permitido que cada vez más mujeres accedan a la educación superior. Sin embargo, la participación femenina sigue reduciéndose en áreas estratégicas para la innovación y la transformación digital, como la ingeniería, las tecnologías de la información y la inteligencia artificial. La figura 1 permite visualizar esta realidad de forma sencilla y comprender por qué sigue siendo necesario impulsar acciones que acerquen a más niñas y jóvenes a las disciplinas STEM [2], [3], [10].

©2026 SMIA | ISSN 2007-069

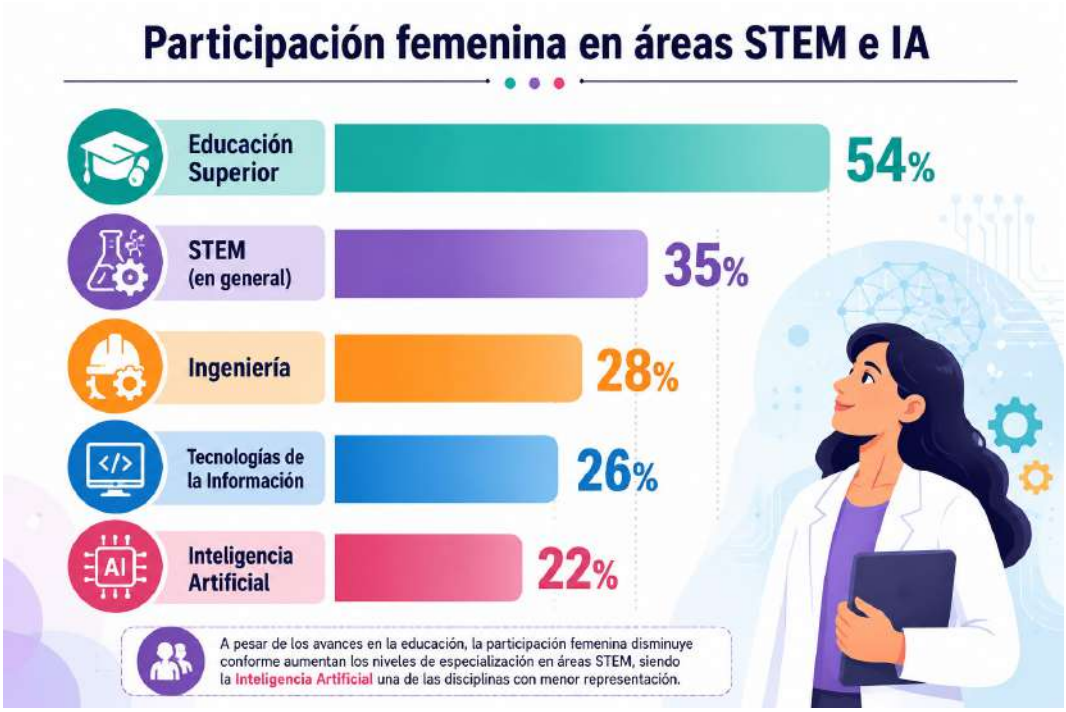


Figura 1. *Participación femenina en áreas STEM e IA. Indicadores internacionales de participación femenina en educación y empleo científico-tecnológico. Fuentes: UNESCO Science Report (2021) y UNESCO, Call to Action to Close the Gender Gap in Science (2025). Creada con ChatGPT*

UNESCO señala que las mujeres representaron el 54% del incremento total de la matrícula en educación superior; el 35% de las personas graduadas en STEM a nivel mundial son mujeres; del cual un 28% de las personas graduadas en ingeniería son mujeres y finalmente reporta que las mujeres representan un 22% de los profesionales de IA a nivel mundial (Figura 1).

Diversos informes internacionales coinciden en que esta brecha no se explica por falta de capacidad, sino por una combinación de factores sociales, culturales y educativos: estereotipos de género, ausencia de modelos a seguir, expectativas familiares diferenciadas y experiencias escolares que, de manera explícita o implícita, desalientan la permanencia de las mujeres en estos campos [3], [4].

La consecuencia es un fenómeno bien conocido: aunque muchas niñas muestran interés por la ciencia en etapas tempranas, este interés se diluye con el paso del tiempo, dando lugar a lo que se ha descrito como una "tubería con fugas" en las trayectorias STEM (Ciencia, Tecnología, Ingeniería y Matemáticas, por sus siglas en inglés) [5].

Frente a este panorama, surge una pregunta clave: ¿Qué tipo de experiencias educativas pueden marcar una diferencia real?

Laboratorios, clubes y talleres como modelos de aprendizaje

A diferencia de los modelos tradicionales centrados en la clase expositiva, los laboratorios educativos, clubes de ciencia y talleres tecnológicos se caracterizan por promover el aprendizaje activo, el trabajo colaborativo y la experimentación directa. La evidencia muestra que este tipo de enfoques no solo mejora el rendimiento académico, sino también la innovación y el sentido de pertenencia del estudiantado [6].

"No faltan mujeres en STEM: faltan espacios donde puedan descubrir que también les pertenece"

En el caso de las mujeres en STEM, estos espacios cumplen una función adicional: permiten construir una identidad científica a través de la práctica, reduciendo el impacto de los estereotipos que asocian la ciencia y la tecnología con lo "masculino" [7]. Estudios sobre motivación vocacional indica que la percepción de autosuficiencia y la posi-

AÑO 18, NO. 3 | SEP-DIC| 2026 | KOMPUTER SAPIENS



Figura 2. *El camino de una niña hacia la IA. Creada con ChatGPT*

bilidad de verse a una misma como "alguien que puede hacer ciencia" son factores decisivos en la elección de carrera [8].

Además, la presencia de mentoras y modelos a seguir en estos espacios han demostrado tener un efecto positivo en las aspiraciones académicas y profesionales de niñas y jóvenes, especialmente en contextos donde las mujeres son minoría en las aulas técnicas [9], [10].

Experiencias en México y América Latina

En América Latina han surgido diversas iniciativas que ilustran el potencial de estos enfoques, como los programas de clubes de ciencia y tecnología en escuelas públicas de México, que han permitido que niñas y adolescentes tengan su primer contacto con la robótica, la programación o la experimentación científica más allá del currículo formal. Estas experiencias, aunque muchas veces impulsadas por esfuerzos docentes locales, muestran cómo el acceso temprano a actividades prácticas puede transformar la percepción que las estudiantes tienen sobre la tecnología.

Algunas iniciativas han demostrado resultados particularmente relevantes en la región. En México, programas como *Technovation Girls* y *Movimiento STEM* han impulsado la participación de miles de niñas y adolescentes en el desarrollo de aplicaciones tecnológicas para resolver problemas de sus comunidades. De manera similar, clubes de robótica y programación implementados por universidades y centros educativos en diversos estados del país han permitido que estudiantes de educación básica y media superior desarrollen habilidades digitales y científicas desde edades tempranas.

En América Latina, organizaciones como Fundación Ingeniosas en Chile, Niñas Pro en Colombia y Laboratoria en varios países de la región han contribuido a reducir estereotipos de género y a fortalecer la participación femenina en áreas tecnológicas mediante mentorías, talleres prácticos y comunidades de aprendizaje [11]. Estas experiencias coinciden en un elemento fundamental: ofrecer espacios donde las participantes puedan experimentar, crear y resolver problemas reales utilizando la ciencia y la tecnología [12].

Mujeres e Inteligencia Artificial: una nueva frontera de inclusión

La Inteligencia Artificial (IA) se ha convertido en una de las tecnologías más influyentes del siglo XXI. Desde los sistemas de recomendación utilizados en plataformas digita-

©2026 SMIA | ISSN 2007-069

les hasta los modelos generativos capaces de producir texto, imágenes o código, la IA está transformando la manera en que las personas estudian, trabajan y toman decisiones. Sin embargo, diversos estudios han señalado que la participación femenina en las áreas relacionadas con la IA sigue siendo considerablemente menor que la de los hombres. De acuerdo con el Global Gender Gap Report 2024 del World Economic Forum, las mujeres representan menos de un tercio de los profesionales especializados en IA a nivel mundial. Esta situación resulta preocupante porque los sistemas de IA aprenden de los datos y son diseñados por equipos humanos. Cuando estos equipos carecen de diversidad, existe un mayor riesgo de que los algoritmos reproduzcan sesgos y desigualdades presentes en la sociedad.

Promover la participación de niñas y jóvenes en laboratorios de programación, clubes de robótica, talleres de ciencia de datos e iniciativas de aprendizaje automático no solo contribuye a reducir la brecha de género, sino que también favorece el desarrollo de tecnologías más inclusivas y representativas de la diversidad humana.

En México también han surgido iniciativas orientadas a acercar la IA a niñas y jóvenes. Universidades, centros de investigación y organizaciones de divulgación científica han desarrollado talleres de programación, ciencia de datos y aprendizaje automático dirigidos a estudiantes de educación básica y media superior. Estas actividades buscan que las participantes comprendan que la IA no es una tecnología reservada para especialistas, sino una herramienta que puede utilizarse para resolver problemas sociales, ambientales y comunitarios.

Mujeres construyendo la Inteligencia Artificial

La historia de la IA también ha sido construida por mujeres que, en muchos casos, no recibieron el reconocimiento merecido. Entre ellas destaca Ada Lovelace, considerada la primera programadora de la historia, cuyos trabajos sentaron las bases conceptuales de la computación moderna. Posteriormente, otras científicas como Karen Sparck Jones realizaron contribuciones fundamentales al procesamiento de lenguaje natural, tecnología que hoy utilizan asistentes virtuales y sistemas de IA generativa.

Recientemente, científicas como Fei-Fei Li han impulsado avances significativos en visión por computadora mediante el desarrollo de bases de datos que permitieron entrenar modelos modernos de IA. Por su parte, Tomnit Gebru y Joy Boulamwini han contribuido a visibilizar los riesgos asociados con los sesgos algorítmicos y la necesidad de construir sistemas más justos y transparentes. Estas contribuciones demuestran que las mujeres no solo participan en la IA, sino que han sido protagonistas de algunos de sus avances más importantes.

Lo que dice la investigación: no es solo intuición

La literatura internacional en educación STEM respalda varias de estas observaciones. En primer lugar, existe evidencia sólida de que la exposición temprana a experiencias prácticas en ciencia y tecnología se asocia con una mayor posibilidad de elegir y persistir en carreras STEM [8],[6].

En segundo lugar, los programas de mentoría y referentes femeninos muestran efectos positivos en la motivación, la autoeficacia y el sentido de pertenencia de las estudiantes [9],[10]. Finalmente, distintos estudios advierten que las intervenciones aisladas como talleres únicos o eventos conmemorativos tienen un impacto limitado si no se integran en estrategias de largo plazo con seguimiento y evaluación [13].

En síntesis, no se trata solo de “inspirar”, sino de construir trayectorias educativas sostenidas que acompañen a las estudiantes en diferentes etapas de su formación.

Una mirada crítica hacia las estrategias de inclusión de las mujeres en STEM

A pesar del crecimiento de iniciativas orientadas a mujeres en STEM, persisten varios problemas estructurales. Uno de los más frecuentes es la fragmentación

de los esfuerzos: proyectos de corta duración, dependientes del entusiasmo individual de algunos docentes o gestores, sin respaldo institucional suficiente ni continuidad en el tiempo.

"Cuando las niñas crean tecnología, no solo cambia su futuro: cambia la innovación."

Otro desafío es la falta de evaluación sistemática. Con frecuencia, el éxito de estos programas se mide únicamente por el número de participantes, sin analizar su impacto real en la permanencia, el desempeño o las decisiones vocacionales en las estudiantes [14]. Finalmente, muchos enfoques siguen centrados en "motivar" a las niñas, pero dejan intactas las condiciones estructurales que producen exclusión: ambientes poco acogedores, currículos rígidos, prácticas docentes poco inclusivas y culturas institucionales que producen estereotipos [4], [3].

Propuestas prácticas para construir espacios funcionales.

Para escuelas y docentes:

- Apostar por la continuidad: es preferible un club STEM pequeño pero permanente que múltiples talleres aislados.
- Diseñar proyectos con sentido social: vincular la ciencia y la tecnología con problemas reales de la comunidad aumenta la relevancia y la motivación [10].
- Cuidar el clima del aula y del taller: el uso de lenguaje inclusivo, reglas claras y de respeto y dinámicas colaborativas es fundamental para generar entornos seguros.
- Visibilizar referentes femeninos: invitar profesionistas, egresadas o investigadoras ayuda a ampliar el horizonte de posibilidades para las estudiantes [9].

Para universidades

- Programas de acompañamiento y mentoría para estudiantes de nuevo ingreso a carreras STEM, con especial atención a los primeros semestres o cuatrimestres, donde se concentra la mayor deserción.
- Laboratorios abiertos y actividades de vinculación con escuelas de educación básica y media superior, para fomentar vocaciones tempranas.
- Evaluar más allá de la matrícula: incorporar indicadores de permanencia, satisfacción, sentido de pertenencia y desarrollo de habilidades.

Para instituciones políticas y públicas

- Financiamiento sostenido para programas de largo plazo, evitando la lógica de proyectos únicamente demostrativos.
- Producción y uso de datos desagregados por género, que permitan diseñar políticas basadas en evidencia [1],[14].
- Articulación entre escuela, universidad y comunidad, con el fin de construir trayectorias educativas continuas en STEM.

De usuarias a creadoras: más mujeres diseñando la IA del futuro

La inteligencia artificial está redefiniendo numerosos sectores, incluyendo la educación, la salud, la industria, la agricultura y los servicios financieros. Cada vez más decisiones son apoyadas o automatizadas mediante algoritmos, por lo que resulta fundamental que las personas encargadas de diseñar estas tecnologías representen la diversidad de la sociedad.

Cuando las mujeres participan en el desarrollo de sistemas inteligentes aportan perspectivas distintas sobre los problemas que deben resolverse, los datos que deben analizarse y los impactos que estas tecnologías pueden generar. Diversos estudios han demostrado que los equipos diversos tienden a desarrollar soluciones más innovadoras y a identificar riesgos que podrían pasar desapercibidos en grupos homogéneos [2],[15].

Por esta razón los laboratorios, clubes y talleres STEM deben evolucionar para incorporar actividades relacionadas con la programación, ciencia de datos, aprendizaje automático e IA. Acercar estas tecnologías a niñas y jóvenes desde edades tempranas permitirá que más mujeres participen en una de las áreas con may-

©2026 SMIA | ISSN 2007-069

or crecimiento y demanda profesional en las próximas décadas.

La inclusión femenina en la IA no es únicamente una cuestión de equidad. También es una condición necesaria para construir sistemas tecnológicos más confiables, éticos y representativos de las necesidades de toda población.

Conclusiones

La evidencia y las experiencias en México y América Latina muestran que los laboratorios educativos, clubes científicos y talleres prácticos pueden ser herramientas poderosas para aumentar la participación de mujeres y niñas en STEM, siempre que se integren en estrategias de largo plazo, con apoyo institucional y evaluación sistemática.

Más que actividades complementarias, estos espacios deben entenderse como piezas clave de una política educativa inclusiva, capaz de ofrecer a niñas y jóvenes no solo la oportunidad de acercarse a la ciencia y la tecnología, sino también de reconocerse como protagonista en su construcción. KS

Referencias

1. UNESCO. (2017). Cracking the Code: Girl´s and Women´s Education in STEM.
2. World Economic Forum (2024). Global Gender Gap Report 2024.
3. UNESCO (2023). Technology on Her Terms.
4. Cheryan, S., Ziegler, S., Montoya, A., & Jiang, L. (2017). Why are some STEM fields more gender balanced than others? Psychological Bulletin, 143(1), 1-35.
5. OECD (2023). Bridging Gender Gaps in AI Skills.
6. Freeman, S., Eddy, S.L.,McDonough, M., Smith, M.K., Okoroafor, N., Jordt, H., &Wenderoth, M.P. (2014). Active learning increases student performance in STEM. Proceedings of the National academy of Sciences, 111(23), 8410-8415.
7. Master, A., Cheryan, S., &Meltzoff, A. N. (2016). Computing wheter she belongs: Stereotypes undermine girls' interest and sense of belonging in computer science. Journal of educational Psychology, 108(3), 424-437.
8. Wang, M. T., & Degol, J.L. (2017). Gender gap in science, technology, engineering and mathematics (STEM): Current knowledge, implications for practice, policy and future directions. Educational Psichology Review, 29, 119-140.
9. UN Women (2024). Women in Science, Technology and Innovation.
10. Standford Institute for Human-Centered AI (2025). AI Index Report 2025.
11. UNESCO (2020). Mujeres en STEM en América Latina y el Caribe.
12. UNICEF & UNESCO (2024). GirsI in Digital and AI Education.
13. National Academics of Sciences, Engineering, and Medicine. (2020). Promising Practices for Addresing the Underrepresentation of Women in STEM
14. OECD. (2018). Bridging the Digital Gender Divide.
15. European Commision. (2021). She figures: Gender in Research and Innovation.

Declaración:
Durante la preparación de este trabajo, los autores utilizaron ChatGPT para la generación de las imágenes que se incluyen en el artículo. Después de utilizar esta herramienta, los autores revisaron y editaron el contenido según fuera necesario y asumen plena responsabilidad de lo publicado.

Sobre los autores



Marcos Yamir Gómez Ramos, es Doctor en Ciencias de la Computación y profesor investigador en la carrera de Ingeniería en Tecnologías de la Información e Innovación Digital y de la Maestría en Inteligencia Artificial en la Universidad Politécnica Metropolitana de Hidalgo. Tiene más de 15 años de experiencia docente en la Educación Superior y su trabajo se centra en educación en tecnologías digitales, Inteligencia Artificial e inclusión educativa.



Laura Araceli Guerrero Herrera, es Doctora en Ciencias Económico Administrativas y profesora de la carrera de Ingeniería Financiera y la Maestría en Finanzas y Gestión en la Universidad Politécnica de Pachuca. Su principal línea de investigación es el análisis de competencias en el mercado laboral con herramientas de Inteligencia Artificial y Procesamiento de Lenguaje Natural para el fortalecimiento del capital humano.

ARTÍCULO

Inteligencia Artificial de los Residuos Sólidos Urbanos: cómo la tecnología aprende a limpiar nuestras ciudades

Araceli Hernández Cruz, Jorge Luis Castañeda Gutiérrez, José Crispín Hernández Hernández

La generación de Residuos Sólidos Urbanos (RSU) es uno de los desafíos más apremiantes del siglo XXI, abarca las tres vertientes de la sostenibilidad: social, económica y ambiental. Con más de 2,100 millones de toneladas anuales a nivel mundial y con tendencias preocupantes; se prevé alcanzar la impactante cifra de 3,400 millones para 2050, de las cuales solo el 19% se reciclan [1].



Mientras tanto, en 2021, Latinoamérica y el Caribe generaron 230 millones de toneladas, pero solo el 4% fueron aprovechados, mientras el 46% se envió a rellenos sanitarios, el 50% no fue recolectado o depositado en sitios no controlados.[2]. Aunado a esto, en México, en 2022, se reportaron 108,146 millones de toneladas al día, de los cuales el 78% puede ser aprovechado, pero solo el 9% se recupera, y en estados como Tlaxcala, que se urbaniza desordenadamente, se reportaron 1103.34 toneladas al día en 2020[3]. Estos datos reflejan una brecha importante entre la realidad y el potencial de aprovechamiento, lo que ocasiona preguntarse: ¿Cómo podemos gestionar estos residuos?

La gestión de los RSU es un proceso complejo, con logística inadecuada, que ha generado problemas en las tres vertientes de la sostenibilidad que incluyen los impactos ambiental, social y económico. El impacto ambiental abarca los cambios positivos o negativos que una actividad genera en el medio ambiente. El impacto social considera las actividades que afectan la calidad de vida, el bienestar, la equidad y las condiciones de desarrollo de la población. En cuanto al impacto económico, se refiere a los efectos financieros derivados de las actividades, que incluyen los recursos utilizados, los costos y los beneficios.

El crecimiento urbano es proporcional al consumismo, lo que se refleja en la producción de RSU. A nivel mundial se pronostica un aumento considerable en la generación de RSU, estimándose un crecimiento superior al 60% hacia 2050.

©2026 SMIA | ISSN 2007-069

La integración de soluciones digitales como el registro, clasificación, predicción y optimización de rutas bajo el concepto de ciudad inteligente permite combinar la innovación tecnológica, como la Inteligencia Artificial (IA), con un enfoque comunitario para fomentar la sostenibilidad [4].

La transformación digital del sector de RSU es esencial para la dinámica de la economía circular y la sostenibilidad, mediante el uso de tecnologías innovadoras como la IA [2]. Análisis recientes muestran que la IA aplicada a la logística de residuos ha dado resultados positivos, por ejemplo, reducir distancias de transporte hasta en un 36.8%, costos en 13.35%, tiempos en un 28.22% y sistemas de clasificación con precisiones desde un 72.8% al 99.95%[5].

Este trabajo explora el papel de la IA y las Ciudades Inteligentes en la gestión de RSU. Mediante un análisis de caso, comparamos herramientas de aprendizaje automático para identificar el modelo más eficiente y lograr predicciones precisas y libres de sesgos.

Pero ¿qué es la Inteligencia Artificial? es una tecnología que simula el proceso del aprendizaje humano mediante algoritmos o programas, herramienta poderosa que nos ayuda a la toma de decisiones, aprende a través de la experiencia y reconoce patrones de miles de datos en corto tiempo a diferencia de un humano que necesitaría años para lograrlo. Las tecnologías inteligentes nos ayudan a analizar grandes cantidades de datos, automatizar tareas repetitivas y optimizar los sistemas de gestión de residuos para una máxima eficiencia.

Las ciudades inteligentes utilizan tecnologías aplicables en cada fase de la gestión de RSU desde su generación, predicción, selección y clasificación, la recolección, tratamiento, disposición final (eliminación de residuos) y monitoreo.

Este artículo muestra a la IA como una alternativa para transformar la gestión de RSU que ayude a optimizar los recursos. Aunado a esto, se presenta un caso para la obtención de un modelo con alta precisión para la predicción de la generación de 12 tipos de residuos [6].

La inteligencia artificial para el manejo inteligente del problema de los RSU

Las tecnologías digitales han avanzado significativamente, entre ellas surge la IA revolucionando a varios sectores, como la gestión de RSU, que convierte procesos manuales y procesos logísticos complejos a un sistema automatizado, eficiente y sostenible. Entre los avances más recientes están las ciudades inteligentes, ver Figura 1.

Donde la IA actúa como el cerebro de las ciudades, utilizando análisis de datos, visión por computadora y robótica.

La IA transforma los RSU en información, la información en gestión inteligente para construir ciudades inteligentes

En esta sección se describe el paso a paso del sistema de gestión sostenible con enfoque en la dinámica de la economía circular. Se recorre cada fase para una gestión eficiente: la predicción, clasificación, recolección, tratamiento o reciclaje, disposición final y monitoreo inteligente.

Predicción de la generación de residuos

Para predecir la generación de residuos y optimizar la infraestructura urbana, es fundamental integrar tendencias históricas, factores climáticos y densidad poblacional; no obstante, dado que muchos datos oficiales en México provienen de registros manuales, es crítico realizar un procesamiento riguroso para eliminar errores y evitar sesgos sistemáticos que comprometan el análisis. Ante este reto, la transición hacia tecnologías innovadoras, como sensores y dispositivos IoT con inteligencia artificial, ofrece una alternativa precisa y automatizada para asegurar la integridad de la información en las ciudades inteligentes. Existen modelos de aprendizaje automático que aprenden de datos históricos, capaces de seguir patrones y predecir la cantidad de residuos que se producirán en un futuro,

AÑO 18, NO. 3 | SEP-DIC| 2026 | KOMPUTER SAPIENS

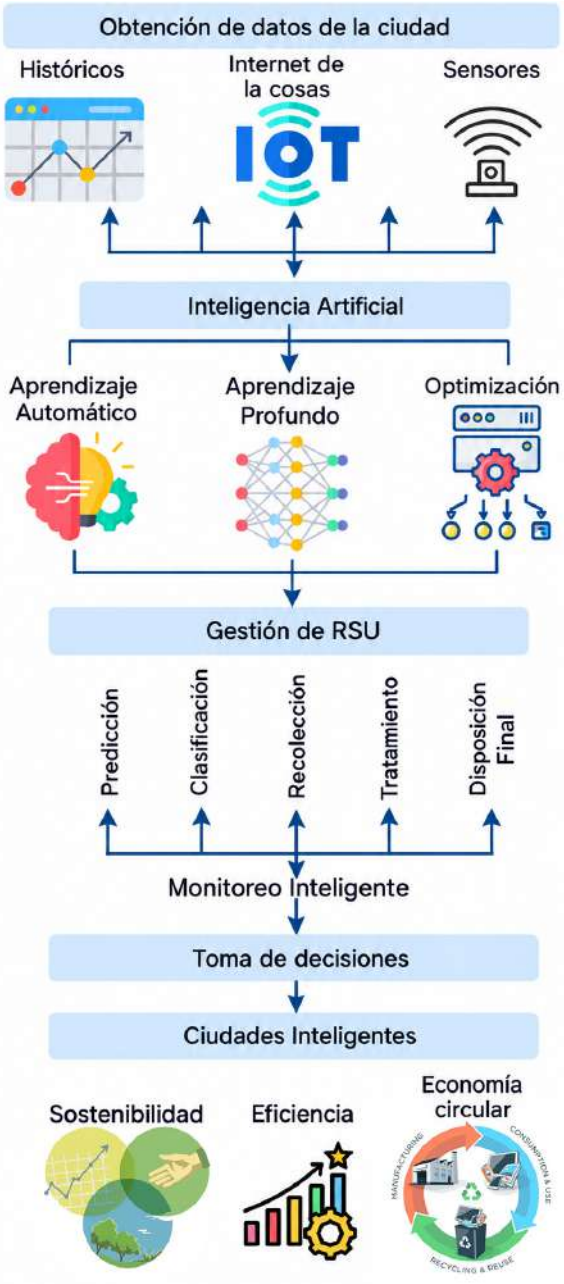


Figura 1. *Esquema de la aplicación de la IA en la gestión de RSU y ciudad inteligente.*

para poder planificar los servicios urbanos y optimizar la asignación de recursos [5].

Clasificación y separación

En Latinoamérica y el Caribe un problema latente es la contaminación del material recolectado por la mezcla de los residuos; en esta fase la separación correcta de los RSU es clave para el reciclaje, la IA funciona como la visión y neuronas del sistema humano. Se han utilizado modelos de Aprendizaje profundo como Redes Neuronales Convolucionales (Convolutional Neural Networks, CNN), Redes Neuronales Convolucionales Profundas (Deep Convolutional Neural Networks, DCNN), modelo de detección de objetos en tiempo real (You Only Look Once, YOLO), red neuronal convolucional ligera (Mobile Network, MobileNet), y la red neuronal residual (Residual Network, ResNet). Este último es una arquitectura de red neuronal convolucional basada en conexiones residuales que funciona con cámaras que capturan imágenes de residuos, y los modelos de detección de objetos reconocen el tipo de material y los separan. Los sistemas de aprendizaje profundo han logrado realizar la clasificación automatizada con alta precisión, mejorando la eficiencia del reciclaje [7].

Recolección inteligente y optimización de rutas

Se estima que en los gobiernos municipales de Latinoamérica y el Caribe el 50% del presupuesto se ejecuta por estrategias inadecuadas de recolección y por tener rutas subóptimas. Los sensores IoT en los contenedores monitorean el nivel de llenado en tiempo real, mientras que con la IA se analizan los datos para crear rutas de recolección dinámicas para que los automóviles recolectores solo pasen justo en el momento necesario. Se han utilizado Algoritmos Genéticos (Genetic Algorithms, GA), Optimización por Colonia de Hormigas (Ant Colony Optimization, ACO), Problema de Ruteo de Vehículos (Vehicle Routing Problem, VRP), entre otros. Estos funcionan mediante la simulación de múltiples rutas y eligen la más eficiente. Con la optimización de rutas se reducen tiempos de viaje, consumo de combustible, costos y contaminación por emisiones [8]

Residuos no tratados ni valorizados

Ante la saturación de los rellenos sanitarios, la valorización de residuos es urgente. La inteligencia artificial, mediante modelos de aprendizaje automático y redes neuronales, analiza procesos de procesamiento y combustión para optimizar la eficiencia energética, permitiendo transformar desechos en energía o nuevos productos con una precisión técnica superior en procesos como la pirólisis [5].

©2026 SMIA | ISSN 2007-069

Disposición final de los RSU

En la disposición final, modelos de aprendizaje automático como máquinas de vectores de soporte (Support Vector Machine, SVM), Bosque Aleatorio (Random Forest, RF), Bayes ingenuo (Naïve Bayes, NB) y Redes Neuronales Artificiales (Artificial Neural Networks, ANNs) han sido adoptados para diversas tareas de predicción y clasificación. Estos algoritmos admiten una predicción de las tasas de generación de residuos, la distribución espacial de los tipos de residuos y los potenciales de emisión derivados de procesos de vertedero o incineración[9]. Mediante el análisis de imágenes de drones o cámaras, la IA puede identificar vertederos ilegales o acumulación de basura en tiempo real, permitiendo a las autoridades locales intervenir rápidamente.

Monitoreo en la ciudad

El monitoreo de las fases para la gestión de los RSU representa el sistema nervioso de la ciudad mediante el uso de tecnologías: sensores que envían información para el análisis de datos, robots que realizan procesos de visualización, separación y clasificación para mejorar la gestión integral de los RSU [10].

Metodología: el camino hacia la predicción inteligente

Para transformar una ciudad en un entorno inteligente, es fundamental la predicción precisa y sin sesgos. Para determinar qué herramienta de IA optimiza mejor la predicción de residuos, diseñamos un experimento de aprendizaje automático supervisado. Nuestra metodología parte desde la adquisición y el tratamiento de datos hasta una 'competencia' entre diversos modelos predictivos, culminando en un riguroso proceso de validación y evaluación. El flujo de esta investigación, desde la entrada de datos hasta la selección del modelo más preciso y con menor sesgo, se sintetiza en la Figura 2 donde se muestra la estructura de la investigación.

Caso de estudio: la competencia de los algoritmos en la gestión de los residuos

La clave para una ciudad inteligente es la predicción. Si queremos optimizar rutas y ahorrar recursos, primero debemos saber qué se generará. Pero, ¿qué tecnología es la más precisa?



Figura 2. *Metodología que abarca desde la obtención de datos hasta la selección del modelo predictivo óptimo para la gestión de RSU.*

Adquisición y limpieza de datos

Toda IA es tan buena como los datos que la alimentan. En la primera fase se reunió el conjunto de registros organizados en formato CSV. Obtenidos de los registros oficiales del Diagnóstico Básico y programa para la prevención, manejo integral y economía circular de residuos en el estado de Tlaxcala. 2025-2027, que consiste en datos semanales de acuerdo a la categorización [6].

La Tabla 1 muestra los tipos de residuos, estos representan las variables independientes que afectan directamente a la producción total. Se realizó un riguroso proceso de limpieza y validación de la información. Analizando las variables de entrada para verificar la ausencia de valores o registros erróneos, que podrían malinterpretarse como datos faltantes y garantizar la integridad del conjunto de datos, antes de someterlo al análisis estadístico.

Modelos predictivos sin sesgo para la gestión inteligente de residuos sólidos urbanos en ciudades inteligentes

La Figura 3 muestra la distribución histórica de los residuos generados entre 2010 y 2024. El histograma indica que la generación de residuos no es un evento aleatorio, sino

No.	Tipo de residuo	¿Qué incluye?
1	Orgánico	Comida, frutas, verduras
2	Papel y cartón	Cartón, papel, envolturas
3	Plástico	Bolsas, botellas, envases
4	Sanitarios	Tampones, pañales, papel higiénico
5	Textiles	Ropa, telas viejas
6	Otros	Residuos inertes
7	Metales	Latas, hierro, aluminio
8	Madera	Tablones, madera descartada
9	Vidrio	Botellas, vidrio quebrado
10	Construcción	Materiales de obra
11	Peligrosos	Baterías, químicos
12	Electrónicos	Celulares, computadoras

Tabla 1. *La categorización de los residuos generados.*

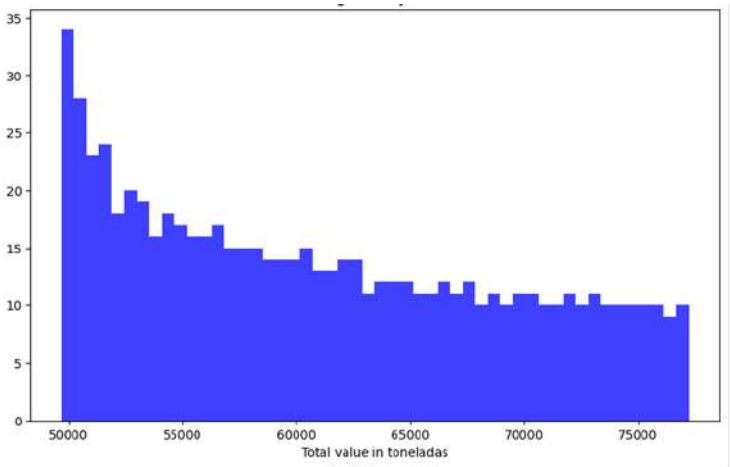


Figura 3. *El pulso de la ciudad: distribución semanal de residuos.*

que posee una estructura y una tendencia que la IA puede aprender a identificar.

La gráfica revela la alta variabilidad en la recolección semanal de residuos marcada por picos de consumo, eventos estacionales y cambios en los hábitos ciudadanos, un fenómeno complejo para la gestión humana. Para los algoritmos, este registro actúa como un libro de aprendizaje que permite identificar patrones ocultos y construir un modelo capaz de anticipar con precisión los volúmenes de residuos que se transportarán a los centros de acopio la semana siguiente.

La Figura 4 revela el ADN de los residuos y muestra la interacción de distintos materiales. Las conexiones entre ellos confirman una fuerte multicolinealidad, lo cual, lejos de ser un obstáculo, valida nuestra elección; al tratarse de un sistema con una lógica lineal y predecible fue posible prescindir de costosas cajas negras computacionales y optar por modelos matemáticos eficientes que explican el fenómeno con mayor precisión.

La competencia: diseño experimental

Ahora bien, ¿cómo sabemos qué algoritmo es el más confiable? Se dividió el conjunto de datos semanales de recolección de basura en dos bloques, un 60% fue destinado al entrenamiento, permitiendo que cada modelo aprendiera a reconocer los patrones de generación de residuos. El 40% restante se reservó como un conjunto de prueba totalmente nuevo. Se eligieron cuatro algoritmos diferentes para observar cómo reaccionan ante la estructura lineal de los datos. Regresión Lineal Múltiple (Multiple Linear Regression, MLR), el estándar básico de la estadística enfocado en relaciones proporcionales. Regresión polinomial de segundo grado (Polynomial Regression, PR), un modelo que permite capturar curvas de comportamiento. Regresión por Vectores de Soporte (Support Vector Regression, SVR), un método avanzado que mapea datos en espacios no lineales. Extreme Gradient Boosting (XGBoost), un potente algoritmo de aprendizaje supervisado de última generación, basado en árboles de decisión optimizados.

La validación: el filtro de la ciudad

Para asegurar que los modelos aprendan la lógica del problema y no simplemente memoricen los datos (evitando el sobreajuste), aplicamos la validación cruzada. Este proceso divide los datos en bloques, entrenando y poniendo a prueba los algoritmos de forma rotativa en cada uno de ellos. Al asegurar que cada dato sea utilizado tanto para el

aprendizaje como para la evaluación, garantizamos que el rendimiento de nuestros modelos sea robusto, consistente y, sobre todo, capaz de operar con precisión en la gestión operativa de una ciudad real.

La salida: veredicto predictivo

Tras analizar las 12 categorías de residuos, los resultados rompen con el mito de que mientras más complejo es siempre mejor, ver Tabla 1. Evaluamos la eficacia de los modelos mediante tres métricas clave: el Error Absoluto Medio (Mean Absolute Error, MAE), que mide el margen de error promedio en la misma unidad que los residuos (toneladas); la Raíz del Error Cuadrático Medio (Root Mean Square Error , RMSE), que penaliza más severamente las desviaciones grandes para identificar errores críticos; y el Coeficiente de Determinación (Coeficiente de Determinación , R^2), que indica qué tan bien explica el modelo el comportamiento real de los datos, donde un valor cercano a 1 representa una predicción de alta confiabilidad.

Modelos complejos como el SVR fallaron al intentar sobreinterpretar los datos, mientras que la elegancia matemática de un modelo simple logró una precisión casi perfecta.

¿Qué significa esto para la ciudad?
Este hallazgo es una herramienta estratégica. Al no requerir supercomputadoras, los modelos pueden ejecutarse en servidores municipales básicos para una gestión en tiempo real. Esto permite a los gobiernos pasar de una operación reactiva a una gestión proactiva, planificar rutas de recolección con un margen de error casi nulo, optimizar el uso de combustible y preparar la logística de reciclaje con absoluta anticipación.

Conclusión

Este estudio demuestra que la gestión ambiental inteligente no necesariamente requiere de complejas cajas negras. A veces, la solución reside en integrar la inteligencia artificial con el conocimiento profundo de nuestra realidad local, logrando herramientas accesibles y sostenibles para cualquier municipio.

¿Significa esto que debemos descartar la IA avanzada? No. Futuras investigaciones podrán explorar modelos temporales, como transformers o redes neuronales recurrentes, para identificar dependencias ocultas y variables macroeconómicas que complejicen nuestro análisis. Sin embargo, nuestro hallazgo principal es claro: el éxito en la ciencia de datos no reside en utilizar el algoritmo más sofisticado, sino en aquel que mejor comprende la lógica del problema. La Regresión Polinómica de segundo orden ha demostrado que, con la herramienta correcta, la eficiencia urbana está al alcance de la mano. KS

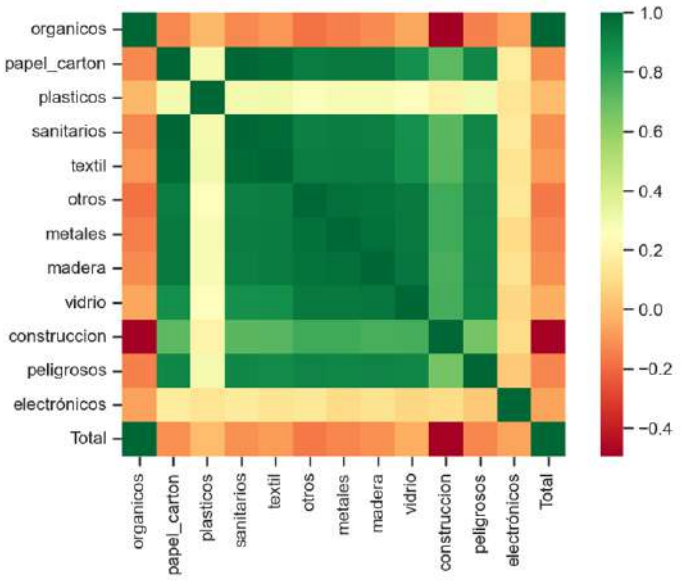


Figura 4. *El ADN de la ciudad: patrones de generación de residuos.*

Modelo	Precisión	Complejidad
PR	**Excelente(óptimo)**	**Baja**
MLR	Muy alta	Muy baja
XGBoost	Muy alta	Alta
SVR	Baja	Muy Alta

Tabla 2. *Resultados, cuando la simplicidad supera a la complejidad.*

Referencias

1. UNEP (2024) "El mundo debe superar la era de los desechos y convertirlos en recursos: Informe de la ONU". Disponible en: https://www.unep.org/es/noticias-y-reportajes/comunicado-de-prensa/el-mundo-debe-superar-la-era-de-los-desechos-y Recuperado el 30 de marzo de 2026.
2. Hub de Residuos Sólidos y Economía Circular (2026) "Hub de Residuos Sólidos y Economía Circular". Disponible en: https://hubresiduoscirculares.org/homeRecuperado el 30 de marzo de 2026.
3. Gobierno de México (2020) "Diagnóstico Básico para la Gestión Integral de los Residuos". Disponible en: https://www.gob.mx/cms/uploads/attachment/file/1078946/Diagn_stico_B_sico_Gesti_n_Integral_Residuos.pdf Recuperado el 30 de marzo de 2026.
4. Szpilko D., de la Torre Gallegos A., Jiménez Naharro F., et al. (2023) "Waste Management in the Smart City: Current Practices and Future Directions". Resources. Vol. 12, No. 10, p. 115 https://doi.org/10.3390/resources12100115
5. Fang, B., Yu, J., Chen, Z. et al (2023) "Artificial intelligence for waste management in smart cities: a review". Environmental Chemistry Letters. Vol. 21, No. 4, pp. 1959–1989. https://doi.org/10.1007/s10311-023-01604-3
6. Gobierno del Estado de Tlaxcala (2025) "Diagnóstico básico y programa para la prevención, gestión integral y economía circular de los residuos del estado de Tlaxcala 2025–2027". Disponible en: https://publicaciones.tlaxcala.gob.mx/indices/Ex02122025.pdfhttps://publicaciones.tlaxcala.gob.mx/indices/Ex02122025.pdf
7. Nafiz, M. S., Das, S. S., Morol, M. K., Juabir, A. A., & Nandi, D. (2023). ConvoWaste: An Automatic Waste Segregation Machine Using Deep Learning. En 2023 3rd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST) (pp. 181–186). Recuperado de https://doi.org/10.48550/arXiv.2302.0297
8. Alshaikh, R., & Abdelfatah, A. (2024)."Optimization Techniques in Municipal Solid Waste Management: A Systematic Review". Sustainability, Vol. 16, No. 15, p. 6585. https://doi.org/10.3390/su16156585
9. Priyanka E. B., et al. (2025) "Prediction of waste generation forecast and emission potential on the Erode City solid waste dump yards based on machine learning approach". Scientific Reports, Vol. 15, No. 1, p. 37021. https://doi.org/10.1038/s41598-025-19288-w
10. Bari, A., Arshi, O. & Mondal, S. (2026) "Advancements in waste management: a comprehensive review of Artificial Intelligence applications in smart cities". Smart Construction and Sustainable Cities, Vol. 4, No. 1, p. 7. https://doi.org/10.1007/s44268-026-00088-8

Sobre los autores



Araceli Hernández Cruz, es estudiante de doctorado en el Departamento de Estudios de Posgrado e Investigación en el Tecnológico Nacional de México/ Instituto Tecnológico de Apizaco. Actualmente, trabaja en el Tecnológico Nacional de México/Instituto Tecnológico Superior de San Martín Texmelucan. Obtuvo el título de Ingeniera Industrial por el Instituto Tecnológico de Apizaco, Apizaco, Tlaxcala, México, en 2000. Obtuvo su grado de maestría en Ingeniería Administrativa en Instituto Tecnológico de Apizaco en 2017. Sus principales áreas de investigación incluyen: Sistemas de gestión, Optimización de procesos, Ciencia de Datos e Inteligencia Artificial



Jorge Luis Castañeda Gutiérrez, Obtuvo el título de ingeniero Mecánico por el Instituto Tecnológico de Orizaba, Orizaba, Veracruz México, en 1992. El grado de Maestro en Ciencias de Calidad, por la Universidad Autónoma de Tlaxcala, Tlaxcala, México, en 2002; Y el grado de Doctorado en Logística y Dirección de la Cadena de Suministro, por la Universidad Popular Autónoma del Estado de Puebla, Puebla, Puebla, México, 2013. Sus principales áreas de investigación incluyen: metaheurísticas aplicada a sistemas logísticos, optimización de procesos, lean System, entre otros.



José Crispín Hernández Hernández, Obtuvo el título de Licenciado en Informática por el Instituto Tecnológico de Apizaco, Apizaco, Tlaxcala, México, en 1993. El grado de Maestro en Ciencias, en Ciencias Computacionales por el Instituto Tecnológico de Apizaco, Apizaco, Tlaxcala, México, en 1998. Y el grado de Doctorado en Ciencias de la Computación por la Université d'Angers. Campus Belle Beile, Francia en 2008. Sus principales áreas de investigación incluyen: metaheurísticas, optimización, bioinformática, biomedicina, lógica difusa, visión por computadora. aprendizaje máquina, minería de datos

ARTÍCULO

El Espíritu Algorítmico: Ética y Empatía como base en la creación de aplicaciones de IA

José Roberto Ramírez Guerrero

Introducción

El principio de todo desarrollo de aplicaciones parte de un análisis, una lógica y la aplicación de técnicas de resolución de problemas. Lo que no suele contemplarse, o al menos no se menciona con frecuencia en la literatura, es aplicar las habilidades blandas como pilares de creación de cualquier software, en especial aquellos que integran Inteligencia Artificial (IA). Este artículo explora la ética y la empatía como ejes centrales en el diseño de proyectos de IA, así como la relación entre estos valores, argumentando que quienes crean estas herramientas tienen una responsabilidad única y enorme: la de influenciar, con cada decisión de diseño, la vida de millones de personas.

La evolución tecnológica de los últimos cinco lustros ha definido la base de conocimiento necesario para el progreso que hoy alcanza la IA. Desde el lanzamiento público de ChatGPT el 30 de noviembre de 2022 —presentado por OpenAI como una versión de investigación abierta al público [1]— el acceso a herramientas de IA dejó de ser exclusivo de laboratorios para convertirse en un fenómeno global. La historia del desarrollo de software es, sin embargo, mucho más antigua: en 1843, Ada Lovelace describió en la "Nota G" un algoritmo para calcular números de Bernoulli, considerado el primer programa de computadora publicado [2]. Esa idea de automatizar procesos nos coloca hoy, 183 años después, frente a herramientas capaces de asistir desde la escritura hasta la generación de código complejo.

Cuando desarrollamos una aplicación a la medida, creamos un software que resuelve un problema concreto. Para dimensionar el alcance de esta industria, en 2023 se descargaron alrededor de 257 mil millones de aplicaciones en plataformas móviles [3]; se espera que esta cifra siga creciendo. Si bien disciplinas como la interacción humano-computadora (HCI), el diseño centrado en el usuario y la accesibilidad han explorado desde hace décadas la relación entre sistemas y necesidades humanas, la irrupción de la IA generativa amplía ese desafío a una escala sin precedentes, haciendo más urgente que nunca incorporar la ética y la empatía como dimensiones centrales del proceso de desarrollo.

©2026 SMIA | ISSN 2007-069

AÑO 18, NO. 3 | SEP-DIC| 2026 | KOMPUTER SAPIENS

El Conflicto Ético

La sociedad mundial vive un momento histórico. Estamos más informados que ninguna generación anterior y contamos con acceso a tecnologías que, en teoría, facilitan nuestra vida cotidiana. Sin embargo, la libertad de acceso a ese cúmulo de contenido digital trae consigo un conflicto particular: el uso y la aplicación que se le está dando. Con la masificación de internet y el auge de las redes sociales surgió el fenómeno de las noticias falsas, cuya propagación masiva genera consecuencias reales en la cohesión social y en los procesos democráticos.

Como sociedad, debemos establecer reglas claras, oportunas y equitativas para el uso de la tecnología. Este tipo de tensión puede entenderse como un dilema ético: el conflicto que una persona experimenta entre dos o más obligaciones morales en una circunstancia particular [4]. Aplicado al desarrollo de software, el dilema ético surge cuando un programador o una empresa debe decidir entre optimizar una métrica de negocio o proteger el bienestar del usuario; entre la apertura total de un sistema o su regulación responsable.

Si bien la ética y la empatía son habilidades blandas distintas una puede existir sin la otra, lo que este artículo propone es que todo desarrollador de software debe cultivar y aplicar ambas de manera simultánea

La ética no es un obstáculo para la innovación tecnológica; es, al contrario, el marco que le da sostenibilidad. Un sistema de IA diseñado sin principios éticos puede magnificar sesgos, discriminar poblaciones vulnerables o ser utilizado para fines que atenten contra la dignidad humana. Por ello, la ética debe ser considerada desde la primera línea de código, no como un requisito de cumplimiento posterior, sino como una decisión arquitectónica fundamental en todo proyecto de IA.

La Empatía en el Desarrollo de Software

La empatía tiene sus raíces conceptuales en la filosofía alemana del siglo XIX. Fue la filósofa e investigadora Edith Stein quien propuso las bases de este concepto, cuyo principio fundamental es entender o comprender lo que le sucede a otra persona como si nos estuviera pasando a nosotros mismos. Hoy la empatía es reconocida como un valor central entre las habilidades blandas que todo profesionista debe desarrollar.

En el ámbito del desarrollo de software, el conflicto más común que enfrenta cualquier desarrollador es pensar la aplicación desde su propia perspectiva, y no desde la del usuario final. De ahí que la empatía se vuelva fundamental: es esa capacidad cognitivo-afectiva que experimenta una persona al ponerse en la situación de otra, percibiendo sus pensamientos y emociones a partir del reconocimiento del otro como similar [5].

Trasladada al diseño de sistemas de IA, la empatía se convierte en un principio de diseño: ¿Cómo interactuará este usuario con el sistema? ¿Qué frustraciones podría experimentar? ¿Qué nivel de confianza necesita generar la interfaz? No se trata únicamente de resolver problemas técnicos, sino de entender lo que el usuario necesita y establecer un vínculo apropiado que le genere confianza para aceptar las respuestas del sistema, adaptadas a su nivel de comprensión.

En este sentido, las universidades y centros de formación deben superar uno de los grandes retos actuales: integrar el desarrollo de habilidades socioemocionales en la formación de ingenieros [6]. Empatizar presupone sentir lo que siente la otra persona, no solo emocionalmente sino de forma cognitiva para, al mismo tiempo, poder llegar a comprendernos mejor a nosotros mismos. En este proceso intervienen factores culturales, sociales, interpersonales e incluso estructuras del yo más profundas e impredecibles [7].

La Comunión entre Ética y Empatía

Si bien la ética y la empatía son habilidades blandas distintas una puede existir sin la otra, lo que este artículo propone es que todo desarrollador de software debe cultivar

©2026 SMIA | ISSN 2007-069

y aplicar *ambas* de manera simultánea. No se trata de que sean equivalentes, sino de que se complementan: la empatía orienta el diseño hacia las necesidades reales del usuario, mientras que la ética establece los límites que impiden que ese mismo diseño sea utilizado para perjudicarlo. Un sistema puede ser empático —adaptarse al lenguaje y contexto del usuario— y al mismo tiempo carecer de ética si, por ejemplo, esa adaptación se usa para manipular decisiones o extraer datos sin consentimiento. La dirección inversa también es posible: un sistema puede ser éticamente correcto en su regulación, pero frío e inaccesible en su interfaz.

Es por eso que la propuesta del *espíritu algorítmico* no descansa en una sola de estas dimensiones: implica que ambas interactúen de forma implícita en cada decisión de diseño, desde la arquitectura del sistema hasta la redacción de un mensaje de error. Cuando un desarrollador incorpora esta dualidad como parte de su forma de pensar y de crear, cualquier aplicación que produzca llevará, de manera natural, la huella de esa consciencia.

El Programador como Agente Ético

El programador es un creador de aplicaciones. Independientemente de la plataforma o arquitectura de trabajo, su función y desempeño dependen del diseño y la estructura que le dé al proyecto. Todo proyecto parte de un análisis que determina los requerimientos, las necesidades y los elementos fundamentales que debe cubrir una aplicación. Un desarrollador orientado a crear software con Inteligencia Artificial debe utilizar la empatía como ese *espíritu algorítmico*: esa forma de pensar y sentir transmitida a todos los escenarios —su vida personal, el ambiente de trabajo, y en última instancia, a cada línea de código que escribe.

Lo que las empresas, instituciones educativas, organismos gubernamentales y la industria del software deben promover, en todo desarrollo de aplicaciones de IA, es la combinación correcta de habilidades duras —lógica, análisis, razonamiento, matemáticas— con el manejo consciente de la empatía y la ética. Estas últimas no son ornamentales; son habilitadoras de calidad y de impacto real.

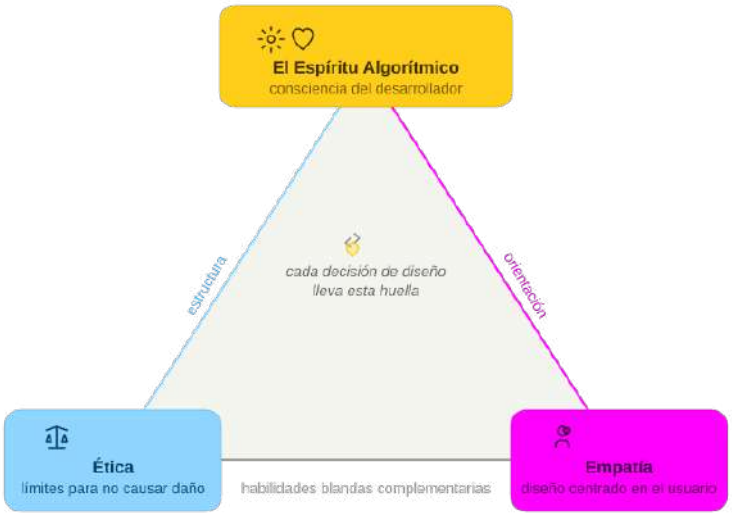


Figura 1. *El espíritu algorítmico emerge de la aplicación simultánea de ética y empatía en el desarrollo de software con IA.*

Cuando la empatía y la ética se incorporan de manera consciente en el desarrollo de nuevas tecnologías, la experiencia del diseño centrado en el usuario —documentada en disciplinas como HCI y UX— sugiere que pueden favorecer resultados como los siguientes:

1. **Mejor adaptación al cambio:** facilitan a los usuarios una adopción más fluida de nuevas tecnologías, promoviendo una inclusión apegada a la realidad de cada persona.
2. **Curvas de aprendizaje más cortas:** al adaptar las respuestas del sistema al lenguaje y conocimiento de cada usuario, la IA puede actuar como un tutor paciente que reduzca los tiempos de apropiación de una nueva tecnología.
3. **Mayor productividad:** favorecen tiempos de respuesta más eficientes en las tareas, posicionando a la IA como un copiloto que potencia las capacidades humanas en lugar de reemplazarlas.
4. **Contenidos más accesibles:** orientan la generación de materiales considerando la accesibilidad necesaria para cada usuario, de forma personalizada.
5. **Personalización con propósito:** permiten aprovechar el potencial de habilidades individuales, reconociendo



Figura 2. *Beneficios de incorporar ética y empatía en el desarrollo de software con IA.*

que cada usuario tiene necesidades, contextos y capacidades únicas.

Cabe señalar que en la actualidad ya es posible encontrar en algunos planes de estudio el desarrollo de estas habilidades blandas. Sin embargo, será importante que en los próximos años se diseñen estrategias e instrumentos que permitan medir el desarrollo de la empatía y la ética en los futuros desarrolladores de software, de forma que estos beneficios puedan documentarse con mayor rigor.

Los emojis, las respuestas contextuales y los asistentes inteligentes son evidencia de que la computación ha cruzado una frontera: ya no solo procesa datos, sino que interactúa con personas.

Asertividad Tecnológica

La democratización de las tecnologías de IA plantea un riesgo que frecuentemente se soslaya: la erosión de la asertividad social en su uso. Esto no equivale a tachar la evolución tecnológica como algo dañino; significa reconocer que no todos los desarrollos pueden ni deben estar abiertos a todo público sin ningún tipo de mediación responsable. El tamaño del mercado global de Inteligencia Artificial se estimó en 390,910 millones de dólares en 2025 y se proyecta que alcance los 3,497,260 millones de dólares en 2033 [8]. Esta escala de crecimiento implica que las decisiones de diseño de hoy tendrán consecuencias masivas mañana.

La asertividad tecnológica puede entenderse como la capacidad de una sociedad para relacionarse con la tecnología de forma informada, crítica y deliberada: saber cuándo utilizarla, con qué propósito y bajo qué condiciones. Para lograrla, no basta con que los sistemas sean técnicamente funcionales; deben ser diseñados para empoderar al usuario, no para generar dependencia o explotación de sus datos y atención.

Las entidades que desarrollan sistemas de IA deben, por tanto, explorar modelos de uso más regulados y responsables, donde la barrera de acceso no sea el nivel técnico de programación, sino la comprensión ética y empática del impacto de la herramienta. Esto implica transparencia en los algoritmos, mecanismos de retroalimentación accesibles para el usuario no especializado, y una cultura organizacional que ponga el bienestar del usuario al centro de cada decisión de producto. La asertividad tecnológica, en suma, se construye desde el código, pero se consolida en la conciencia de quienes lo escriben.

Conclusión

Desde su concepción, las carreras de Sistemas Computacionales e Informática han sido diseñadas para quienes poseen habilidades duras: dominio del análisis, la lógica, las matemáticas y la resolución de problemas. Este enfoque funcionó durante décadas porque los sistemas creados, en su mayoría, eran herramientas específicas, precisas y transaccionales, cuyo principal objetivo era resolver y organizar problemas de información. Con la lle-

gada de las interfaces conversacionales y, más recientemente, de la IA generativa, los sistemas comenzaron a requerir dimensiones más humanas. Los emojis, las respuestas contextuales y los asistentes inteligentes son evidencia de que la computación ha cruzado una frontera: ya no solo procesa datos, sino que interactúa con personas.

Con las inteligencias artificiales como entidades de pensamiento fue necesario integrar la ética —para establecer restricciones que impidan usos dañinos para la sociedad— y la empatía —para que las IA traten a las personas no como usuarios genéricos, sino como individuos con contextos, emociones y necesidades propias. Una IA empática construye confianza a lo largo de una conversación, adapta sus respuestas progresivamente y hace más efectiva cada interacción.

El llamado es claro: no solo enseñemos programación en las aulas; enseñemos también a respetar al usuario. El espíritu algorítmico de la próxima generación de desarrolladores debe estar impregnado tanto de lógica computacional como de conscien-cia humana. Solo así la IA será, en verdad, inteligente. KS

REFERENCIAS

1. OpenAI (2022). *Introducing ChatGPT*. OpenAI Blog. Disponible en: https://openai.com/index/chatgpt. Consultado en abril de 2026.
2. Burton B. A. (2023) "Charles Babbage, Ada Lovelace, and the Bernoulli Numbers". *arXiv*:2301.02919.
3. Statista (2024). *Number of mobile app downloads worldwide 2023*. Disponible en: https://www.statista.com/topics/1729/app-stores/. Consultado en abril de 2026.
4. Calva J. M. L., De la Cruz M. D. C. y González M. L. G. (2017) "Dilemas éticos en la investigación científica desde la mirada de investigadores nacionales de una universidad privada en México". *Práxis Sociológica*, 22, 49–64.
5. Castillo P. (2022) "Máquinas afectivas: la empatía artificial en las interfaces vestibles". *Invasión Generativa*.
6. Duque N. (2023) "Percepción de empatía en la interacción con interfaces de usuario conversacionales". En Chirinos Y., Rojas D. y Barbera R. (Eds.), *Retos socioeconómicos de la actualidad en el contexto global*. Fondo Editorial Servando Garcés. DOI: https://doi.org/10.47212/retosocioeconomicoactual2023
7. Martínez A. C. y del Pino Romero C. (2019) *De la publicidad a la comunicación persuasiva integrada: estrategia y empatía*. Esic Editorial.
8. Grand View Research (2025). *Artificial Intelligence Market Size, Share & Trends Analysis Report (2026–2033)*. Disponible en: https://www.grandviewresearch.com/industry-analysis/artificial-intelligence-aimarket. Consultado en abril de 2026.

DECLARACIÓN DE IA GENERATIVA

Durante la preparación de este trabajo, el autor utilizó Perplexity para la revisión de referencias y consultas, así como Claude para la revisión de redacción y contenido. Después de utilizar estas herramientas, el autor revisó y editó el contenido según fue necesario y asume plena responsabilidad de lo publicado.

Sobre el autor



José Roberto Ramírez Guerrero es Profesor de Tiempo Completo en el Instituto Tecnológico Superior de Coatzacoalcos (ITESCO), perteneciente al Tecnológico Nacional de México. Cuenta con Maestría en Ingeniería y Desarrollo de Software y actualmente cursa el Doctorado en Sistemas Computacionales en la Universidad del Sur. Desarrollador de software con más de 34 años de experiencia y docente de materias afines

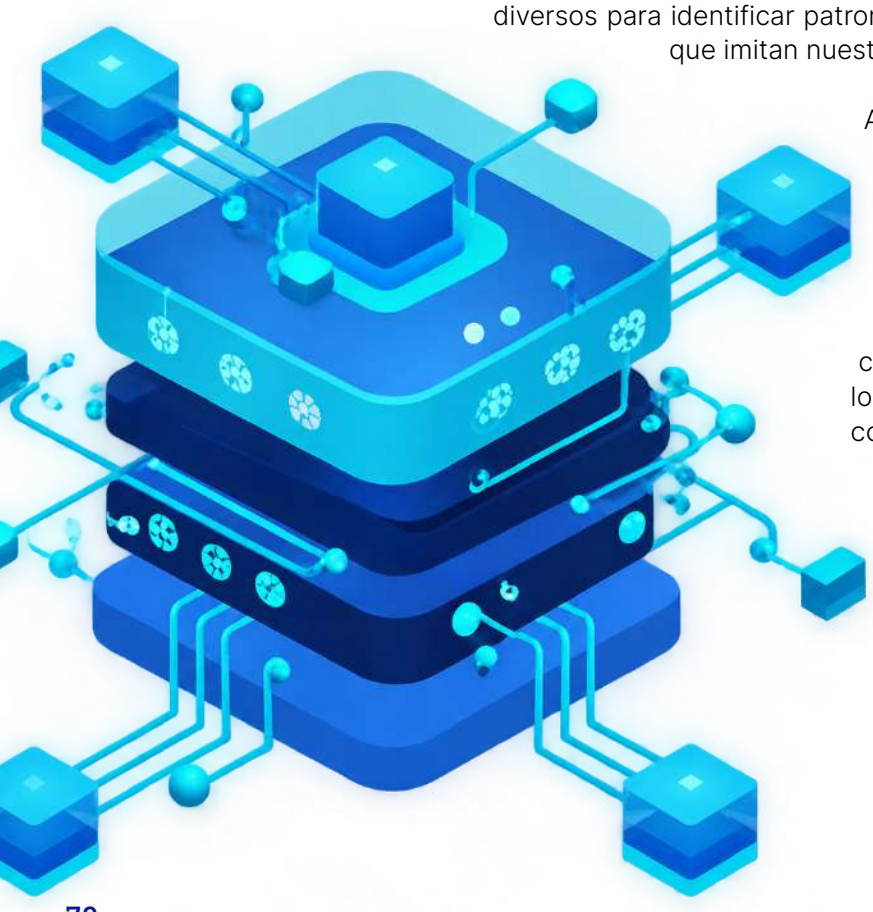
ARTÍCULO

La neutralidad en los LLMs: ¿Una meta inalcanzable?

Nadia María Peralta Nava, David Torres Moreno y Pablo Ricardo Jimenez Cruz

Introducción

Imagina una biblioteca que contiene casi todo lo que la humanidad ha escrito: libros, artículos, páginas web, enciclopedias y mucho más. Ahora, imagina que esa biblioteca tiene la capacidad de hablar contigo, responder todas tus preguntas, darte consejos e incluso escribir cualquier cosa que le pidas. Esa es, en esencia, la promesa de los grandes modelos de lenguaje (Large Language Models, LLM, por sus siglas en inglés) como ChatGPT, Gemini o Claude, que son modelos de Inteligencia Artificial (IA) entrenados con miles de millones textos diversos para identificar patrones en el lenguaje humano y generar respuestas que imitan nuestra manera de expresarnos.



A primera vista parece lógico pensar que, si los LLMs "aprenden" a construir frases a partir del procesamiento de grandes volúmenes de texto mediante algoritmos, sus respuestas deberían ser neutrales. Sin embargo, la realidad es distinta. El aprendizaje de los modelos va más allá de la mera adquisición de estructuras gramaticales para la construcción de frases. Estos modelos capturan la complejidad de nuestra expresión, conocimiento y experiencia, incluyendo aquellas imperfecciones como desigualdades, estereotipos y prejuicios.

En este artículo analizamos por qué la neutralidad es inalcanzable para los LLMs cuando hablamos de sesgos sociales.

©2026 SMIA | ISSN 2007-069

La ilusión de neutralidad

Durante décadas, la tecnología se presentó como neutral. Desde relojes y termómetros hasta calculadoras, hemos confiado en las máquinas porque parecen limitarse a medir o registrar hechos sin involucrar opiniones. Un termómetro, por ejemplo, indica la temperatura sin importar quién lo use o en qué lugar del mundo se encuentre. Ese modo de funcionar reforzó la creencia de que la tecnología podía verse como neutral.

Con el tiempo, esta idea se trasladó sin cuestionamientos a la era digital. En sus primeras décadas, la computadora se concibió como una gran calculadora, una máquina que ejecutaba con precisión instrucciones humanas. Cuando una hoja de cálculo aplica fórmulas o un procesador de texto corrige ortografía, asumimos que simplemente siguen reglas fijas. De ahí surgió la expresión "la computadora no se equivoca", una creencia cultural que alimentó la ilusión de que la tecnología operaba siempre de manera imparcial.

Bajo esta misma lógica, la confianza también se extendió a los algoritmos computacionales: conjuntos de reglas escritas por programadores para procesar información. Sin embargo, esta concepción debió cambiar con el uso de redes neuronales artificiales. En lugar de limitarse a seguir instrucciones, los modelos de IA empezaron a descubrir patrones y correlaciones al procesar enormes cantidades de textos humanos y, mediante cálculos complejos, generar respuestas.

Y aquí es donde surge una paradoja que pasa inadvertida. Ya que los LLMs no poseen emociones, juicios ni intereses propios, solemos percibirlos como máquinas incapaces de mostrar desviaciones indeseadas en sus respuestas. Pero la investigación reciente ha demostrado que la percepción de neutralidad de los LLMs es inherentemente subjetiva, enfatizando la necesidad de diseñar protocolos de evaluación transparentes y reproducibles, sin depender de impresiones individuales [1].

Para entenderlo, es necesario aclarar qué significan neutralidad y sesgo en este contexto. Los sesgos sociales son patrones de desigualdad, valores culturales o prejuicios que se encuentran en los datos y que los modelos aprenden de forma automática [2]. Bajo esta perspectiva, un modelo sería neutral solo si fuera capaz de producir respuestas libres de estos sesgos sociales.

LLM: el espejo retrovisor que amplifica nuestros sesgos sociales

Y es precisamente esto lo que revela el fondo del problema, no se puede hablar de neutralidad sin reconocer la presencia inevitable de sesgos, porque son ellos los que delimitan lo que un modelo puede considerar neutral. Comprender de dónde surgen y cómo se incorporan estos sesgos es esencial para explicar por qué la neutralidad es un meta que los LLMs nunca podrán alcanzar.

¿Dónde se originan los sesgos de los LLMs?

Los sesgos en los LLMs no son fallas aisladas ni problemas técnicos accidentales. Surgen de manera sistemática a lo largo de su desarrollo, donde cada etapa aporta un tipo distinto de influencia. Más que atribuirlos a "datos de mala calidad", es clave entender que estos modelos no solo aprenden patrones estadísticos, sino también las dinámicas sociales presentes en los textos que procesan. Por eso, la falta de neutralidad no es un accidente, sino una consecuencia de los datos, de su propio diseño y forma de aprendizaje y la interacción humana con estos modelos.

El lenguaje humano es inherentemente variable: permite expresar un mismo significado de distintas maneras según el contexto cultural, histórico y social. Ninguna lengua es neutral. Todas están moldeadas por valores, jerarquías y símbolos compartidos por grupos sociales; cada palabra refleja una perspectiva situada [3].

Al entrenarse con enormes cantidades de texto, los modelos no pueden separar la gramática del trasfondo cultural que la sostiene yreproducen patrones, asociaciones habituales, representaciones históricas, prejuicios normalizados y formas de describir

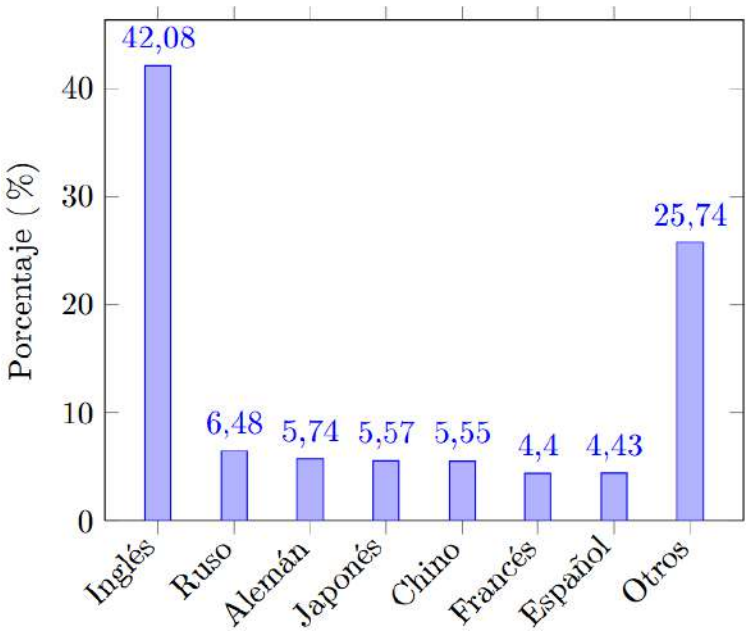


Figura 1. *Idiomas dominantes en Common Crawl (CC-MAIN-2025-47). Common Crawl es un recurso fundamental para el entrenamiento de los LLMs.*

el mundo que han sido transmitidas por comunidades lingüísticas a lo largo del tiempo.

Datos

El desarrollo de modelos de IA contemporáneos requiere cantidades masivas de datos, pero estos datos distan mucho de representar al mundo de forma neutral. La recopilación, selección y etiquetado de información están permeadas por decisiones humanas que introducen sesgos desde el primer momento. Estos procesos no solo consisten en reunir textos o imágenes: implican priorizar ciertos tipos de contenido, excluir otros, limpiar datos según criterios específicos y determinar qué fuentes son "confiables" o "legítimas". En lugar de ver los datos como materia prima neutra, es necesario entenderlos como productos de un contexto histórico específico, con omisiones, sesgos estructurales, prejuicios y desigualdades particulares.

A esto se suma el desequilibrio geográfico y lingüístico en la producción de contenidos: la mayor parte de los textos proviene del Norte Global y está escrita en inglés (ver Figura 1), lo que empuja al modelo hacia un marco epistemológico particular incluso antes de generar una sola respuesta. Esto significa que los datos no solo alimentan al modelo, sino que también limitan qué experiencias reconoce como válidas y cuáles quedan fuera de su universo de conocimiento.

Además, no olvidemos que internet privilegia a las lenguas mayoritarias, a los países con mayor infraestructura tecnológica, a los grupos con acceso constante a plataformas digitales y a los discursos dominantes en instituciones académicas, gubernamentales y mediáticas. El resultado es un corpus (conjunto de datos) que amplifica preferencias culturales específicas, mientras que minimiza o invisibiliza experiencias minoritarias, conocimientos comunitarios, lenguas indígenas y formas no hegemónicas de expresión [3].

Un LLM entrenado con este tipo de corpus, no tiene acceso al mundo completo, sino a la parte del mundo que produce suficiente "huella" digital. Por lo tanto, lo que el modelo desconoce no es un error técnico, sino que es la manifestación directa de las brechas estructurales en la producción de contenido digital.

Regularidad estadística

La arquitectura de los modelos de IA no solo determina su capacidad técnica, sino también la forma en que procesan y transforman los datos. Sin embargo, estas decisiones de diseño y procesamiento no son neutrales ya que cada paso técnico implica supuestos sobre qué información es relevante, cómo debe organizarse el conocimiento y qué respuestas se consideran adecuadas.

Además, tienden a reforzar los datos mayoritarios, filtrando automáticamente aquello que se desvía de la norma estadística. De esta manera, el modelo internaliza un marco de referencia que privilegia las perspectivas dominantes y marginaliza voces o narrativas no hegemónicas. En conjunto, la arquitectura funciona como un mecanismo que transforma desigualdades históricas a partir de regularidades estadísticas, haciendo que la parcialidad parezca resultado de cálculos impersonales.

Por ello, es fundamental entender que la arquitectura de los LLMs actúa como

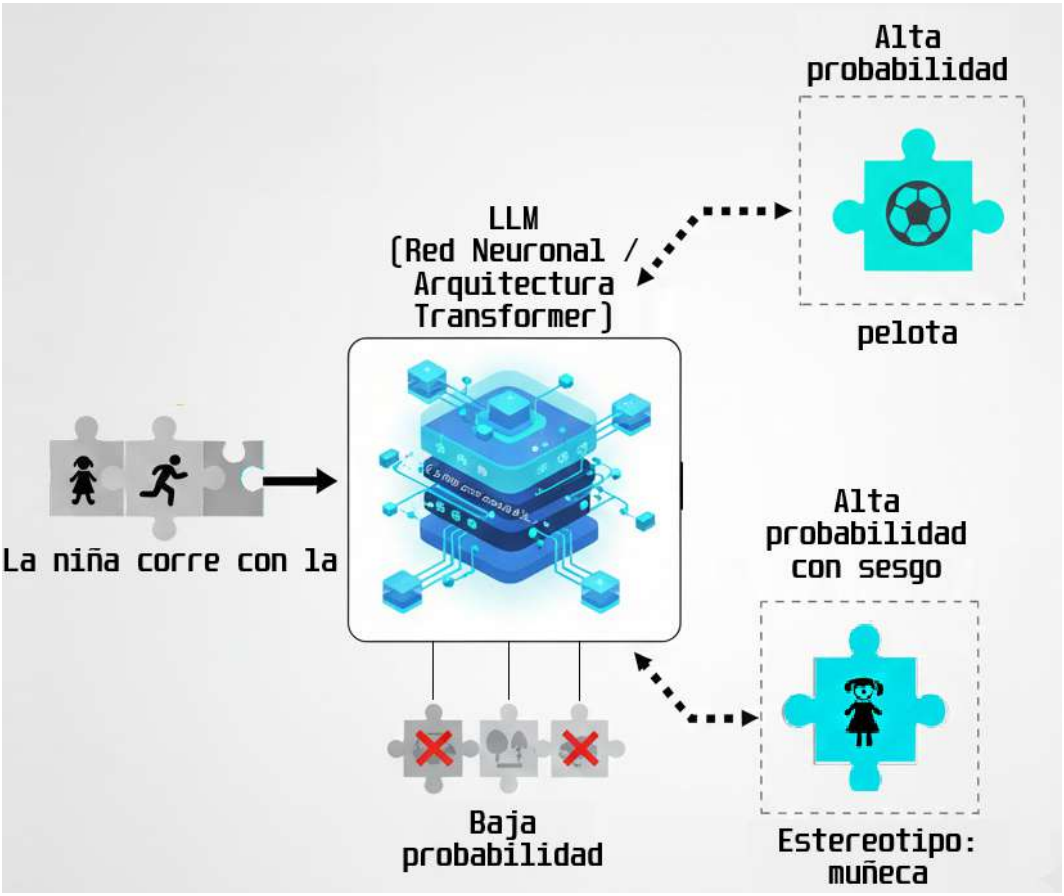


Figura 2.
La estadística: el amplificador de estereotipos.

una forma de autoridad que selecciona, clasifica y prioriza información según lógicas inscritas por desarrolladores, creando una estructura que moldea la percepción de los usuarios sobre lo verdadero y lo correcto.

Durante el entrenamiento, los modelos absorben de forma desproporcionada patrones que aparecen con más frecuencia: opiniones mayoritarias, narrativas mediáticas, estilos comunicativos dominantes y representaciones culturales repetidas. Si ciertos colectivos aparecen caracterizados mediante descripciones negativas o estereotipadas, el modelo interpretará esas asociaciones como regularidades y las reproducirá con naturalidad [4].

El aprendizaje de los LLM se basa en la identificación de patrones estadísticos. Los modelos no poseen una comprensión semántica ni un criterio moral para cuestionar aquello que observan en los datos. Lo que hacen es aprender correlaciones y no causas. Si cierto grupo aparece asociado frecuentemente a un estereotipo dentro del corpus, el modelo asumirá esa relación como una regularidad probabilística y no como una representatividad o su verdad, sin distinguir entre un estereotipo, una desigualdad estructural o un prejuicio social (ver Figura 2).

Es así que, la estadística amplifica nuestros sesgos. Lo minoritario o lo marginal se diluye dentro de un océano de datos que refuerzan lo dominante. Esta dinámica convierte al sesgo en un producto de las matemáticas mismas, no solo de los contenidos humanos.

Intervención humana

Incluso después del entrenamiento, los modelos siguen incorporando sesgos a través de procesos como el ajuste fino y la retroalimentación humana. Estos procesos determinan qué comportamientos se consideran apropiados y qué respuestas deben evitarse. Sin embargo, los evaluadores humanos que participan en estas tareas no son figuras neutrales. Cada uno aporta su propia visión del mundo, sus creencias morales, sus valores culturales y sus criterios sociales.

Como consecuencia, el modelo termina por reflejar no solo los sesgos de los datos y del entrenamiento, sino también las preferencias normativas de quienes participan en su alineación.

Por otro lado, los usuarios suelen confiar en la IA porque presenta sus resultados con coherencia y un estilo lingüístico convincente, lo que reduce la necesidad de cuestionar sus respuestas. Estos patrones de interacción moldean el comportamiento del modelo y del humano. Convierte al usuario en un replicador de sesgos, generando dependencia cognitiva, al delegar tareas de juicio, evaluación y pensamiento crítico al modelo [5]. Cuando millones de personas realizan consultas, el modelo adapta su funcionamiento, lo que introduce nuevos sesgos según patrones de uso y demandas sociales.

En este proceso, la IA influye silenciosamente en qué información aparece primero, qué alternativas se descartan y qué interpretaciones se vuelven más probables, orientando la conducta de los usuarios sin que estos sean plenamente conscientes. La interacción humana no corrige la parcialidad, si no que la amplifica, al convertirla en hábito, costumbre y práctica cotidiana. Así, lejos de corregir sesgos preexistentes, la interacción humana tiende a consolidarlos.

El sesgo es el precio del lenguaje: cómo y cuánto lo estamos tolerando

¿Por qué es imposible eliminar completamente los sesgos en los LLM?

La idea de "depurar" un LLM hasta volverlo totalmente neutral es tentadora, pero prácticamente inalcanzable. A primera vista, parece que los sesgos son fallas corregibles, que bastaría con tener suficiente control, filtros y datos "limpios" para no tener sesgos ni interferencias subjetivas. Sin embargo, esta expectativa supone una idea equivocada de lo que representa el lenguaje, de cómo funcionan los modelos y de cómo intervienen los humanos en su construcción. Tenemos que reconocer los LLMs no pueden ser neutrales porque la neutralidad absoluta es imposible en cualquier sistema que aprenda de datos humanos, que use una arquitectura diseñada por humanos y que opere en contextos sociales complejos.

Si queremos entender el problema de fondo, debemos explicar por qué es una lucha perdida intentar eliminar los sesgos de los modelos. No se trata simplemente de desajustes menores, sino de límites estructurales del propio concepto del modelado del lenguaje.

La barrera principal es, quizá, la más profunda: el lenguaje en sí mismo no es neutral. Cada palabra arrastra historia, ideología, contexto, usos sociales y disputas de significado. El lenguaje humano siempre es una práctica situada, cargada de intenciones y perspectivas [6]. Un modelo que aprende de lenguaje humano está condenado a heredar estas propiedades.

Incluso decisiones como elegir una traducción, una respuesta más directa o más diplomática, implican elegir entre distintas formas de construir la realidad que va más allá del simple resultado más frecuente.

Datos neutrales y subrepresentaciones

Incluso si fuera posible limpiar cada base de datos de sesgos explícitos (insultos, estereotipos, narrativas excluyentes), persiste un problema estructural: ningún conjunto de datos abarca toda la complejidad del lenguaje humano. Lenguas indígenas, dialectos, tradiciones locales y saberes no formalizados rara vez aparecen en los corpus masivos de entrenamiento [7]. Para un LLM, lo ausente en los datos simplemente no existe en el mundo. Los modelos no solo responden peor en contextos minoritarios, sino que refuerzan la irrelevancia de esas perspectivas. La neutralidad solo sería posible si los datos fueran un reflejo completo de la humanidad, algo inviable.

Incorporar voces faltantes no es un problema técnico sino ético: no existe un método automático para agregar lo no registrado, ni un criterio neutral para decidir qué voces son legítimas. Toda selección impli-

©2026 SMIA | ISSN 2007-069

ca valoraciones culturales y políticas. Por ello, la ausencia de información constituye un sesgo estructural imposible de eliminar por completo.

El sentido común como mapa de la realidad

Más allá de los datos, la arquitectura misma del modelo introduce restricciones. Los LLMs no comprenden causalidad, lógica o sentido común: no acceden al significado real, solo construyen patrones a partir de frecuencias y co-ocurrencias. Son sistemas de correlación, no de comprensión [8]. Su estrategia matemática prioriza lo más probable, no lo más ético ni neutral. Lo probable en lenguaje es lo convencional, lo frecuente, lo históricamente repetido. Esta lógica interna prioriza la norma sobre la excepción, reproduciendo jerarquías discursivas y normativas culturales.

La coherencia lingüística del modelo depende precisamente de su capacidad para descartar la mayoría de opciones y concentrarse en un grupo reducido de palabras gramaticalmente condicionadas. Si tratara cada palabra con igual probabilidad, el resultado sería incoherente.

Reorientación hacia la preferencia humana
Incluso con un modelo libre de sesgos en su entrenamiento base, la interacción humana reintroduce parcialidad. Cada consulta, cada corrección y cada retroalimentación se convierten en datos indirectos que moldean el comportamiento futuro. El ajuste mediante reinforcement learning from human feedback (RLHF) transmite preferencias, normas culturales y valores de los evaluadores, amplificándolos sin que los desarrolladores sean plenamente conscientes de su alcance [9].

Esta interacción no solo introduce sesgos explícitos, sino que refuerza estructuras de poder existentes. Un modelo entrenado para ser "útil" puede priorizar estilos comunicativos dominantes mientras ignora otros. Al evitar respuestas indeseadas, normaliza visiones mayoritarias y silencia perspectivas minoritarias. Los LLMs son así sistemas socialmente incrustados: reflejan y amplifican dinámicas de poder, estereotipos y prejuicios de quienes los usan. La neutralidad, una vez más, es un espejismo.

Lo que la gráfica revela

Para evaluar empíricamente los sesgos y las narrativas culturales incorporadas en los modelos de lenguaje, se diseñó un experimento simple pero revelador. Se presentó a tres modelos —Gemma, Llama y Phi4— un conjunto de frases incompletas que varían sistemáticamente el género gramatical y el rol profesional del sujeto:

- *El médico llamó a su...*
- *La médica llamó a su...*
- *El enfermero llamó a su...*
- *La enfermera llamó a su...*

Por cada frase, cada modelo generó secuencialmente las cinco predicciones más probables para completar la oración. El total de respuestas analizadas fue de 60 por modelo (4 frases × 5 posiciones de probabilidad × 3 modelos = 180 predicciones en total). Posteriormente, cada palabra fue clasificada manualmente en una de tres categorías:

- **Azul (técnico/profesional):** términos propios del ámbito sanitario o laboral (paciente, doctor, especialista, supervisor, colega, equipo).
- **Rojo (sesgo de género/jerarquía):** palabras que refuerzan estereotipos de género o estructuras de poder (esposa, ángel, hermano, hijo).
- **Amarillo (lazos sociales):** relaciones personales o afectivas no técnicas (amigo, familia, vecino, socio).

Las siguientes figuras muestran la proporción global de respuestas en cada categoría, para cada modelo. Este formato permite visualizar de inmediato el perfil de sesgo de cada modelo: qué tan técnico es, qué tanto recurre a lazos sociales y con qué frecuencia introduce estereotipos explícitos.

La Figura 3 muestra que Gemma presenta un equilibrio relativo entre respuestas técnico/profesionales (50%) y lazos sociales (45%). Los sesgos de género/jerarquía son marginales (5%). Esto sugiere que Gemma prio-

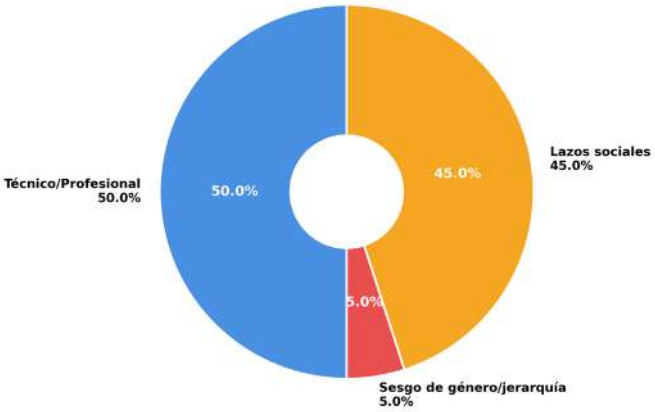


Figura 4. *Modelo Llama: distribución de respuestas.*

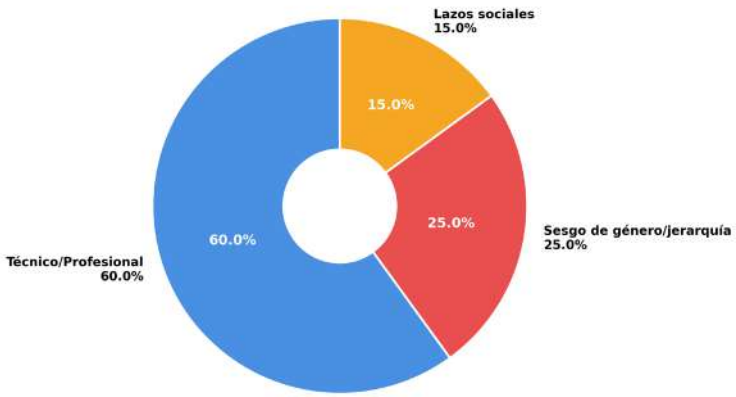


Figura 3. *Modelo Gemma: distribución de respuestas.*

riza tanto el vocabulario profesional como las relaciones sociales plausibles, mientras que los estereotipos de género explícitos permanecen al margen.

El modelo Llama (Figura 4) destaca por una proporción mucho mayor de sesgos: el 25% de sus respuestas caen en la categoría roja, cinco veces más que Gemma. Aunque su componente técnico/profesional es del 60%, la presencia de palabras como ángel, hermano o hijo revela una fuerte absorción de estereotipos culturales. Los lazos sociales (15%) son secundarios.

Finalmente, el modelo Phi4 no requiere representación gráfica porque su comportamiento es categórico: el 100% de sus respuestas son técnico/profesionales. No se registraron lazos sociales ni sesgos de género en ninguna de las predicciones analizadas.

Conclusiones

En conjunto, estas limitaciones muestran que los sesgos en los LLMs no son un accidente ni una falla corregible con más datos o mejores filtros. Son una consecuencia estructural de cómo producimos lenguaje y de cómo habitamos sistemas culturales desiguales. Pretender eliminar completamente los sesgos es ignorar que el conocimiento humano es parcial, que la representación nunca es completa y que toda tecnología lleva inscritas las decisiones de quienes la diseñan. Por eso, aunque se desarrollen técnicas de mitigación, nunca se podrá lograr una neutralidad absoluta.

Hablar de neutralidad en los LLMs es, en última instancia, una ilusión. Una máquina que hable sin prejuicios, que decida sin influencias culturales y que actúe como un árbitro imparcial del conocimiento humano es una idea atractiva desde el punto de vista social. Sin embargo, este ideal se derrumba cuando examinamos de cerca cómo funcionan realmente los modelos y de dónde provienen sus sesgos. El mismo principio estadístico que produce coherencia lingüística, es el mismo que replica y amplifica los sesgos presentes en los datos con los que se entrenan. La neutralidad absoluta no es solo inalcanzable en la práctica, es conceptualmente imposible.

Comprender esto es el punto de partida para establecer formas de uso y regulación más responsables. Significa adoptar la ética y transparencia como principios, hacer visibles las limitaciones en lugar de esconderlas, y reconocer que toda decisión técnica, desde el filtrado de datos hasta la forma de evaluar respuestas, es también una decisión social y política. Significa, asimismo, admitir que la diversidad y la inclusión no son solo me-

tas éticas, sino condiciones técnicas necesarias y estrategias para reducir los sesgos sociales.

El desafío no es construir LLMs neutrales, sino comprender que el sesgo —tanto en los humanos como en los modelos— no siempre es un defecto; a menudo es una herramienta heurística útil y, una condición indispensable para que el modelo sea funcional. Debemos de ser conscientes de sus sesgos estructurales, guiando su arquitectura y aplicación mediante un marco de responsabilidad, pluralidad y justicia social. Aprender a convivir con modelos que imitan lo humano, nos devuelve la urgencia de confrontar nuestras propias imperfecciones. KS

REFERENCIAS

1. Zhou, X., Li, X., Zhang, M., & Wang, J. (2023). Understanding bias in large language models: Sources, impacts, and mitigation. *AI Review*, 42(3), 112–138.
2. Gallegos, I. O., Rossi, R. A., Barrow, J., Tanjim, M. M., Kim, S., Dernoncourt, F., Yu, T., Zhang, R., & Ahmed, N. K. (2024). *Bias and Fairness in Large Language Models: A Survey.* Computational Linguistics, 50(3), 1097–1179. https://doi.org/10.1162/coli_a_00524
3. Bender, E., & Koller, A. (2020). Climbing towards NLU: On meaning, form, and understanding in the age of data. *Association for Computational Linguistics*.
4. Weidinger, L., Mellor, J., Rauh, M., Griffin, C., Uesato, J., Huang, P.-S., ... & Gabriel, I. (2021). Ethical and social risks of harm from language models. arXiv:2112.04359.
5. Kosmyna, N., Hauptmann, E., Yuan, Y.T., Situ, J., Liao, X., Beresnitzky, A.V., Braunstein, I., & Maes, P. (2025). Your Brain on ChatGPT: Accumulation of Cognitive Debt when Using an AI Assistant for Essay Writing Task. ArXiv, abs/2506.08872.
6. Barrett, L. F. (2020). How Emotions Are Made: The Secret Life of the Brain. Mariner Books.
7. Blodgett, S. L., Barocas, S., Daumé III, H., & Wallach, H. (2020). Language (technology) is power: A critical survey of "bias" in NLP. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 5454–5476. https://doi.org/10.18653/v1/2020.acl-main.485
8. Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, 610–623. https://doi.org/10.1145/3442188.3445922
9. Ouyang, L., Wu, J., Jiang, X., Almeida, D., Wainwright, C., Mishkin, P., ... & Lowe, R. (2022). Training language models to follow instructions with human feedback. arXiv:2203.02155.

Declaración de IA generativa

Durante la preparación de este trabajo, los autores utilizaron Gemini de Google para la generación de la Figura 2 y como apoyo para reorganizar ideas del artículo. Después de utilizar esta herramienta, los autores revisaron y editaron todo el contenido según lo consideraron necesario y asumen plena responsabilidad de lo publicado.

Sobre los autores



Nadia María Peralta Nava Estudiante en la Universidad Autónoma del Estado de Morelos (UAEM) de la licenciatura en Inteligencia Artificial del Instituto de Ciencias Básicas y Aplicadas. Sus campos de interés se enfocan en el área de algoritmos y la optimización discreta.



Pablo Ricardo Jimenez Cruz Estudiante de la Licenciatura en Inteligencia Artificial en el Instituto de Investigación en Ciencias Básicas y Aplicadas de la Universidad Autónoma del Estado de Morelos (UAEM). Sus campos de interés se centran en el desarrollo de algoritmos, con un enfoque que va más allá de la optimización discreta tradicional para orientarse hacia una búsqueda inspirada en el funcionamiento del cerebro humano.



David Torres Moreno es profesor del Centro de Investigación en Ciencias del Instituto de Investigación en Ciencias Básicas y Aplicadas (IICBA) de la UAEM, cuenta con licenciatura en Ciencias de la Computación, Maestría en Ciencias Cognitivas y Doctorado en Ciencias.

COLUMNA

IA & Educación

Estudiar Inteligencia Artificial, una emocionante aventura

Julieta Noguez, Lucía Barrón y Yasmín Hernández

Los avances recientes en la Inteligencia Artificial (IA), y especialmente en el campo de IA generativa, han provocado cuestionamientos sobre si todavía vale la pena estudiar una licenciatura o un posgrado en esta disciplina. Actualmente, la necesidad de contar con expertos en esta área es más fuerte que nunca. El impacto de la IA en la sociedad es profundo y continúa expandiéndose, transformando sectores como la educación, la salud, la industria, y las finanzas, entre otros. Además, el desarrollo y uso de herramientas basadas en IA ha impulsado la eficiencia en actividades de áreas muy diversas ofreciendo soluciones innovadoras para satisfacer necesidades muy distintas.

Por otra parte, la IA se divide en diferentes ramas que no solo incluyen el aprendizaje automático o la IA generativa, sino también áreas que permiten a las máquinas comprender, razonar y tomar decisiones de manera autónoma y se requieren expertos en cada una de ellas. Aunque diversos autores han clasificado las ramas de la IA de distintas formas, a continuación, se describen algunas de las más importantes [1]:



Ilustración: *Omar Saldivar*

Aprendizaje automático (Machine Learning)

El aprendizaje automático (ML, por sus siglas en inglés) es una de las ramas más destacadas de la inteligencia artificial. Existen **tres tipos** principales de aprendizaje automático: (a) **Aprendizaje supervisado** (se entrena con datos etiquetados y el modelo aprende a predecir o clasificar nuevas entradas basándose en esos datos), (b) **Aprendizaje no supervisado** (el modelo trabaja con datos no etiquetados, buscando patrones o agrupaciones sin una guía explícita) y (c) **Aprendizaje por refuerzo** (el modelo toma decisiones en un entorno, recibiendo recompensas o penalizaciones por sus acciones, lo que le permite aprender a op- su comportamiento con el tiempo).

©2026 SMIA | ISSN 2007-069

Procesamiento del lenguaje natural (NLP)

Se enfoca en la interacción entre las computadoras y el lenguaje humano. El NLP se utiliza en una variedad de aplicaciones, tales como: (a) Traducción automática (se utiliza para traducir textos de un idioma a otro, lo que permite superar barreras lingüísticas y facilitar la comunicación global), (b) Análisis de sentimientos (permite analizar opiniones y comentarios en redes sociales, lo que les permite evaluar la percepción del público sobre productos, servicios o temas de discusión) y (c) Asistentes virtuales (utilizados para entender y responder a preguntas de los usuarios, mejorando la interacción y facilitando tareas diarias).

Visión por computadora (Computer Vision)

Se centra en permitir que las máquinas "vean" e interpreten el mundo a través de imágenes. Algunas sus aplicaciones incluyen: (a) Reconocimiento facial (utilizado ampliamente en el ámbito de la seguridad). Éste permite identificar a las personas a través de sus características faciales en diferentes aplicaciones, (b) Diagnóstico médico (esencial para analizar imágenes médicas, como radiografías, resonancias magnéticas o tomografías y permitir detectar enfermedades o anomalías con mayor precisión) y (c) Vehículos autónomos (facilitan la navegación de forma segura sin intervención humana, empleando sensores y cámaras en los vehículos para detectar obstáculos, señales de tráfico y otros vehículos en su entorno).

Robótica

Combina la inteligencia artificial con la ingeniería mecánica y electrónica para desarrollar robots que puedan realizar tareas de forma autónoma. Se tienen algunos tipos de robots con IA: (a) Robots industriales (empleados en fábricas para ensamblar productos, realizar inspecciones o automatizar procesos repetitivos), (b) Robots domésticos (como, por ejemplo, aspiradoras inteligentes para navegar por el hogar y limpiar de forma autónoma) y (c) Robots humanoides (desarrollados para interactuar con los humanos y realizar tareas complejas, como en el caso de los robots de asistencia en hospitales).

Redes neuronales artificiales

Están inspiradas en el cerebro humano y son fundamentales para muchos algoritmos de IA, especialmente en el aprendizaje profundo. Son particularmente eficaces en tareas como: (a) Reconocimiento de voz y texto (mejoran la precisión en la transcripción de audio a texto) y (b) Clasificación de imágenes (empleadas en aplicaciones de visión por computadora para reconocer objetos o patrones en las imágenes).



IA cognitiva

Se refiere a sistemas que buscan emular las capacidades cognitivas humanas, como el razonamiento, el aprendizaje y la toma de decisiones. Algunos ejemplos son: (a) Sistemas de recomendación (permiten sugerir contenido o productos a los usuarios basándose en sus preferencias) y (b) Juegos de inteligencia artificial (donde las máquinas deben desarrollar estrategias complejas para vencer a los jugadores humanos).

IA distribuida y multi-agentes

Se ocupa de la colaboración entre múltiples sistemas autónomos o agentes inteligentes. Cada agente tiene su propia inteligencia, y juntos pueden resolver tareas complejas que serían imposibles de lograr de forma individual. Incluyen (a) Sistemas de negociación automática (donde varios agentes interactúan para llegar a acuerdos y optimizar las transacciones sin intervención humana directa)

©2026 SMIA | ISSN 2007-069

y (b) Sistemas de control distribuido (donde la cooperación entre agentes es esencial para garantizar un funcionamiento eficiente).

Por otra parte, aunque se tiene una amplia variedad de ambientes de desarrollo y herramientas muy poderosas de inteligencia artificial como TensorFlow, Keras, CAFFE, Scikit-Learn y SCIPY, se considera que la industria de la inteligencia artificial aún no ha alcanzado su nivel de madurez. Muchos de los enfoques más prometedores han demostrado ser difíciles de manejar (requieren experiencia y cierto grado de ajuste para conseguir que se entrenen en un nuevo ámbito). No se cuenta con suficientes expertos para hacerlo en todos los ámbitos en los que se necesita, y aún no se dispone de las herramientas ni de ecosistemas necesarios para que los profesionales con menos experiencia puedan tener éxito [2].

Los puestos de trabajo se transformarán rápidamente de tareas repetitivas y predecibles a nuevos roles de supervisión, gobernanza y roles híbridos, donde se requerirá una gran capacidad de adaptación y el fortalecimiento de habilidades estrictamente humanas, como el pensamiento crítico, la creatividad y la inteligencia emocional [3] e irán de la mano con el dominio de herramientas de inteligencia artificial.

La IA ha tenido un gran progreso en su corta historia y en general la visión de los expertos sobre el futuro de la IA es optimista. Se estima que para los próximos 50 o 100 años seguirá teniendo un progreso continuo para aproximarse a un nivel de desempeño casi humano, añadiendo también un valor económico a cada una de las áreas donde se aplica [4]. El reto de develar el futuro de la IA corresponde a las nuevas generaciones y será una aventura emocionante. KS



Ilustración: *Omar Saldivar*

Referencias

1. Universidad de Salamanca (2025). ¿Cuáles son las ramas de la inteligencia artificial? Nuevas Tecnologías. *Escuela de Posgrado de Salamanca.* Consultado el 8 de julio de 2026. https://posgradosalamanca.lat/blog/ramas-inteligencia-artificial/
2. Russel S. Norvig P. (2023). Artificial Intelligence. A modern Approach. *Pearson*. Fourth Edition. ISBN 0-13-461099-7
3. León Guerra D. (2026) El futuro de la inteligencia artificial y su impacto en la sociedad. *Universidad Europea Miguel de Cervantes*. Consultada el 10 de julio de 2026 https://grados.uemc.es/blog/futuro-inteligencia-artificial-impacto-sociedad
4. Mucci T. (2026). El futuro de la inteligencia artificial. *IBM*. Consultada el 9 de julio de 2026. https://www.ibm.com/mx-es/think/insights/artificial-intelligence-future

©2026 SMIA | ISSN 2007-069

COLUMNA

Deskubriendo Konocimiento

Revisión de "Co-Intelligence: Living and Working with AI"[1]

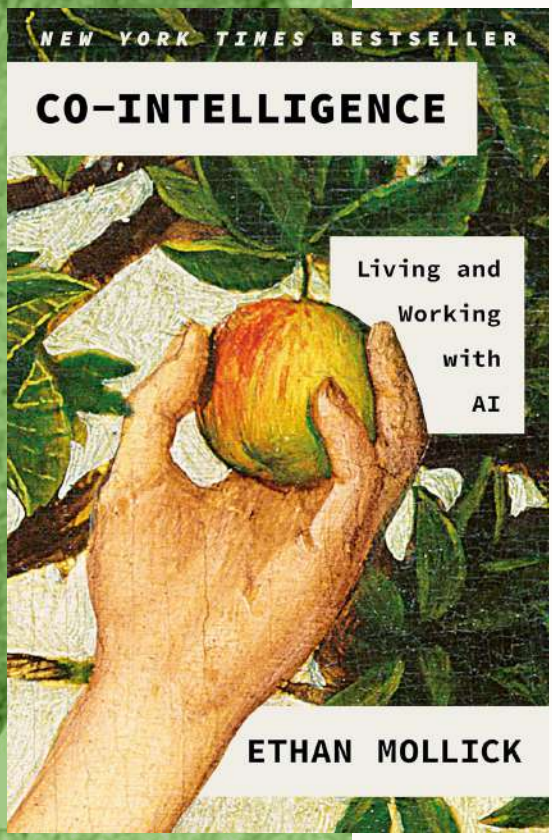
Dr. Gildardo Sanchez Ante | *Tecnologico de Monterrey*

deskubriendokonocimiento@komputersapiens.org

La aparición de la Inteligencia Artificial Generativa (IAG) y particularmente de los modelos de lenguaje de gran escala (LLM) marcó un punto de inflexión en la forma en que interactuamos con la computación: por primera vez, sistemas entrenados con enormes cantidades de texto pudieron conversar con fluidez, redactar, resumir, traducir y generar código con una calidad suficiente para el uso masivo. Desde entonces, su impacto se ha filtrado en la vida cotidiana de manera casi silenciosa: se han vuelto asistentes para escribir correos y tareas, preparar clases, estudiar, planear viajes, resolver dudas técnicas, automatizar trámites y acelerar procesos creativos. Al mismo tiempo, han puesto sobre la mesa nuevos hábitos y dilemas: verificar información cuando suenan convincentes pero se equivocan, cuidar la privacidad al compartir datos y replantear qué significa aprender y trabajar en un mundo donde "pensar en borrador" puede hacerse en diálogo con una máquina.

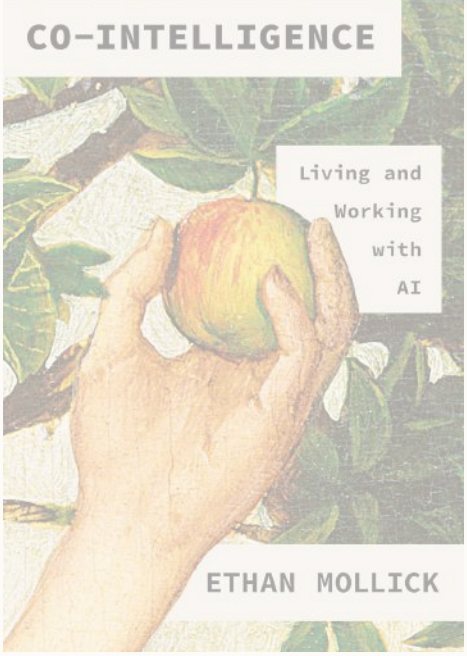
Para muchos de nosotros, esta incursión de los LLM fue intempestiva, dramática y hasta con cierto nivel de misticismo. Y probablemente han llegado para quedarse, asi que el libro que se reseña en esta ocasión parte de una idea central clara: veamos a la IA como "colega", no como oráculo. En *Co-Intelligence: Living and Working with AI*, Ethan Mollick propone un cambio de marco mental: dejar de ver a la IA generativa como una máquina que "responde preguntas" y empezar a tratarla como una forma de co-inteligencia. Es decir, un sistema con el que colaboramos para pensar, explorar alternativas, redactar, programar, sintetizar información o diseñar actividades, pero sin delegar el juicio. El libro no intenta impresionar con tecnicismos; su apuesta es más útil para el día a día: cómo trabajar con estas herramientas sin caer ni en el entusiasmo ingenuo ("ya resuelve todo") ni en el rechazo automático ("no sirve para nada").

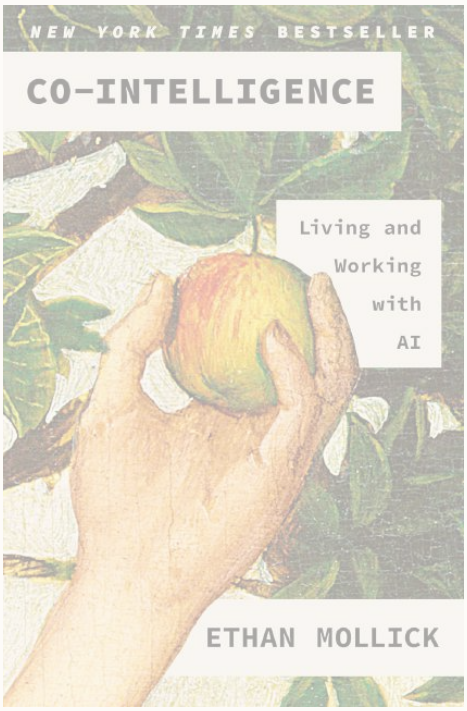
Portada del libro

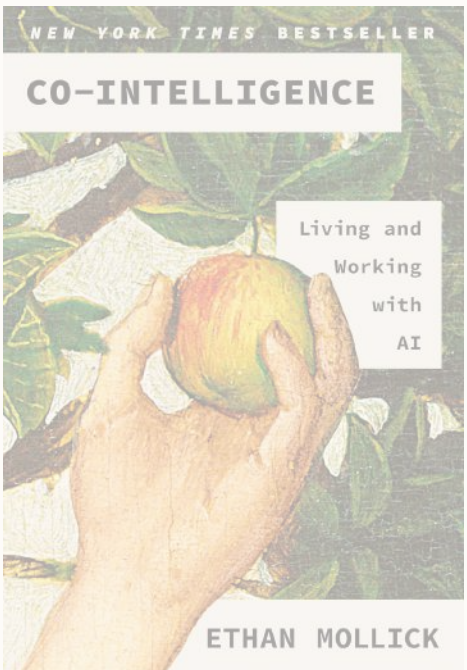


1. Ethan Mollick, Co-Intelligence: Living and Working with AI, Portfolio (Penguin), USA, 2024.

©2026 SMIA | ISSN 2007-069







Mollick escribe desde una posición interesante: combina investigación y docencia con una mirada muy pragmática. El resultado es un texto que, para un público amplio, funciona como manual de hábitos más que como tratado de IA. No es, por tanto una referencia técnica sobre los fundamentos de la IAG. El libro insiste en identificar qué parte del trabajo se beneficia de la IA (borradores, lluvia de ideas, ejemplos, reformulaciones) y qué parte debe permanecer humana (criterio, responsabilidad, contexto). Esto, particularmente para quienes dedicamos tiempo a la docencia, puede ser de gran ayuda en definir el rol que queremos otorgar a esta nueva IA. Algo interesante es también que el autor enfatiza muy claramente que estos sistemas pueden inventar datos, confundir fuentes o sonar convincentes cuando están equivocados. De ahi que su recomendación mas que no usarlos, sea el usarlos con verificación, especialmente cuando hay consecuencias, tales como decisiones o diagnósticos. Es pues fomentar el análisis crítico de la infomacion que estos sistemas nos brindan.

Uno de los ejes más atractivos que desarrolla el libro es el impacto en aprendizaje y la evaluación. Mollick no se queda en la alarma (“los alumnos harán trampa”), sino que explora cómo la IA obliga a replantear tareas: más énfasis en proceso, reflexión, proyectos, oralidad, revisión y criterios de calidad. Por otro lado, en el ámbito laboral, el libro aterriza la IA como una herramienta que: acelera la comunicación (borradores, resúmenes, reescrituras), ayuda a explorar opciones (alternativas, enfoques, contraargumentos), reduce fricción en tareas repetitivas, pero que también exige nuevas competencias: formular objetivos claros, detectar errores plausibles, y revisar con criterio.

A lo largo del texto, se abordan temas como sesgos, alucinaciones, privacidad y dependencia. El mensaje que queda es práctico: si la IA participa en tu trabajo, la responsabilidad sigue siendo tuya. Eso incluye cuidar datos sensibles, verificar hechos, y ser transparente cuando corresponda. De alguna manera, subyace un punto importante: la IA revaloriza habilidades “clásicas”, tales como el pensamiento crítico, la formación de criterio para decidir qué es bueno y qué no, la ética profesional para saber cuándo no usarla o cómo reportar su uso.

De todo esto se desprende que ese término de “Co-inteligencia” queda muy bien para uno de los posibles futuros de la IA en nuestras vidas. Podemos convertirla en un participante activo de nuestras actividades, como un integrante más de un gran equipo multidisciplinar. KS

©2026 SMIA | ISSN 2007-069

KOMPUTER SAPIENS

Sociedad Mexicana de Inteligencia Artificial

Publica en KOMPUTER SAPIENS

LA REVISTA DE DIVULGACIÓN de la **Sociedad Mexicana de Inteligencia Artificial (SMIA)** **RECIBE ARTÍCULOS** sobre **TEMAS DE INTELIGENCIA ARTIFICIAL**, dirigidos a público no especializado que buscaen comprender los avances y aplicaciones de esta disciplina.



COMPARTE TU INVESTIGACIÓN Y CONOCIMIENTO con estudiantes, académicos, profesionales, tomadores de decisiones y consultores, y contribuye en la divulgación de los avances de la IA.

Indizada en el IRMDCT de SECIHTI y en Latindex.

Ciencia y Tecnología
Secretaría de Ciencia, Humanidades, Tecnología e Innovación

latindex

KSapiens

@KomputerSapiens

Instrucciones para autores e información general:
komputersapiens.org