

# INTELIGENCIA ARTIFICIAL

EXPERIENCIAS Y REFLEXIONES SOBRE LA INVESTIGACIÓN CIENTÍFICA



ALEXANDRO ESCUDERO-NAHÓN  
EDITOR

**Transdigital**<sup>®</sup>  
editorial



# INTELIGENCIA ARTIFICIAL

EXPERIENCIAS Y REFLEXIONES SOBRE LA INVESTIGACIÓN CIENTÍFICA

ALEXANDRO ESCUDERO-NAHÓN

EDITOR

ALEJANDRO GUADALUPE RINCÓN CASTILLO, ALEXANDRO ESCUDERO-NAHÓN, ALMA DELIA OTERO ESCOBAR, ANDREA SÁNCHEZ-RUIZ, ANDRÉS VALENCIA SÁNCHEZ, ANTONIO FRANCO VADILLO, ANTONIO JUAN CAPISTRAN ABUNDEZ, ARTURO GONZÁLEZ TORRES, AURA PATRICIA HERNÁNDEZ OLICÓN, BLANCA CECILIA LÓPEZ RAMÍREZ, CÁNDIDA MARCELA RODRÍGUEZ CHÁVEZ, CARLOS ENRIQUE LEVET RIVERA, CARLOS ZEPEDA-LUGO, CAROLINA MEDINA GARCÍA, CECILIA ESPERANZA OSTOS CRUZ, CESAIRE CHIATCHOUA, CHRISTIAN PAULINA MENDOZA TORRES, CLARA ROSALVA MERCADO-LÓPEZ, CLAUDIA MARGARITA GARCÍA PAULIN, DANIEL ALBERTO MEJÍA HERRERA, DIEGO ESCUDERO-SÁNCHEZ, ELENA ELSA BRICIO-BARRIOS, ELIZABETH VANESSA TENIENTE GASCA, ELSA SUÁREZ JASSO, EMMA PATRICIA MERCADO-LÓPEZ, ERIK CARBAJAL-DEGANTE, FABIÁN GÓMEZ SANTIAGO, FRANCISCO ANTONIO TORRES-ESPRIÚ, FRANCISCO DE JESÚS MATA GÓMEZ, FRANCISCO GUADALUPE AVENDAÑO ESPARZA, GEORGINA DEL CARMEN MOTA VALTIERRA, GERARDO QUIROZ BOJORGES, GUILLERMO VARGAS RODRÍGUEZ, HÉCTOR ALFREDO BAPTISTA GONZALES, HUMBERTO AGUIRRE BECERRA, INÉS GUADALUPE GERMÁN AGUILAR, ITZIA NALLELY GUZMÁN MEJÍA, , IVETTE SELENE MARAÑÓN LIZÁRRAGA, JOSÉ ANTONIO CISNEROS JIMÉNEZ, JOSÉ CRISTÓBAL SOLÍS POLLORENA, JOSÉ LUIS BAUTISTA LÓPEZ, JUAN CARLOS LOBATO-VALDESPINO, JULIA DOLORES TOSCANO GARIBAY, KARINA GUADALUPE CORTINA CALDERÓN, LEONARDO ELIPHAS DAZA RAMÍREZ, LEONARDO LEDESMA DOMÍNGUEZ, LUCIA MORALES-MORALES, LUIS ALONSO CASTAÑEDA NEGRETE, LUIS JAVIER RAÚL OBREGÓN HERRIN, LUIS RAMÓN CARREÑO DURÁN, LUZ ANGÉLICA MONDRAGÓN DEL ANGEL, MA. CRISTINA VÁZQUEZ HERNÁNDEZ, MANUEL RAMÓN GONZÁLEZ HERRERA, MARCOS SANCHEZ-LIZARRAGA, MARIAJOSÉ LÓPEZ LAIZA, MARIO ALBERTO DOMÍNGUEZ-ROVIRA, MARYSOL ESTRELLA HERNÁNDEZ GARCÍA, MIGUEL ÁNGEL MEDINA ROMERO, MIREILLE TOLEDO BLAS, MODESTA LORENA HERNÁNDEZ SÁNCHEZ, MÓNICA LORENA SÁNCHEZ LIMÓN, NALLELY GUADALUPE HERNÁNDEZ HERNÁNDEZ, OCTAVIO REYES LÓPEZ, PAVEL DAVID ULISES AVENDAÑO LÓPEZ, RAMAR MENDOZA DÍAZ, RITA ÁVILA ROMERO, RODRIGO OCHOA FIGUEROA, SALVADOR ORTIZ SANTOS, SANTIAGO ARCEO-DIAZ, TANIA HAIDÉE TORRES CHÁVEZ, TOMÁS PERALTA PALAZÓN, VITERVO LÓPEZ-CABALLERO Y XÓCHITL TRUJILLO-TRUJILLO.

AUTORES Y AUTORAS

---

Título original: Inteligencia artificial: experiencias y reflexiones sobre la investigación científica / Alexandro Escudero-Nahón (Editor) — Ciudad de Querétaro, México: Editorial Transdigital, 2026 — 457 páginas.

International Standard Book Number (ISBN): 978-968-9724-25-4.

Digital Object Identifier (DOI) del libro: <https://doi.org/10.56162/transdigitalbc12>

Clasificación DEWEY. Materia: 370.7—Estudio y enseñanza de la educación. Tipo de Contenido: Libros universitarios.  
Clasificación thema: JN—Educación. Tipo de soporte: libro digital gratuito descargable. Formato: PDF. Tamaño: 8.3 Mb.

---



Este libro es una publicación de acceso abierto con los principios de Creative Commons Attribution 4.0 International License (CC BY-NC-SA). Esta licencia permite a los reutilizadores distribuir, remezclar, adaptar y desarrollar el material en cualquier medio o formato únicamente con fines no comerciales y siempre que se otorgue la atribución al creador. Si remezcla, adapta o construye sobre el material, debe licenciar el material modificado bajo términos idénticos.

Esta obra ha sido dictaminada por pares académicos expertos con el método de doble ciego. Los dictámenes están resguardados en los archivos de la Editorial *Transdigital*.

D.R. 2026 Alexandro Escudero-Nahón (Editor).

D.R. 2026 Autores y autoras.

D.R. 2026 Sello Editorial *Transdigital*.



Sociedad de Investigación sobre Estudios Digitales, S. C. Nombre de marca: *Transdigital*. Dirección: Circuito Altos Juriquilla 1132. Colonia Altos Juriquilla. C. P. 76230, Juriquilla, Querétaro, México.  
+52 (442)301 32 38. [editorial@transdigital.mx](mailto:editorial@transdigital.mx) [www.editorial.transdigital.mx](http://www.editorial.transdigital.mx)



Registro en el Padrón Nacional de Editores como agente editor Sociedad de Investigación sobre Estudios Digitales, S. C., con el Dígito Identificador 978-607-99594.



Afiliación a la Cámara Nacional de la Industria Editorial Mexicana (CANIEM) con el número 4069, de conformidad con el artículo 17 de la Ley de Cámaras Empresariales y sus Confederaciones en vigor.

Registro Nacional de Instituciones y Empresas Científicas y Tecnológicas de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) de México con el folio: RENIECYT 2400068.



Sugerencia de referencia para el libro en APA 7a. edición:

Escudero-Nahón, A. (2026) (Editor). *Inteligencia artificial: experiencias y reflexiones sobre la investigación científica*. Editorial Transdigital. <https://doi.org/10.56162/transdigitalbc12>


# CONTENIDO

00.	ANÁLISIS DE LAS EXPERIENCIAS Y REFLEXIONES SOBRE LA INTELIGENCIA ARTIFICIAL EN LA INVESTIGACIÓN CIENTÍFICA.....	9
	<a href="#">Alexandro Escudero-Nahón y Diego Escudero-Sánchez</a>	
01.	CONDICIONES SOCIALES EN LA PLANEACIÓN ESTRATÉGICA PARA LA ADQUISICIÓN DE INTELIGENCIA ARTIFICIAL EN LAS ORGANIZACIONES .....	29
	<a href="#">José Antonio Cisneros Jiménez</a>	
02.	EMPLOYMENT SITUATION FOR RECENT UNIVERSITY GRADUATES IN MEXICO CITY (2020-2024).....	43
	<a href="#">Mariajosé López Laiza, Rita Ávila Romero y Cesaire Chiatichoua</a>	
03.	INTELIGENCIA ARTIFICIAL Y PALEOGENÓMICA PREDICTIVA: INCOMPATIBILIDAD RH Y KELL EN EL COLAPSO DEMOGRÁFICO NEANDERTAL.....	58
	<a href="#">Luis Ramón Carreño Durán, Aura Patricia Hernández Olicón, Antonio Franco Vadillo, Mireille Toledo Blas, Fabián Gómez Santiago y Héctor Alfredo Baptista Gonzales</a>	
04.	JUSTICIA ALGORÍTMICA Y GOBERNANZA ÉTICA ANTE LOS SESGOS DE LA INTELIGENCIA ARTIFICIAL ....	77
	<a href="#">Alma Delia Otero Escobar, Cecilia Esperanza Ostos Cruz y Elsa Suárez Jasso</a>	
05.	INTELIGENCIA ARTIFICIAL GENERATIVA Y ÉTICA PROFESIONAL EN LA CONTADURÍA PÚBLICA.....	96
	<a href="#">Leonardo Eliphaz Daza Ramírez y Francisco de Jesús Mata Gómez</a>	
06.	INTEGRACIÓN DE LA INTELIGENCIA ARTIFICIAL EN PROCESOS DE INVESTIGACIÓN EN INSTITUCIONES EDUCATIVAS EN ZACATECAS, MÉXICO.....	123
	<a href="#">Alejandro Guadalupe Rincón Castillo, Cándida Marcela Rodríguez Chávez, Luis Alonso Castañeda Negrete y Daniel Alberto Mejía Herrera</a>	
07.	¿PUEDEN LAS MÁQUINAS SALVAR AL MAÍZ? APRENDIZAJE PROFUNDO PARA LA DETECCIÓN DE PLAGAS .....	142
	<a href="#">Antonio Juan Capistran-Abundez, Vitervo López-Caballero, Lucía Morales-Morales y Andrea Sánchez-Ruiz</a>	

<b>08.</b>		
	TRIPLE CONVERGENCIA EN LA ERA DE LA TRANSFORMACIÓN DIGITAL DEL TURISMO: CIENCIA DE DATOS, INTELIGENCIA ANALÍTICA Y GESTIÓN DE DESTINOS .....	159
	<a href="#">Manuel Ramón González Herrera y Carolina Medina García</a>	
<b>09.</b>		
	USO DE LA INTELIGENCIA ARTIFICIAL EN EL COACHING EMPRESARIAL (2024): REVISIÓN DE LITERATURA .....	175
	<a href="#">Arturo González Torres, Gerardo Quiroz Bojorges y Pavel David Ulises Avendaño López</a>	
<b>10.</b>		
	EL USO DE LA INTELIGENCIA ARTIFICIAL EN LOS PROCESOS DE INVESTIGACIÓN CIENTÍFICA .....	193
	<a href="#">Marysol Estrella Hernández García</a>	
<b>11.</b>		
	HACIA UNA NUEVA PRAXIS DE CIENCIA ABIERTA DOMINADA POR DATOS MASIVOS E INTELIGENCIA ARTIFICIAL GENERATIVA .....	208
	<a href="#">Erik Carbajal-Degante y Leonardo Ledesma-Domínguez</a>	
<b>12.</b>		
	LA INTELIGENCIA ARTIFICIAL EN EL DERECHO: USO PRÁCTICO Y TRANSICIÓN REGULATORIA .....	224
	<a href="#">Carlos Enrique Levet Rivera, Modesta Lorena Hernández Sánchez y Ramar Mendoza Díaz</a>	
<b>13.</b>		
	ENVEJECIMIENTO DIGNO EN MÉXICO: DETECCIÓN EN TIEMPO REAL DEL NIVEL DE RIESGO DE SARCOPENIA MEDIANTE INTELIGENCIA ARTIFICIAL .....	238
	<a href="#">Santiago Arceo-Díaz, Xóchitl Trujillo-Trujillo y Elena Elsa Bricio-Barrios</a>	
<b>14.</b>		
	EL IMPACTO DE LA INTELIGENCIA ARTIFICIAL GENERATIVA EN LA ARQUITECTURA EDITORIAL Y EL CRECIMIENTO EXPONENCIAL DE LA PRODUCCIÓN CIENTÍFICA EN SALUD.....	251
	<a href="#">Salvador Ortiz Santos, Georgina del Carmen Mota Valtierra, Humberto Aguirre Becerra, Blanca Cecilia López Ramírez y Ma. Cristina Vázquez Hernández</a>	
<b>15.</b>		
	FACTORES CRÍTICOS DE ÉXITO PARA IMPLEMENTAR LA INTELIGENCIA ARTIFICIAL EN LAS UNIDADES DE CUIDADOS INTENSIVOS.....	265
	<a href="#">Carlos Zepeda-Lugo, Marcos Sanchez-Lizarraga e Ivette Selene Marañón Lizárraga</a>	

<b>16.</b>		
	<b>ESCUCHA HUMANA E INTELIGENCIA ARTIFICIAL: LÍMITES Y ALCANCES EN LA INVESTIGACIÓN MUSICAL .....</b>	<b>280</b>
	<a href="#">José Luis Bautista López, Guillermo Vargas Rodríguez y Luis Javier Raúl Obregón Herrin</a>	
<b>17.</b>		
	<b>EVOLUCIÓN DE LA REPRESENTACIÓN GRÁFICA: DEL TRAZO HUMANO AL ALGORITMO.....</b>	<b>295</b>
	<a href="#">Luz Angélica Mondragón del Angel e Inés Guadalupe Germán Aguilar</a>	
<b>18.</b>		
	<b>CONOCIMIENTO O APARIENCIA: EL ESTATUTO EPISTÉMICO DE LA INTELIGENCIA ARTIFICIAL GENERATIVA.....</b>	<b>312</b>
	<a href="#">Tomás Peralta Palazón</a>	
<b>19.</b>		
	<b>ENTRE EL PROMPT Y EL DISEÑO: EXPERIENCIAS DE CO-CREACIÓN CRÍTICA HUMANO-INTELIGENCIA ARTIFICIAL EN EDUCACIÓN SUPERIOR.....</b>	<b>325</b>
	<a href="#">Juan Carlos Lobato-Valdespino y Claudia Margarita García Paulín</a>	
<b>20.</b>		
	<b>APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL EN LA GESTIÓN ADMINISTRATIVA DE LAS MICRO, PEQUEÑAS Y MEDIANAS EMPRESAS DEL SECTOR DE LA CONSTRUCCIÓN .....</b>	<b>343</b>
	<a href="#">Elizabeth Vanessa Teniente Gasca, Octavio Reyes López y Christian Paulina Mendoza Torres</a>	
<b>21.</b>		
	<b>MODELOS Y APLICACIONES DE MACHINE LEARNING EN LA ESTRATIFICACIÓN DE RIESGO CLÍNICO.....</b>	<b>359</b>
	<a href="#">Julia Dolores Toscano Garibay</a>	
<b>22.</b>		
	<b>ENTRE PRINCIPIOS Y PRÁCTICA: REVISIÓN DE MARCOS REGULATORIOS Y ÉTICOS SOBRE INTELIGENCIA ARTIFICIAL EN LA INVESTIGACIÓN CIENTÍFICA .....</b>	<b>374</b>
	<a href="#">Miguel Ángel Medina Romero, Tania Haidée Torres Chávez y Rodrigo Ochoa Figueroa</a>	
<b>23.</b>		
	<b>INTELIGENCIA ARTIFICIAL EN EL PROCESO DE INVESTIGACIÓN CIENTÍFICA: USOS, EXPERIENCIAS Y LIMITACIONES.....</b>	<b>389</b>
	<a href="#">Emma Patricia Mercado-López y Clara Rosalva Mercado-López</a>	

<b>24.</b>	
LA MEDIACIÓN EPISTÉMICA DE LA INTELIGENCIA ARTIFICIAL GENERATIVA EN LA CIENCIA CONTEMPORÁNEA.....	<b>406</b>
<a href="#">Andrés Valencia Sánchez y José Cristóbal Solís Pollorena</a>	
<b>25.</b>	
ANÁLISIS DOCUMENTAL DE LA ADOPCIÓN Y HUMANIZACIÓN DE ASISTENTES DIGITALES BASADOS EN INTELIGENCIA ARTIFICIAL .....	<b>422</b>
<a href="#">Karina Guadalupe Cortina Calderón, Nallely Guadalupe Hernández Hernández y Mónica Lorena Sánchez Limón</a>	
<b>26.</b>	
DEL ANDAMIAJE CON INTELIGENCIA ARTIFICIAL A LA AUTONOMÍA: EVALUACIÓN DE CÓDIGO ESTADÍSTICO EN INGENIERÍA .....	<b>442</b>
<a href="#">Francisco Antonio Torres-Espriú, Itzia Nallely Guzmán Mejía, Francisco Guadalupe Avenidaño Esparza y Mario Alberto Domínguez-Rovira</a>	



**21.**

**MODELOS Y APLICACIONES DE MACHINE  
LEARNING EN LA ESTRATIFICACIÓN DE RIESGO  
CLÍNICO**

**JULIA DOLORES TOSCANO GARIBAY**

HOSPITAL REGIONAL DE ALTA ESPECIALIDAD DE IXTAPALUCA IMSS-BIENESTAR, MÉXICO

ORCID: 0000-0001-5858-2814

---

# 21.

## MODELOS Y APLICACIONES DEL MACHINE LEARNING EN LA ESTRATIFICACIÓN DE RIESGO CLÍNICO

### INTRODUCCIÓN

Los sistemas de salud a nivel mundial enfrentan retos derivados de la complejidad clínica en poblaciones cambiantes, los cuales demandan estrategias de priorización para optimizar la gestión de recursos (Rajkomar et al., 2019; Topol, 2019). Esta priorización, entendida como la capacidad de identificar proactivamente a los pacientes que más se beneficiarán de una atención personalizada, permite mejorar tiempos de respuesta, flujos de trabajo clínicos y asignaciones de personal, siendo aplicable en contextos tan distintos como el Servicio Nacional de Salud (NHS, por sus siglas en inglés) del Reino Unido, el sistema *Medicare* de Estados Unidos o redes de atención primaria en América Latina (Sendak et al., 2021; OECD, 2025). La inteligencia artificial (IA) y, en particular, el machine learning (ML) emergen actualmente como herramientas para analizar grandes volúmenes de datos clínicos y generar perfiles predictivos de pacientes que podrían guiar decisiones clínicas informadas y centradas en la persona (Davenport y Kalakota, 2019; Obermeyer et al., 2019).

La Organización Mundial de la Salud (WHO, por sus siglas en inglés) estima que 1,600 millones de personas en el mundo padecen multimorbilidad, incrementando la demanda de servicios incluso en contextos de alto ingreso, donde la Organización para la Cooperación y el Desarrollo Económicos (OCDE) documenta listas de espera superiores a 18 semanas en el NHS británico y demoras en atención especializada que superan los tres meses en Australia (OECD, 2025; WHO, 2025). Los *scores* tradicionales de estratificación clínica como *APACHE*, *SOFA* o *NEWS* tienen limitaciones al depender de un número reducido de variables y capturar solo interacciones lineales (Futoma et al., 2018; Sendak et al., 2021). El ML aborda estas limitaciones mediante algoritmos que aprenden patrones complejos directamente de los datos, con capacidad de procesamiento en tiempo real y de incorporar diversas fuentes de información (Choudhury et al., 2023; Wiens et al., 2019). Estudios con conjuntos de datos de hasta 42.9 millones de admisiones han demostrado que modelos

de ML alcanzan alta eficiencia ( $AUC > 0.89$ ) en predicción de mortalidad intrahospitalaria (Rajkomar et al., 2018), y aplicaciones de aprendizaje por refuerzo han logrado mejoras del 17% en el pronóstico de demanda clínica (Schäfer et al., 2023).

El propósito de este capítulo es ofrecer una revisión conceptual de algunos modelos de ML aplicados en salud, con énfasis en su aplicabilidad universal en sistemas sanitarios de diversa escala y contexto. Se definen los fundamentos conceptuales de la IA y el ML, se describe la taxonomía, los principales tipos de modelos, se muestra su alcance documentado en investigación biomédica global y se exploran algunas aplicaciones en la estratificación de riesgo y priorización clínica.

## CONCEPTOS FUNDAMENTALES

### INTELIGENCIA ARTIFICIAL COMO SIMULACIÓN DE PROCESOS COGNITIVOS

La denominación *inteligencia artificial* fue acuñada formalmente en 1956 como la ciencia de construir máquinas capaces de emular comportamientos propios del razonamiento humano (Russell y Norvig, 2021). La IA abarca técnicas como el procesamiento del lenguaje natural, la visión artificial, los sistemas expertos y el ML (Davenport y Kalakota, 2019). En salud, su historia revela un movimiento desde sistemas expertos basados en reglas —como *MYCIN* en los años 70s— hasta modelos actuales de aprendizaje profundo capaces de detectar melanoma o interpretar electrocardiogramas con alta precisión (Esteva et al., 2017; Rajpurkar et al., 2022). La IA no reemplaza el juicio clínico, sino que lo amplifica, ofreciendo capacidad de procesamiento que aumenta el conocimiento individual (Topol, 2019).

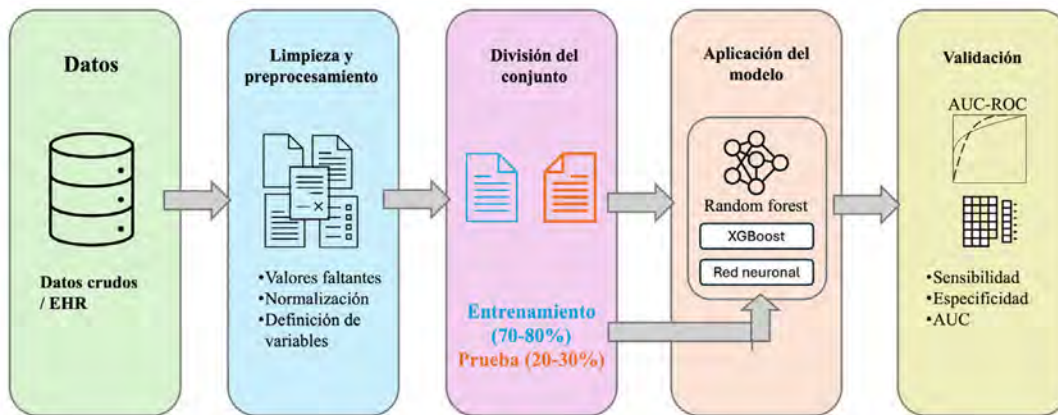
### MACHINE LEARNING: INTELIGENCIA ARTIFICIAL BASADA EN APRENDIZAJE DE DATOS

El ML constituye una parte de la IA con uno de los más altos impactos en investigación biomédica, y se define como el conjunto de algoritmos computacionales que mejoran el desempeño en tareas específicas mediante la exposición reiterativa a datos, con lo cual no se requiere la programación explícita de reglas para cada caso particular (Beam y Kohane, 2018; Deo, 2015). A diferencia de los sistemas expertos clásicos, un modelo de ML extrae automáticamente las relaciones estadísticas relevantes de un conjunto de datos de entrenamiento, generando representaciones internas que le permiten generalizar a casos no vistos previamente (conjunto de prueba) (Obermeyer y Emanuel, 2016; Choudhury et al., 2023). Un flujo de trabajo típico en las técnicas de ML se muestra en la Figura 1. Los datos crudos son

organizados, normalizados y divididos para la generación del modelo matemático. Cuando este último es aplicado al subconjunto de prueba, los resultados muestran patrones predictivos aplicables a otras poblaciones. Esta capacidad de aprendizaje inductivo es lo que confiere al ML su flexibilidad para abordar problemas clínicos de alta complejidad, donde las interacciones entre variables son no lineales y multidimensionales (Saria et al., 2019).

**Figura 1**

*Flujo de trabajo del machine learning: del dato crudo a la validación del modelo*



*Nota.* Elaboración propia con asistencia de inteligencia artificial (Perplexity AI, 2026).

Es fundamental distinguir el ML de los métodos estadísticos tradicionales. Mientras que la estadística inferencial busca cuantificar relaciones entre variables para formular conclusiones causales, el ML se orienta principalmente hacia la maximización de la precisión predictiva, aceptando modelos de alta complejidad no lineal (Steyerberg et al., 2019; Saria et al., 2019).

La taxonomía del ML se organiza en tres tipos de aprendizaje. El aprendizaje supervisado entrena algoritmos sobre datos etiquetados —con una variable de resultado conocida— para tareas de clasificación y regresión. El aprendizaje no supervisado trabaja sobre datos sin etiquetas para descubrir estructuras latentes como agrupamientos, útil para la caracterización clínica de los pacientes (fenotipado). El aprendizaje por refuerzo opera mediante un agente que interactúa con un entorno y aprende a seleccionar acciones que maximizan una recompensa acumulada, aplicable a problemas de optimización secuencial (Gottesman et al., 2019; Petch et al., 2022).

---

## TAXONOMÍA DE MODELOS DE MACHINE LEARNING

### MODELOS SUPERVISADOS

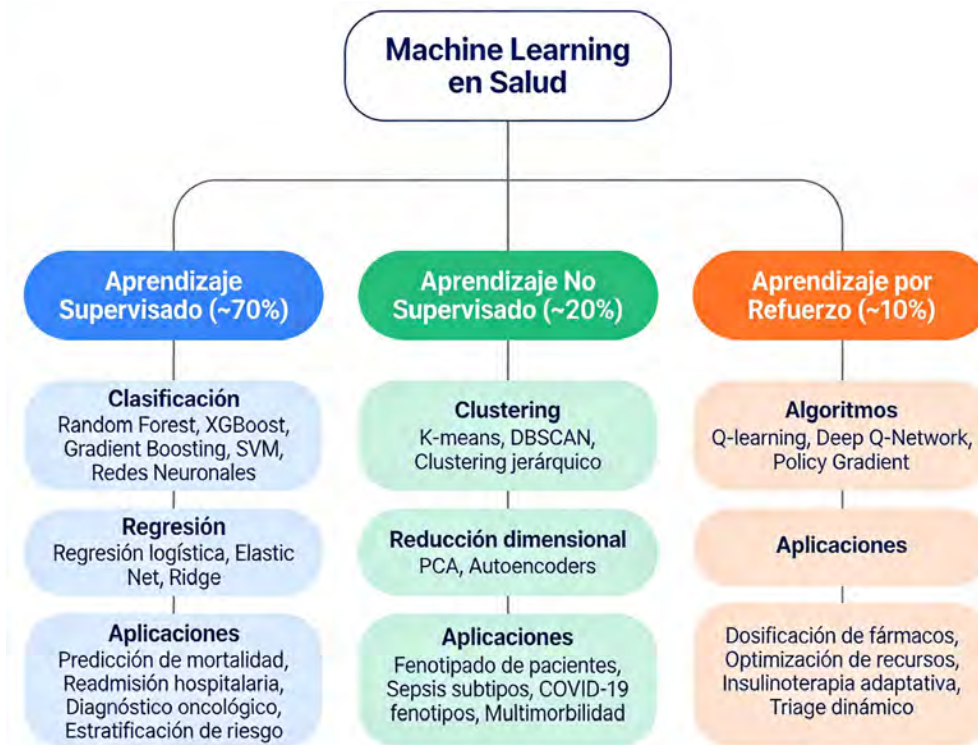
Los modelos de aprendizaje supervisado aprenden una función que rastrea la relación entre variables de entrada (características del paciente) y una variable de salida previamente etiquetada, como por ejemplo, la probabilidad de readmisión o el riesgo de mortalidad (Deo, 2015; Beam y Kohane, 2018). La Figura 2 muestra una síntesis de la taxonomía general de los modelos ML que serán descritos a continuación. La regresión logística ha sido el estándar de referencia por su interpretabilidad mediante cocientes de momios, pero el supuesto de linealidad inherente a este algoritmo limita su capacidad para capturar interacciones complejas (Saria et al., 2019). Los árboles de decisión superan esta limitación al dividir características de manera recursiva y no lineal, generando reglas visualmente interpretables, aunque son propensos al denominado sobreajuste (Deo, 2015). Las máquinas de vectores de soporte (SVM) trazan la frontera matemática más eficiente para separar categorías clínicas, con capacidad de operar con datos complejos y multivariantes (Petch et al., 2022). Los métodos de ensamble constituyen el estado del arte en predicción sobre datos tabulares: el random forest agrega predicciones de múltiples árboles reduciendo la varianza, mientras que gradient boosting y XGBoost entrenan secuencialmente árboles que corrigen errores del árbol anterior, logrando AUC sostenidos superiores a 0.90 en predicción de mortalidad y falla renal aguda (Molina et al., 2023; Rashid et al., 2023).

### MODELOS NO SUPERVISADOS

Los algoritmos de aprendizaje no supervisado operan sobre datos sin etiquetas y descubren estructuras internas como agrupamientos, útiles para el fenotipado de pacientes: identificar subgrupos con patrones similares de comorbilidades, utilización de servicios o respuesta a tratamientos (Obermeyer et al., 2019; Loftus et al., 2022). El algoritmo K-means es el método de clustering más utilizado, que divide el conjunto en k grupos cuya formación minimiza la varianza intragrupo. Su aplicación en pacientes con COVID-19 identificó cinco fenotipos clínicamente distintos con diferencias significativas en mortalidad y respuesta a ventilación mecánica (Palomar-Lever et al., 2021). El análisis de componentes principales (PCA) y otros métodos como t-SNE y UMAP condensan cientos de variables clínicas en sus componentes esenciales, conservando las semejanzas entre pacientes y haciendo manejable su agrupación, facilitando la visualización y el mejoramiento del rendimiento de modelos predictivos subsecuentes (Beam & Kohane, 2018).

**Figura 2**

*Taxonomía de algoritmos de machine learning y sus aplicaciones en salud*



Nota. Elaboración propia con asistencia de inteligencia artificial (Perplexity AI, 2026).

### APRENDIZAJE POR REFUERZO

El aprendizaje por refuerzo (AR) difiere de los enfoques supervisados y no supervisados: un agente aprende mediante la interacción iterativa con un entorno dinámico, tomando acciones que generan recompensas y ajustando su política de decisión para maximizar la recompensa acumulada a lo largo del tiempo (Gottesman et al., 2019; Petch et al., 2022). Esta arquitectura resulta adecuada para problemas clínicos de decisión secuencial, como la titulación de vasopresores en sepsis o la dosificación de heparina en anticoagulación. Políticas de manejo de líquidos y vasopresores generadas mediante AR para pacientes con sepsis redujeron la mortalidad relativa en 10.23% frente a la práctica clínica estándar en estudios retrospectivos a gran escala (Gottesman et al., 2019). Por otro lado, el aprendizaje semisupervisado combina datos etiquetados y no etiquetados para mejorar el rendimiento cuando el etiquetado es costoso, especialmente relevante en medicina donde la anotación por expertos es limitada.

## DEEP LEARNING E HÍBRIDOS

El *deep learning* (DL) se distingue por el uso de redes neuronales artificiales con múltiples capas capaces de extraer automáticamente características de alta abstracción a partir de datos no estructurados como imágenes, señales temporales y texto clínico (Rajpurkar et al., 2022; Topol, 2019). Las arquitecturas más relevantes de DL incluyen las redes neuronales convolucionales (CNN) en análisis de imágenes médicas con exactitudes de 95-98%, las redes neuronales recurrentes (RNN/LSTM) para series temporales de signos vitales, y los transformers en procesamiento del lenguaje natural aplicado a notas clínicas (Jiang et al., 2024). Los modelos de lenguaje de gran escala (LLM) como *GPT-4* y *Med-PaLM 2* han demostrado capacidad para responder preguntas médicas complejas y asistir en diagnóstico diferencial, con implicaciones para automatizar el procesamiento de información no estructurada (Jiang et al., 2024). Los modelos híbridos combinan dos o más paradigmas de ML para capitalizar las fortalezas de cada enfoque, como ensambles de redes neuronales con SVM o XGBoost con regresión de Cox, superando en capacidad predictiva a cada componente por separado (Molina et al., 2023).

## EJEMPLOS DE APLICACIONES EN SALUD DEL MACHINE LEARNING

La transición desde la investigación hacia el entorno clínico ha consolidado al ML como una herramienta útil en prácticamente todas las especialidades médicas. La magnitud y diversidad de esta producción científica —que comprende miles de publicaciones, revisiones sistemáticas y meta-análisis durante la última década— exige una lectura organizada que permita comprender cuántos y cuáles tipos de modelos han sido efectivamente aplicados en salud, en qué proporciones se distribuyen entre los tipos de aprendizaje, y qué dominios clínicos han concentrado el mayor volumen de investigación y evidencia de resultados (Choudhury et al., 2023; Rajpurkar et al., 2022).

La Tabla 1 sintetiza la distribución de aplicaciones de ML en salud por tipo de aprendizaje. Los modelos supervisados representan aproximadamente el 70% de los estudios, concentrándose en tareas de predicción clínica donde una variable de resultado conocida —mortalidad, readmisión, diagnóstico— sirve como señal de supervisión para el entrenamiento algorítmico. Los modelos no supervisados, que representan el 20%, se aplican al fenotipado computacional: la identificación de subgrupos de pacientes con perfiles similares sin criterios diagnósticos predefinidos, revelando heterogeneidades clínicas con implicaciones para la personalización del tratamiento. El aprendizaje por refuerzo, con el 10% de las

aplicaciones, se especializa en optimización de decisiones secuenciales en entornos dinámicos, como la dosificación adaptativa de fármacos o la gestión de recursos hospitalarios.

**Tabla 1**

*Distribución de aplicaciones de machine learning en salud según tipo de aprendizaje*

Aprendizaje	Proporción	Algoritmos representativos	Aplicaciones clínicas documentadas	Evidencia clave
Supervisado	~70%	Random Forest, XGBoost, Gradient Boosting, Redes neuronales, SVM	Predicción de mortalidad (AUC 0.86), readmisión hospitalaria, diagnóstico oncológico, estratificación de riesgo cardiovascular	Delpino et al. (2025); Rashid et al. (2023); Ghasemi et al. (2025)
No supervisado	~20%	K-means, DBSCAN, Clustering jerárquico, PCA, Autoencoders	Fenotipado de sepsis (2-5 subtipos), fenotipos COVID-19 (mortalidad 0%-10.6%), farmacofenotipos en UCI, trasplante renal	Nalinthasnai et al. (2025); Li et al. (2025); Sikora et al. (2023)
Aprendizaje por refuerzo	~10%	Q-learning, Deep Q-Network, Policy Gradient	Dosificación de vasopresores/ antibióticos, insulino terapia adaptativa (TIR superior), radioterapia adaptativa, gestión de camas	Coronato et al. (2020); Nambiar et al. (2024); Schäfer et al. (2023)

*Nota.* Elaboración propia con base en revisiones sistemáticas citadas. TIR = tiempo en rango glucémico; AUC = área bajo la curva ROC; UCI = unidad de cuidados intensivos.

## MACHINE LEARNING PARA PERFILES ESPECÍFICOS Y PRIORIZACIÓN

La literatura acumulada durante la última década evidencia que los modelos de ML no solo predicen eventos clínicos con mayor precisión que los métodos convencionales, sino que estructuran la información disponible en los registros electrónicos de salud de manera que permite identificar, antes de que se manifieste el deterioro clínico, qué pacientes requieren

mayor intensidad de atención, seguimiento proactivo, o derivación prioritaria a servicios especializados (Sendak et al., 2021; Rajpurkar et al., 2022). Esta capacidad de anticipación fundamenta su valor en cuatro grandes aplicaciones de priorización que se sintetizaron en la Tabla 2: estratificación de riesgo, apoyo al triage en urgencias, predicción de alta demanda y la integración operativa en sistemas clínicos de apoyo a la decisión en tiempo real.

La estratificación de riesgo mediante ML asigna a cada paciente una puntuación a partir de múltiples variables clínicas, administrativas y sociodemográficas, capturando interacciones no lineales que los scores tradicionales no pueden modelar. El triage en urgencias se transforma de un proceso binario basado en síntomas a uno continuo de estimación de riesgo individualizado, con modelos como eCART superando consistentemente a los scores convencionales. La predicción de alta demanda anticipa picos en el volumen de pacientes, ocupación de camas y consumo de recursos, permitiendo medidas preventivas como redistribución de personal o habilitación de capacidad adicional. Finalmente, la integración operativa en sistemas clínicos constituye el mayor desafío traslacional: solo el 5% de los modelos de ML desarrollados alcanzan implementación clínica real, evidenciando una brecha profunda entre investigación y adopción práctica (Choudhury et al., 2023; Preti et al., 2024).

**Tabla 2**

*Aplicaciones de machine learning para priorización clínica y gestión de recursos en salud*

<b>Aplicación</b>	<b>Función principal</b>	<b>Modelos de mayor rendimiento</b>	<b>Resultados documentados</b>	<b>Desafíos</b>
Estratificación de riesgo	Asignar puntuación de riesgo individual para orientar seguimiento e intervención preventiva	Gradient Boosting (RMSE 1.48, $R^2=0.81$ ), Random Forest, Redes neuronales	Exactitud 78.39% vs. 47.70% del score LACE+; reducción del 48% en readmisiones con modelo Re-Admit	Brecha traslacional: solo 5% de modelos alcanza implementación clínica
Triage y urgencias	Estimar riesgo de deterioro en tiempo real para priorizar atención en urgencias	eCART (Gradient Boosting), BioClinicalBERT (NLP), XGBoost	SERP superó a NEWS, MEWS y MEWS2; precisión 0.92 con notas de triage vs. 0.12 para NEWS	Variabilidad en rendimiento entre poblaciones; riesgo de sobreconfianza
Predicción de alta demanda	Anticipar volumen de pacientes, ocupación de camas y consumo de recursos	XGBoost, LSTM, SVM-kernel (K-SVR)	MAPE 8.1% en ocupación hospitalaria; superioridad sobre ARIMA en patrones estacionales	Dependencia de datos históricos de calidad; variabilidad contextual

**Tabla 2***Aplicaciones de machine learning para priorización clínica y gestión de recursos en salud*

Aplicación	Función principal	Modelos de mayor rendimiento	Resultados documentados	Desafíos
Integración en sistemas clínicos	Operacionalizar modelos predictivos dentro del flujo de trabajo clínico del EHR	CDSS basados en HL7 FHIR; módulos no interruptivos	Mayor impacto clínico cuando integrado en EHR vs. herramienta externa	Interoperabilidad limitada; ausencia de marcos regulatorios nacionales

*Nota.* EHR = historia clínica electrónica; NLP = procesamiento de lenguaje natural; MAPE = error absoluto porcentual medio; CDSS = sistema de apoyo a la decisión clínica. Choudhury et al. (2023); Preti et al. (2024); Watson et al. (2024).

## DISCUSIÓN Y CONCLUSIONES

El recorrido de conceptos realizado a lo largo de este capítulo permite afirmar que el machine learning representa un cambio cualitativo sustancial en la capacidad de los sistemas de salud para comprender, anticipar y responder a las necesidades de sus poblaciones. La revisión de la taxonomía y las aplicaciones documentadas evidencia que esta transformación no es un horizonte tecnológico lejano, sino una realidad operativa en progreso, con múltiples modelos validados, herramientas integradas en flujos de trabajo clínico real y resultados reproducibles en múltiples contextos geográficos e institucionales (Choudhury et al., 2023; Rajpurkar et al., 2022).

### RETOS PENDIENTES: INTERPRETABILIDAD, EQUIDAD Y MARCO NORMATIVO

La interpretabilidad de los algoritmos constituye un reto central cuando se busca adoptar ML en entornos donde la justificación de decisiones clínicas es esencial para su aceptación por el profesional de la salud y el afianzamiento de la confianza del paciente (Saleem et al., 2025). Por ejemplo, aunque los modelos de ensamble y las redes neuronales profundas superan en precisión a la regresión logística, su opacidad técnica dificulta entender por qué un paciente es clasificado como de alto riesgo. Técnicas como SHAP (SHapley Additive exPlanations) y LIME (Local Interpretable Model-agnostic Explanations) emergieron entonces para generar explicaciones post-hoc de tales modelos complejos. Saleem et al. (2025) mostraron en su estudio aplicando SHAP a un modelo de gradient boosting para predicción de readmisión hospitalaria que las variables más influyentes fueron

el número de diagnósticos previos, la duración de la estancia y el nivel de albúmina sérica, información que resultó accionable para el equipo clínico al diseñar intervenciones preventivas específicas. Por lo cual, esta aproximación debe ser generalizada en las aplicaciones de las técnicas de ML.

El sesgo algorítmico representa otro obstáculo ético de primera magnitud, documentado en el estudio seminal de Obermeyer et al. (2019), que demostró que un modelo comercial de predicción de riesgo ampliamente utilizado en hospitales estadounidenses subestimaba sistemáticamente la necesidad de atención de pacientes afroamericanos, quienes a igual puntuación de riesgo que pacientes blancos presentaban mayor carga de enfermedad crónica no reconocida. Este sesgo derivaba del uso del costo de atención como *proxy* de necesidad de atención, una decisión de diseño que perpetúa desigualdades estructurales preexistentes (Obermeyer et al., 2019). La equidad algorítmica en consecuencia requiere auditorías sistemáticas del rendimiento desagregado por subgrupos vulnerables, el uso de métricas de equidad durante el desarrollo y validación, y la participación de comunidades afectadas en el diseño de sistemas (Norgeot et al., 2019).

El marco regulatorio de modelos de ML en salud demanda una gestión normativa clara que equilibre la innovación con la protección de los pacientes. La actualización continua de modelos para mantener su rendimiento ante cambios epidemiológicos (*concept drift*) requiere procesos de validación prospectiva continua, que son costosos y logísticamente complejos (Wiens et al., 2019). La interoperabilidad entre sistemas de información hospitalaria heterogéneos y la ausencia de estándares unificados de documentación de modelos de ML dificultan la transferibilidad de herramientas entre instituciones (Lee et al., 2022). Finalmente, la educación de profesionales de la salud en competencias de alfabetización digital y pensamiento crítico sobre las salidas de modelos de ML es indispensable para una integración responsable que preserve la autonomía clínica y la centralidad del paciente (Topol, 2019).

Sin embargo, el machine learning representa una de las herramientas más promisorias para transformar la investigación en salud, con aplicaciones documentadas que mejoran tanto la precisión clínica como la eficiencia operativa de los sistemas sanitarios. Lo que resta no es demostrar su utilidad, sino construir los andamiajes éticos, regulatorios e institucionales que permitan que esa utilidad llegue con equidad a todos los pacientes. Su consolidación como práctica estándar exige resolver los desafíos estructurales mencionados anteriormente que limitan aún su transferibilidad a entornos clínicos reales. Avanzar en ambas dimensiones —técnica e institucional— es la condición necesaria para que el ML cumpla su promesa de

una medicina más precisa, equitativa y centrada en la persona. El camino está trazado; el reto es recorrerlo con responsabilidad.

## REFERENCIAS

- Beam, A. L., & Kohane, I. S. (2018). Big data and machine learning in health care. *Annual Review of Medicine*, 69, 153-161. <https://doi.org/10.1146/annurev-med-050516-033destress>
- Choudhury, A., Asan, O., & Hu, Q. (2023). Systematic reviews of machine learning in healthcare: A literature review. *Journal of Medical Internet Research*, 25, e46089. <https://doi.org/10.2196/46089>
- Coronato, A., Naeem, M., De Pietro, G., & Paragliola, G. (2020). Reinforcement learning for intelligent healthcare applications: A survey. *Artificial Intelligence in Medicine*, 109, 101964. <https://doi.org/10.1016/j.artmed.2020.101964>
- Davenport, T. y Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future Healthcare Journal*, 6(2), 94-98. <https://doi.org/10.7861/futurehosp.6-2-94>
- Delpino, F. M., Flores, T. R., Portela, M. A. P., Hartwig, F. P., Menezes, A. M. B., Barcelos, R. K., & Thumé, E. (2025). Global performance of machine learning models to predict all-cause mortality. *Scientific Reports*, 15(1), 10381. <https://doi.org/10.1038/s41598-025-94576-5>
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920-1930. <https://doi.org/10.1161/CIRCULATIONAHA.115.001593>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://doi.org/10.1038/nature21056>
- Futoma, J., Hariharan, S., & Heller, K. (2018). Learning to detect sepsis with a multitask Gaussian process RNN classifier. *JAMIA Open*, 1(1), 77-85. <https://doi.org/10.1093/jamiaopen/ooy014>
- Ghasemi, N., Haghghi, M. S., Dehghani, S., & Baradaran, H. R. (2025). Artificial intelligence in breast cancer survival prediction: A comprehensive systematic review and meta-analysis. *Frontiers in Oncology*, 14, 1420328. <https://doi.org/10.3389/fonc.2024.1420328>
- Gottesman, O., Johansson, F., Komorowski, M., Faisal, A., Sontag, D., Doshi-Velez, F., & Celi, L. A. (2019). Guidelines for reinforcement learning in healthcare. *Nature Medicine*, 25(1), 16-18. <https://doi.org/10.1038/s41591-018-0310-5>
- Jiang, L. Y., Liu, X. C., Nejatian, N. P., Nasir-Moin, M., Wang, D., Abidin, A., Eaton, K., Riina, H. A., Laufer, I., Punjabi, P., Miceli, M., Kim, N. J., Orillac, C., Zanos, P., Kennigsberg, E., Costa, A. B., Mirhaji, P., Fattah, M., Moll, M. K. ... Narayan, J. (2024). Health system-scale language models are all-purpose prediction engines. *Nature*, 631(8020), 357-365. <https://doi.org/10.1038/s41586-024-07603-2>

- Lee, S., Lee, S. H., & Kim, N. (2022). Development of an interoperable and easily transferable clinical decision support system deployment platform: System design and development study. *Journal of Medical Internet Research*, 24(7), e37214. <https://doi.org/10.2196/37214>
- Li, N., Sheng, B., Mao, Y., Li, T., Chen, J., Xu, Y., & Li, C. (2025). Unsupervised clustering for sepsis identification in large-scale epidemiologic surveillance data. *Intensive Care Medicine Experimental*, 13(1), 24. <https://doi.org/10.1186/s40635-025-00726-2>
- Loftus, T. J., Shickel, B., Balch, J. A., Upchurch, G. R. y Bihorac, A. (2022). Phenotype clustering in health care: A narrative review of methods and applications. *npj Digital Medicine*, 5(1), 105. <https://doi.org/10.1038/s41746-022-00648-9>
- Molina, A., Puig-Domingo, M., Lecube, A., Simó-Servat, O., & Ciudin, A. (2023). Development and validation of an XGBoost-algorithm-powered survival model for predicting in-hospital mortality based on 545,388 isolated severe traumatic brain injury patients from the TQIP database. *Frontiers in Neurology*, 14, 1246886. <https://doi.org/10.3389/fneur.2023.1246886>
- Nalinthasnai, N., Sirilert, S., & Tongsong, T. (2025). Unsupervised machine learning clustering approach for phenotyping and clinical outcomes in patients with severe COVID-19. *Frontiers in Medicine*, 12, 1543279. <https://doi.org/10.3389/fmed.2025.1543279>
- Nambiar, M., Wilson, B. M., Bhatt, D. L., & Pfeifer, J. M. (2024). Reinforcement learning in healthcare: Applications for personalized treatment planning and clinical decision support. *Journal of Artificial Intelligence and Machine Learning*, 1(1), 10. <https://doi.org/10.46965/jaim.1.1.10>
- Norgeot, B., Glicksberg, B. S., & Butte, A. J. (2019). A call for deep-learning healthcare. *Nature Medicine*, 25(1), 14-15. <https://doi.org/10.1038/s41591-018-0320-3>
- Obermeyer, Z., & Emanuel, E. J. (2016). Predicting the future: Big data, machine learning, and clinical medicine. *New England Journal of Medicine*, 375(13), 1216-1219. <https://doi.org/10.1056/NEJMp1606181>
- Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447-453. <https://doi.org/10.1126/science.aax2342>
- OECD. (2025). *The future of health systems*. OECD. <https://www.oecd.org/en/topics/policy-issues/the-future-of-health-systems.html>
- Palomar-Lever, A., García-Gutiérrez, S., Prieto, D., González-García, B., Cruz-Gómez, A. J., & Merino, J. (2021). Deploying unsupervised clustering analysis to derive clinical phenotypes and risk factors associated with mortality risk in 2022 critically ill COVID-19 patients in Spain. *Critical Care*, 25(1), 63. <https://doi.org/10.1186/s13054-021-03487-8>

- Petch, J., Di, S., & Nelson, W. (2022). Opening the black box: The promise and limitations of explainable machine learning in cardiology. *Canadian Journal of Cardiology*, 38(2), 204-213. <https://doi.org/10.1016/j.cjca.2021.09.004>
- Preti, L. M., Elkin, P. L., Topaz, M., & Sridharan, S. (2024). Implementation of machine learning applications in health care settings: Systematic review. *Journal of Medical Internet Research*, 26, e55897. <https://doi.org/10.2196/55897>
- Rajkomar, A., Oren, E., Chen, K., Dai, A. M., Hajaj, N., Hardt, M., Liu, P. J., Liu, X., Marcus, J., Sun, M., Sundberg, P., Yee, H., Zhang, K., Zhang, Y., Flores, G., Duggan, G. E., Irvine, J., Le, Q., Litsch, K., ... Dean, J. (2018). Scalable and accurate deep learning with electronic health records. *npj Digital Medicine*, 1, 18. <https://doi.org/10.1038/s41746-018-0029-1>
- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347-1358. <https://doi.org/10.1056/NEJMra1814259>
- Rajpurkar, P., Chen, E., Banerjee, O., & Topol, E. J. (2022). AI in health and medicine. *Nature Medicine*, 28(1), 31-38. <https://doi.org/10.1038/s41591-021-01614-0>
- Rashid, M. M., Liu, J., & Yi, C. (2023). Machine learning based readmission and mortality prediction in heart failure patients. *Scientific Reports*, 13(1), 18476. <https://doi.org/10.1038/s41598-023-45893-0>
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4.<sup>a</sup> ed.). Pearson.
- Saleem, J. A., Siek, K. A., Shabbir, S. A., & Garg, V. (2025). Comparison of SHAP and clinician friendly explanations reveals effects on clinical decision behaviour. *npj Digital Medicine*, 8(1), 467. <https://doi.org/10.1038/s41746-025-01467-y>
- Saria, S., Butte, A., & Sheikh, A. (2019). Better medicine through machine learning: What's real, and what's artificial? *PLOS Medicine*, 15(12), e1002721. <https://doi.org/10.1371/journal.pmed.1002721>
- Schäfer, F., Schiffer, M., & Walther, G. (2023). Data-driven hospital staff and resources allocation using agent-based simulation and deep reinforcement learning. *Engineering Applications of Artificial Intelligence*, 126, 107097. <https://doi.org/10.1016/j.engappai.2023.107097>
- Sendak, M. P., Elish, M. C., Gao, M., Futoma, J., Ratliff, W., Nichols, M., Bedoya, A., Balu, S., & O'Brien, C. (2021). Machine learning for patient risk stratification: Standing on, or looking over, the shoulders of clinicians? *npj Digital Medicine*, 4(1), 56. <https://doi.org/10.1038/s41746-021-00426-3>
- Sikora, A., Zimmerman, L., Mueller, S. W., Bhatt, D. L., & Rech, M. A. (2023). Cluster analysis driven by unsupervised latent feature learning of ICU medications. *Scientific Reports*, 13(1), 15612. <https://doi.org/10.1038/s41598-023-42617-y>

- 
- Steyerberg, E. W., Moons, K. G. M., van der Windt, D. A., Hayden, J. A., Perel, P., Schroter, S., Riley, R. D., Hemingway, H., & Altman, D. G. (2019). Prognosis research strategy (PROGRESS) 3: Prognostic model research. *PLOS Medicine*, *10*(2), e1001381. <https://doi.org/10.1371/journal.pmed.1001381>
- Tariku, M. F., Kuru, K., & Okolo, C. (2025). Predicting total healthcare demand using machine learning: Separate and combined analysis of predisposing, enabling, and need factors. *BMC Health Services Research*, *25*(1), 401. <https://doi.org/10.1186/s12913-025-12588-x>
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, *25*(1), 44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- Watson, M., Ireland, G., Stirling, A., Lawrenson, P., Chuter, A., Dobie, G., Dent, J., & Mair, F. S. (2024). Performance of machine learning versus the National Early Warning Score for predicting patient deterioration risk: A single-site study of emergency admissions. *BMJ Open*, *14*(12), e085211. <https://doi.org/10.1136/bmjopen-2024-085211>
- WHO. (2025). *Countries are already experiencing significant health system disruptions*. WHO. <https://www.who.int/news/item/10-04-2025-countries-are-already-experiencing-significant-health-system-disruptions--who>
- Wiens, J., Saria, S., Sendak, M., Ghassemi, M., Liu, V. X., Doshi-Velez, F., Jung, K., Heller, K., Kale, D., Saeed, M., Ossorio, P. N., Thadaney-Israni, S., & Goldenberg, A. (2019). Do no harm: A roadmap for responsible machine learning for health care. *npj Digital Medicine*, *2*, 138. <https://doi.org/10.1038/s41746-019-0154-8>



# INTELIGENCIA ARTIFICIAL

EXPERIENCIAS Y REFLEXIONES SOBRE LA INVESTIGACIÓN CIENTÍFICA

ISBN: 978-968-9724-25-4



9 789689 724254

Trans<sup>®</sup>  
digital  
editorial