

Transformación de la epidemiología en la era de la inteligencia artificial

Transformation of Epidemiology in the Age of Artificial Intelligence

Juan Rodrigo Gómez-Bernal^{1a}

Resumen

La epidemiología ha sido fundamental para el análisis de los problemas de salud y para la toma de decisiones en los sistemas sanitarios y la salud pública. No obstante, los métodos tradicionales de la epidemiología, diseñados fundamentalmente para identificar asociaciones causales a nivel poblacional mediante medidas de datos agrupados, presentan limitaciones inherentes para capturar la heterogeneidad individual en la respuesta ante exposiciones específicas. Esta aproximación poblacional dificulta la predicción personalizada del desenlace en un individuo particular, cuyos factores de riesgo pueden manifestarse de forma distinta al promedio grupal, particularmente cuando intervienen múltiples variables contextuales y perfiles biológicos únicos.

Los avances en inteligencia artificial han generado herramientas capaces de integrar grandes volúmenes de información, identificar patrones complejos en subgrupos específicos y elaborar estimaciones más personalizadas, transicionando desde un enfoque reactivo basado en promedios poblacionales hacia modelos predictivos centrados en trayectorias individuales. Sin embargo, estos desarrollos no sustituyen los fundamentos metodológicos de la epidemiología, ya que la identificación de exposiciones, desenlaces y relaciones causales continúa dependiendo del marco conceptual epidemiológico.

Bajo esta perspectiva, las tensiones actuales no representan una crisis disciplinaria, sino una transición hacia enfoques más amplios que combinan análisis poblacionales con herramientas predictivas avanzadas. Esta integración resulta especialmente relevante para instituciones de gran escala, como las de seguridad social, que requieren modelos capaces de aprovechar datos diversos para mejorar la comprensión de los procesos de salud y apoyar decisiones clínicas y operativas.

Abstract

Epidemiology has been fundamental for analyzing health problems and supporting decision-making in healthcare systems and public health. However, traditional epidemiological methods, designed fundamentally to identify causal associations at the population level through aggregate data measures, present inherent limitations in capturing individual heterogeneity in response to specific exposures. This population-based approach hinders personalized prediction of outcomes in a particular individual whose risk factors may manifest differently from the group average, particularly when multiple contextual variables and unique biological profiles are involved. Advances in artificial intelligence have generated tools capable of integrating large volumes of information, identifying complex patterns in specific subgroups, and producing more personalized estimates, transitioning from a reactive approach based on population averages toward predictive models centered on individual trajectories. However, these developments do not replace the methodological foundations of epidemiology, as the identification of exposures, outcomes, and causal relationships continues to depend on the epidemiological conceptual framework. From this perspective, current tensions do not represent a disciplinary crisis, but rather a transition toward broader approaches that combine population-based analyses with advanced predictive tools. This integration is particularly relevant for large-scale healthcare institutions and national health systems, which require models capable of leveraging diverse data to improve understanding of health processes and support clinical and operational decisions.

¹Universidad Nacional Autónoma de México, Unidad de Posgrados, Facultad de Medicina. Ciudad de México, México

ORCID: [0000-0002-4070-7727^a](https://orcid.org/0000-0002-4070-7727)

Palabras clave

Epidemiología
Inteligencia Artificial
Medicina de Precisión
Toma de Decisiones
Sistemas de Salud

Keywords

Epidemiology
Artificial Intelligence
Precision Medicine
Decision Making
Health Planning Organizations

Fecha de recibido: 20/11/2025

Fecha de aceptado: 14/01/2026

Comunicación con:

Juan Rodrigo Gómez Bernal

 jrgomez@comunidad.unam.mx

 56 3884 6676

Cómo citar este artículo: Gómez-Bernal JR. Transformación de la epidemiología en la era de la inteligencia artificial. Rev Med Inst Mex Seguro Soc. 2026;64(4):e7010. doi: 10.5281/zenodo.19076288

Introducción

La epidemiología ha sido una herramienta fundamental para comprender los problemas de salud y orientar las decisiones clínicas y operativas en los sistemas sanitarios. Sus métodos han permitido identificar factores de riesgo, evaluar intervenciones y establecer criterios diagnósticos ampliamente utilizados en la práctica diaria.¹ Sin embargo, en la última década la cantidad y diversidad de la información disponible en salud han aumentado de forma notable debido a la digitalización de registros clínicos, la integración de bases de datos poblacionales, la automatización de estudios de laboratorio, la sistematización de imágenes médicas y la incorporación de nuevas herramientas de seguimiento.²

Este crecimiento ha generado un volumen de datos que con frecuencia rebasa la capacidad de análisis de los métodos tradicionales. Estos métodos, utilizados durante décadas en epidemiología y salud pública, se fundamentan en el análisis de muestras poblacionales, comparaciones entre grupos y la identificación de factores de riesgo mediante medidas de asociación que permiten obtener conclusiones aplicables a poblaciones o estratos definidos.³ Aunque han sido esenciales para generar conocimiento sobre causalidad y factores de riesgo a nivel colectivo, estos enfoques enfrentan desafíos cuando el objetivo es predecir desenlaces específicos en individuos particulares, especialmente al considerar que la respuesta ante exposiciones puede variar sustancialmente según múltiples características contextuales y biológicas.

En la práctica clínica, un individuo con un factor de riesgo establecido puede tener una probabilidad de enfermedad significativamente diferente al riesgo promedio calculado para su grupo de referencia, dependiendo de interacciones complejas entre sus variables genómicas, ambientales y conductuales que los análisis poblacionales tradicionales no logran capturar de forma individual.⁴ Paralelamente, herramientas de inteligencia artificial han comenzado a ofrecer alternativas complementarias que permiten transitar desde un enfoque reactivo basado en análisis poblacionales retrospectivos hacia modelos predictivos capaces de anticipar desenlaces en individuos específicos.

Mediante la integración de grandes volúmenes de información heterogénea, estos modelos pueden identificar patrones complejos en subgrupos particulares y generar estimaciones personalizadas de riesgo. Algunos ejemplos incluyen modelos que anticipan el riesgo individual de desarrollar enfermedades crónicas considerando miles de variables clínicas simultáneamente, sistemas que apoyan la interpretación de imágenes médicas identificando patrones sutiles imperceptibles en análisis convencionales o algoritmos que analizan texto libre de historias clínicas para detectar señales tempranas de brotes epidémicos.

Estas aplicaciones muestran que la inteligencia artificial no sustituye los fundamentos causales de la epidemiología, sino que amplía su capacidad para trabajar con información compleja, transicionando desde la identificación de factores de riesgo poblacionales hacia la predicción de trayectorias individuales.⁵

La convergencia de estos enfoques ha generado la percepción de que la epidemiología podría estar enfrentando una crisis. Sin embargo, más que una competencia entre métodos, se trata de una transición hacia modelos integradores que combinan la visión poblacional con análisis más específicos. Los principios epidemiológicos siguen siendo indispensables para definir exposiciones, desenlaces y relaciones causales, mientras que la inteligencia artificial aporta herramientas para explorar dimensiones de los datos antes inaccesibles. El propósito de este artículo es analizar esta integración mediante una revisión sistemática de la literatura científica (2020–2025) y discutir cómo ambas perspectivas pueden complementarse en diferentes áreas de la epidemiología (clínica, genética, ambiental, nutricional, social y ocupacional), así como examinar sus implicaciones para responder a los retos actuales de los sistemas de seguridad social y los servicios de salud, donde la información crece más rápido que nuestra capacidad para interpretarla.

Desarrollo

La discusión sobre la relación entre la epidemiología y la inteligencia artificial ha crecido en la última década a medida que el volumen y la complejidad de los datos en salud han aumentado de manera exponencial. Este fenómeno ha dado lugar a distintas interpretaciones sobre cómo debe entenderse la integración entre ambos enfoques. En la literatura reciente pueden encontrarse diversos términos para referirse a esta convergencia.

Por un lado, se ha consolidado el concepto de epidemiología digital, enfocado en el uso de datos generados fuera del sistema sanitario tradicional.² Otros autores prefieren el término epidemiología computacional para resaltar el uso de simulaciones y modelado matemático avanzado (incorporados al *machine learning*).⁶ Asimismo, surgen definiciones como epidemiología basada en datos, que prioriza el volumen de información procesada,⁷ y epidemiología de precisión, que busca la estratificación fina del riesgo individual.⁸ Finalmente, propuestas más recientes sugieren el concepto de epidemiología aumentada por inteligencia artificial, enfatizando el rol de soporte de estas tecnologías (figura 1).⁹ Aunque estas denominaciones difieren en matices, comparten una premisa común: la epidemiología, como disciplina, está expandiendo su campo de acción desde una visión predominantemente poblacional hacia marcos de análisis

que incorporan herramientas computacionales capaces de manejar información más compleja y diversa.

Durante décadas, los estudios poblacionales —ya fueran ensayos clínicos aleatorizados, estudios de cohorte, de casos y controles o encuestas transversales— han constituido la base del conocimiento biomédico. Estos diseños continúan siendo indispensables y no pierden validez ante la llegada de nuevas tecnologías. Sin embargo, existen fenómenos que difícilmente pueden captarse a través de enfoques tradicionales como las tablas de contingencia de 2×2 o los modelos de regresión. Esto es particularmente evidente cuando se requiere integrar cientos o miles de variables heterogéneas en un solo modelo.^{7,10} Los métodos clásicos enfrentan dificultades al analizar datos longitudinales de alta resolución temporal⁸ o al intentar distinguir subgrupos biológicos sutiles que quedan ocultos bajo los promedios poblacionales habituales.⁵

En este punto resultan útiles ejemplos concretos. En el análisis de imágenes médicas, redes neuronales convolucionales como *CheXNet* —desarrollada por Stanford— han mostrado capacidad para identificar neumonía en radiografías de tórax con desempeños comparables a los de radiólogos experimentados, especialmente cuando se procesan grandes volúmenes de estudios. Desde una perspectiva epidemiológica, esta herramienta permite la vigilancia activa de enfermedades respiratorias en poblaciones extensas, identificando patrones de distribución temporal y geográfica que resultarían inviables mediante la revisión manual de imágenes.¹¹

En el plano clínico predictivo, modelos como *Deep Patient*, del Mount Sinai, han integrado miles de variables de historias clínicas electrónicas para anticipar el riesgo de hospitalización o la aparición de enfermedades crónicas varios meses antes de que sean detectables mediante

Figura 1 Marcos conceptuales para la integración entre epidemiología e inteligencia artificial



El diagrama muestra ocho aproximaciones terminológicas identificadas en la literatura científica reciente (2020-2025) que describen la convergencia entre métodos epidemiológicos tradicionales y herramientas computacionales avanzadas. Cada término representa un énfasis particular: desde la dimensión digital de los datos, hasta la precisión de las estimaciones o el papel de soporte que ofrece la IA. Aunque conceptualmente distintos, todos comparten la premisa de una epidemiología ampliada en sus capacidades analíticas

Fuente: elaboración propia

métodos convencionales. Esta capacidad predictiva resulta fundamental para la epidemiología clínica, permitiendo la identificación temprana de subgrupos de alto riesgo y la implementación de intervenciones preventivas dirigidas antes de la manifestación clínica de la enfermedad.¹²

En genómica, los modelos poligénicos de riesgo desarrollados por el Broad Institute permiten estimar la susceptibilidad individual a desarrollar diabetes tipo 2, enfermedad coronaria o ciertos tipos de cáncer, combinando millones de variantes genéticas mediante algoritmos basados en aprendizaje automático. Estos modelos transforman la epidemiología genética al posibilitar la estratificación del riesgo poblacional basada en perfiles genómicos, facilitando el diseño de programas de tamizaje personalizados y la identificación de grupos que podrían beneficiarse de intervenciones preventivas específicas.¹³

En vigilancia epidemiológica, herramientas como *BlueDot* han utilizado análisis de texto y aprendizaje no supervisado para detectar señales tempranas de brotes infecciosos, incluida la COVID-19, antes de que se emitieran reportes oficiales.¹⁴

Detección temprana de brotes epidémicos mediante inteligencia artificial

La detección temprana de brotes representa un área de especial relevancia donde la inteligencia artificial ha demostrado capacidades transformadoras. Los sistemas tradicionales de vigilancia dependen de reportes oficiales que frecuentemente presentan retrasos de días o semanas, como se documentó durante las primeras semanas de la pandemia de la COVID-19, cuando los sistemas formales tardaron en reconocer la magnitud de la transmisión comunitaria.¹⁵

En contraste, los algoritmos de procesamiento de lenguaje natural pueden monitorear en tiempo real múltiples fuentes de información no estructurada —incluyendo redes sociales, búsquedas en internet, reportes de medios de comunicación, registros de farmacias y proveedores de servicios de salud— para identificar patrones anómalos que sugieran la emergencia de un brote.^{16,17} Plataformas como *HealthMap* y *GPHIN* han demostrado capacidad para detectar señales epidémicas hasta dos semanas antes que los reportes oficiales mediante análisis automatizado de noticias en múltiples idiomas y fuentes digitales.¹⁸

Esta capacidad de integración de datos heterogéneos permite no solo detectar señales tempranas, sino también estimar la velocidad de propagación geográfica y caracterizar grupos poblacionales con mayor riesgo, facilitando respuestas de salud pública más oportunas y focalizadas.¹⁹ En

el contexto de instituciones de seguridad social que atienden grandes poblaciones distribuidas geográficamente, estos sistemas representan una herramienta valiosa para la anticipación y contención de amenazas epidemiológicas, especialmente cuando se integran con datos de consultas ambulatorias, compra de medicamentos de venta libre y ausentismo laboral, que pueden servir como indicadores sindrómicos tempranos.²⁰

Estos ejemplos ilustran que la inteligencia artificial no constituye un conjunto abstracto de “herramientas”, sino un repertorio diverso de modelos diseñados para tipos específicos de datos y preguntas concretas en salud.

Aplicaciones específicas y contrastes metodológicos

La integración de la inteligencia artificial no ocurre de manera homogénea en todas las ramas de la epidemiología. Cada subdisciplina ha adoptado estas herramientas para resolver limitaciones concretas de sus métodos clásicos, generando contrastes notables en la práctica diaria.

Epidemiología clínica

En el ámbito clínico, la predicción de riesgo ha dependido históricamente de escalas aditivas lineales, como el puntaje de Framingham para riesgo cardiovascular o el modelo APACHE en cuidados intensivos. Estas herramientas, aunque valiosas, asumen que la relación entre una variable (como la edad o la presión arterial) y el desenlace es constante y proporcional.³ Sin embargo, la fisiología humana es intrínsecamente no lineal. Aquí es donde los modelos de aprendizaje automático, como los *random forests* o las redes neuronales, han demostrado superioridad. Por ejemplo, al evaluar el riesgo de sepsis o deterioro súbito en pacientes hospitalizados, los algoritmos modernos pueden detectar interacciones complejas entre signos vitales sutilmente alterados que pasarían desapercibidos en una escala de puntuación tradicional, permitiendo alertas hasta con 48 horas de antelación frente a los métodos convencionales.²¹

Epidemiología ambiental

Tradicionalmente, la epidemiología ambiental ha estimado la exposición a contaminantes basándose en estaciones de monitoreo fijas, asumiendo que todos los individuos en un radio de kilómetros respiran el mismo aire. Esta aproximación ignora la microvariabilidad urbana.²² Mediante el uso de inteligencia artificial, hoy es posible integrar datos de imágenes satelitales (que miden la profundidad óptica

de aerosoles), patrones de tráfico en tiempo real y variables meteorológicas para modelar la concentración de partículas PM2.5 con una resolución de hasta 100 metros. Esto permite pasar de un modelo de “promedio de ciudad” a una estimación personalizada de la exposición (“*exposoma*”) basada en el código postal o la movilidad del individuo.²³

Epidemiología nutricional

Uno de los grandes retos en la investigación nutricional ha sido la dependencia de los cuestionarios de frecuencia de alimentos, instrumentos subjetivos propensos al sesgo de memoria y a la subestimación de la ingesta calórica. La inteligencia artificial ofrece alternativas mediante el reconocimiento de imágenes.²⁴

Aplicaciones experimentales permiten ahora que los participantes fotografíen sus platos, utilizando redes neuronales convolucionales para identificar los alimentos y estimar su volumen. Recientemente, esta tecnología se ha aplicado específicamente para validar la adherencia a guías alimentarias: mediante la evaluación de proporciones dietéticas impulsada por inteligencia artificial, es posible calcular automáticamente si la distribución de alimentos cumple con el modelo del “*plato equilibrado*”, mejorando sustancialmente tanto la precisión de la medición como la practicidad de la intervención clínica frente a la estimación visual subjetiva.¹⁹

Epidemiología genética y social

En la epidemiología genética, el desafío ha pasado de encontrar asociaciones simples (GWAS) a comprender la función. Mientras que los métodos estadísticos clásicos enfrentan dificultades para modelar la epistasis (interacción gen-gen), los modelos de aprendizaje profundo (*deep learning*) están siendo utilizados para predecir cómo variantes en regiones no codificantes del ADN afectan la expresión génica en tejidos específicos, integrando información genómica y fenotípica en modelos multimodales de alta complejidad.²⁰

Finalmente, en la epidemiología social, los métodos tradicionales como censos o encuestas transversales ofrecen una “*fotografía*” estática que a menudo llega con años de retraso. En contraste, el análisis de grandes datos (*big data*) permite estudiar determinantes dinámicos. Un ejemplo claro fue el uso de datos de movilidad anonimizados de teléfonos móviles durante la pandemia de COVID-19, que permitió a los especialistas en epidemiología medir la adherencia a las políticas de confinamiento en tiempo real y correlacionarlas con la velocidad de transmisión viral en diferentes estratos socioeconómicos, algo imposible de realizar con encuestas convencionales.²¹

Epidemiología ocupacional

En el ámbito de la salud laboral, la investigación causal y el reconocimiento de enfermedades de trabajo han dependido históricamente de estudios de casos y controles, sustentados fundamentalmente en matrices de empleo-exposición, cuestionarios autoaplicados y la opinión del experto para la calificación de riesgos. Si bien este enfoque ha sido el estándar, presenta limitaciones críticas: la subjetividad inherente a la valoración experta, el sesgo de memoria en los cuestionarios y la incapacidad de las matrices genéricas para capturar la variabilidad real de las tareas.

La inteligencia artificial, integrada con el Internet de las Cosas (*IoT*), ofrece soluciones para superar estas barreras.²² En el plano físico, el uso de sensores vestibles y visión computacional permite realizar evaluaciones ergonómicas continuas, cuantificando posturas forzadas y movimientos repetitivos con una precisión objetiva que elimina la variabilidad interobservador.^{23,24} Simultáneamente, en la psicología laboral, algoritmos de procesamiento de lenguaje natural analizan patrones de interacción digital y carga de trabajo para predecir riesgos psicosociales y *burnout* con mayor anticipación que las encuestas de clima organizacional, permitiendo transitar de una dictaminación reactiva a una prevención basada en datos en tiempo real.²⁵

Para identificar la distribución de aplicaciones de IA en epidemiología, se realizó una búsqueda sistemática en *Consensus* (<https://consensus.app>) mediante 18 consultas dirigidas sobre aplicaciones de inteligencia artificial en subdisciplinas epidemiológicas (clínica, genética, ambiental, social, nutricional y ocupacional). El proceso identificó 798 artículos, de los cuales 50 de mayor calidad (período 2020–2025) fueron seleccionados y clasificados según subdisciplina, técnica de IA y aplicación específica. La figura 2 muestra este análisis bibliométrico mediante un diagrama de Sankey, revelando mayor concentración de publicaciones en epidemiología clásica, clínica y genética, con énfasis en predicción y modelado de riesgo, mientras que las áreas ambiental, social y ocupacional muestran una incorporación más reciente.

Este panorama genera preguntas legítimas sobre el futuro de la investigación en salud. Sobre todo, si los algoritmos ahora pueden procesar grandes volúmenes de datos, identificar patrones complejos y sugerir predicciones precisas, ¿cuál será el papel de los estudios tradicionales? La respuesta no es excluyente: los diseños epidemiológicos siguen siendo indispensables porque permiten establecer relaciones causales, evaluar intervenciones en condiciones controladas y generar evidencia robusta. La inteligencia artificial no reemplaza estos diseños; los complementa. Puede orientar qué preguntas vale la pena investigar, ayu-

Figura 2 Integración de la inteligencia artificial con diferentes ramas de la epidemiología




Diagrama de Sankey que ilustra las conexiones entre subdisciplinas epidemiológicas (izquierda), técnicas de inteligencia artificial (centro) y aplicaciones específicas (derecha). El ancho de los flujos representa la proporción relativa de publicaciones identificadas durante el período 2020-2025 mediante búsqueda de investigación con *Deep Research*. La epidemiología clínica y genética muestran mayor integración con técnicas de aprendizaje automático (ML) y aprendizaje profundo (*Deep Learning*), principalmente orientadas a predicción temprana y modelos de riesgo. Las ramas ambiental y social han incorporado estas herramientas más recientemente, con énfasis en análisis de patrones complejos y fenotipos

Fuente: elaboración propia

dar a identificar subgrupos que requieren análisis diferenciados o sugerir hipótesis basadas en patrones que no eran visibles. Sin ensayos clínicos, cohortes o estudios de casos y controles, los modelos de IA carecerían de un marco para validar su utilidad en decisiones clínicas o de salud pública.

Inferencia causal frente a predicción

A pesar del entusiasmo generado, es imperativo reconocer las tensiones epistemológicas entre ambas disciplinas. La epidemiología tradicional se centra en la inferencia causal: entender por qué ocurre un fenómeno y si una intervención específica modificará el resultado. En contraste, la mayoría de los modelos actuales de inteligencia artificial son “motores de correlación” extraordinariamente potentes, diseñados para maximizar la predicción, no la explicación. Esto genera riesgos significativos.

Un algoritmo puede predecir con alta precisión la mortalidad hospitalaria basándose en variables espurias (como la hora de ingreso o el código postal), sin que estas sean causas biológicas reales. Si los especialistas en salud y profesionales en epidemiología, trabajando de forma interdisciplinaria, no supervisan estos modelos, se corre el riesgo de diseñar intervenciones de salud pública basadas en correlaciones matemáticas que carecen de plausibilidad biológica

o sustento causal, desperdiciando recursos valiosos en blancos terapéuticos equivocados.²⁶

Interpretabilidad y razonamiento clínico

Otro desafío crítico es la interpretabilidad. Muchos algoritmos de aprendizaje profundo, aunque precisos, funcionan como “cajas negras”, donde el proceso de toma de decisiones es opaco para el humano. En la práctica clínica, esto es problemático: un médico difícilmente aceptará una recomendación de tratamiento sugerida por una IA si no puede entender la lógica clínica detrás de ella.

Además, existe el riesgo del “sesgo de automatización”, donde el uso extendido de estas herramientas puede reducir la capacidad crítica de los profesionales. Si el personal de salud se acostumbra a confiar ciegamente en una puntuación de riesgo automatizada sin cuestionar su origen, se debilita el razonamiento clínico fundamental. Por tanto, la inteligencia artificial debe integrarse siempre como un sistema de soporte a la decisión (*Clinical Decision Support System*), y no como un sustituto del juicio profesional, requiriendo una formación continua en la interpretación crítica de estas nuevas tecnologías.²⁷

Viabilidad técnica y desafíos de implementación

La implementación de estas herramientas enfrenta barreras tangibles en entornos con recursos limitados. La dependencia tecnológica es un factor limitante severo; los algoritmos de vanguardia requieren infraestructura digital robusta, servidores de alto rendimiento, conectividad ininterrumpida y calidad de datos homogénea. En México, la fragmentación de los sistemas de información y la heterogeneidad en la calidad del registro electrónico suponen un reto mayúsculo.

Un modelo entrenado con datos de un hospital de tercer nivel en la Ciudad de México podría fallar al aplicarse en una unidad de medicina familiar rural, debido a las diferencias en la población y en la disponibilidad de pruebas diagnósticas (fenómeno conocido como *dataset shift*).²⁸ En este escenario, el IMSS posee una posición única pero desafiante. La digitalización progresiva a través del expediente clínico electrónico y la existencia de bases de datos masivas centralizadas representan un activo invaluable para el desarrollo de una “IA soberana”, ajustada a la epidemiología mexicana.

A pesar de los retos de infraestructura, existen áreas de impacto inmediato donde la integración es viable. Por ejemplo, algoritmos ligeros para la identificación temprana de pacientes con “riesgo invisible” de complicaciones por enfermedades crónicas (diabetes e hipertensión) que no acuden a control regular; la gestión inteligente del rezago quirúrgico, utilizando modelos que optimizan la programación de quirófanos y predicen cancelaciones para incrementar el flujo de pacientes intervenidos;^{29,30} la optimización logística de medicamentos mediante la predicción de demanda estacional, o el análisis de patrones de prescripción para detectar polifarmacia inapropiada en el adulto mayor.

Para lograrlo, la institución no solo requiere inversión en infraestructura tecnológica, sino también en capital humano capaz de auditar estos modelos y adaptarlos a la realidad operativa de la seguridad social.

Desafíos éticos y gobernanza de datos

La implementación de inteligencia artificial en instituciones de seguridad social conlleva desafíos éticos que trascienden las dificultades técnicas. Un aspecto crítico es la privacidad y la gobernanza de los datos. A diferencia de los estudios epidemiológicos tradicionales, donde el consentimiento informado es específico para un protocolo, el uso secundario de datos clínicos masivos para el entrenamiento de algoritmos plantea interrogantes sobre la autonomía del paciente.

En México, aunque la Ley Federal de Protección de Datos Personales establece un marco legal, la anonimización robusta de grandes bases de datos sigue siendo un reto técnico, dado que la combinación de variables sociodemográficas podría permitir la reidentificación de derechohabientes.³¹ Asimismo, existe el riesgo de sesgo algorítmico. Si los modelos de IA se entrenan con datos históricos que reflejan disparidades en el acceso a la atención (por ejemplo, menor registro de datos en zonas rurales o marginadas), los algoritmos resultantes podrían replicar o exacerbar estas inequidades al subestimar el riesgo en poblaciones vulnerables.

Por tanto, la “*epidemiología algorítmica*” debe someterse a auditorías continuas de equidad (*fairness auditing*), asegurando que las herramientas predictivas funcionen con la misma precisión en todos los estratos de la derechohabencia.³²

Reconfiguración del talento humano en salud

Finalmente, la transición hacia una epidemiología apoyada por IA exige una actualización urgente en las competencias del personal de salud. No se trata de convertir a los médicos, profesionales de la salud y epidemiólogos en ingenieros de *software*, sino de formar “*traductores bilingües*” capaces de comprender tanto la lógica clínica como los principios básicos de la ciencia de datos.

Las residencias de epidemiología y salud pública deben incorporar en sus currículos nociones de aprendizaje automático, interpretación de modelos y curaduría de datos.³³ Para el IMSS, esto implica fortalecer la capacitación continua en sus Unidades de Investigación Epidemiológica, fomentando equipos multidisciplinarios donde colaboren clínicos, estadísticos e ingenieros biomédicos. La alfabetización digital avanzada será tan crucial para el epidemiólogo del siglo XXI como lo fue la bioestadística en el siglo XX.³⁴

En conjunto, el análisis de estos factores sugiere que la epidemiología no se encuentra ante una crisis disciplinaria, sino ante una necesaria ampliación de sus fronteras metodológicas. La inteligencia artificial aporta el “*microscopio*” para observar patrones complejos en grandes volúmenes de datos, pero la epidemiología debe seguir aportando la “*brújula*” para interpretar, validar y contextualizar esos hallazgos dentro del proceso salud-enfermedad.

La convergencia entre ambos campos no implica el abandono de los métodos tradicionales, sino su integración en un marco más amplio y robusto. Esta transición es inevitable y merece ser liderada con rigor científico, especialmente

en sistemas de salud donde la demanda asistencial supera la capacidad humana de análisis sin apoyo tecnológico.³⁵

Conclusiones

A medida que los sistemas de salud avanzan hacia modelos basados en datos, será fundamental promover enfoques complementarios que utilicen la inteligencia artificial como apoyo y no como reemplazo, asegurando que el análisis crítico, el razonamiento clínico y la toma de decisiones sigan guiados por criterios científicos sólidos y por la experiencia profesional.

Para instituciones como el IMSS, este momento representa una oportunidad para liderar la transición hacia una epidemiología integradora que aproveche tanto el conocimiento acumulado como las capacidades tecnológicas emergentes. Esto requiere inversión en infraestructura, pero, sobre todo, en la formación continua de profesionales capaces de navegar con criterio entre métodos tradicionales y herramientas computacionales avanzadas, mante-

niendo siempre como prioridad la equidad en el acceso y la calidad de la atención.

Declaración de uso de herramientas de apoyo tecnológico

Para la preparación, organización y revisión conceptual del presente artículo se utilizaron herramientas de asistencia tecnológica. En particular, se emplearon *Scispace* para la consulta y gestión de literatura científica, así como *Claude* (Sonnet 4.5) para apoyar la redacción inicial, la integración de ideas y la verificación de coherencia narrativa. Todas las decisiones de contenido, interpretación y redacción final fueron realizadas por el autor.

Declaración de conflicto de interés: el autor ha completado y enviado la forma traducida al español de la declaración de conflictos potenciales de interés del Comité Internacional de Editores de Revistas Médicas, y no fue reportado alguno que tuviera relación con este artículo.

Referencias

1. Ahlbom A. Epidemiology is about disease in populations. *Eur J Epidemiol*. 2020;35:1111. doi:10.1007/s10654-020-00701-9
2. Salathé M, Bengtsson L, Bodnar TJ, et al. Digital Epidemiology. *PLoS Comput Biol*. 2012;8:e1002616. doi:10.1371/journal.pcbi.1002616
3. Ng HKT, Lovric M. Statistical Methods in Epidemiology. *International Encyclopedia of Statistical Science*. 2025;2514–2523. doi:10.1007/978-3-662-69359-9_616
4. Buckee C. Improving epidemic surveillance and response: big data is dead, long live big data. *Lancet Digit Health*. 2020; 2:e218–e220. doi:10.1016/S2589-7500(20)30059-5
5. Ye Y, Pandey A, Bawden C, et al. Integrating artificial intelligence with mechanistic epidemiological modeling: a scoping review of opportunities and challenges. *Nat Commun*. 2025; 16:581. doi:10.1038/s41467-024-55461-x
6. Wiemken TL, Kelley RR. Machine Learning in Epidemiology and Health Outcomes Research. *Annu Rev Public Health*. 2020;41:21–36. doi:10.1146/annurev-publhealth-040119-094437
7. Zhou J, Li L, Su J. Leveraging big data in health care and public health for AI driven talent development in rural areas. *Front Public Health*. 2025;13:1524805. doi:10.3389/fpubh.2025.1524805
8. Kim K-N, Hong Y-C. The exposome and the future of epidemiology: a vision and prospect. *Environ Health Toxicol*. 2017; 32:e2017009. doi:10.5620/eh.t.e2017009
9. Panteli D, Adib K, Buttigieg S, et al. Artificial intelligence in public health: promises, challenges, and an agenda for policy makers and public health institutions. *Lancet Public Health*. 2025;10:e428–e432. doi:10.1016/S2468-2667(25)00036-2
10. Chen S, Yu J, Chamouni S, et al. Integrating machine learning and artificial intelligence in life-course epidemiology: pathways to innovative public health solutions. *BMC Med*. 2024;22:354. doi:10.1186/s12916-024-03566-x
11. Hasanah U, Avian C, Darmawan JT, et al. CheXNet and feature pyramid network: a fusion deep learning architecture for multilabel chest X-Ray clinical diagnoses classification. *Int J Cardiovasc Imaging*. 2023;40:709–722. doi:10.1007/s10554-023-03039-x
12. Si Y, Du J, Li Z, et al. Deep representation learning of patient data from Electronic Health Records (EHR): A systematic review. *J Biomed Inform*. 2021;115:103671. doi:10.1016/j.jbi.2020.103671
13. Dara M, Dianatpour M, Azarpira N, et al. The transformative role of Artificial Intelligence in genomics: Opportunities and challenges. *Gene Rep*. 2025;41:102314. doi:10.1016/j.genrep.2025.102314
14. Gupta RM, Lall M. COVID-19 pandemic and artificial intelligence possibilities: A healthcare perspective. *Med J Armed Forces India*. 2021;77:S242–S244. doi:10.1016/j.mjafi.2021.06.001
15. Dong E, Du H, Gardner L. An interactive web-based dashboard to track COVID-19 in real time. *Lancet Infect Dis*. 2020; 20(5):533–534. doi:10.1016/S1473-3099(20)30120-1
16. Malla S, Kumar LK, Alphonse PJA. Novel fuzzy deep learning approach for automated detection of useful COVID-19 tweets. *Artif Intell Med*. 2023 Sep;143:102627. doi: 10.1016/j.artmed.2023.102627.
17. Milinovich GJ, Williams GM, Clements AC, Hu W. Internet-based surveillance systems for monitoring emerging infectious diseases. *Lancet Infect Dis*. 2014;14(2):160–168. doi:10.1016/S1473-3099(13)70244-5
18. Arsevska E, Valentin S, Rabatel J, et al. Web monitoring of emerging animal infectious diseases integrated in the French Animal Health Epidemic Intelligence system. *PLoS One*. 2018; 13(8):e0199960. doi:10.1371/journal.pone.0199960

19. Choi SB, Ahn I. Forecasting seasonal influenza-like illness in South Korea after 2 and 30 weeks using Google Trends and influenza data from Argentina. *PLoS One*. 2020;15(7): e0233855. doi:10.1371/journal.pone.0233855
20. Colón-González FJ, Lake IR, Morbey RA, et al. A methodological framework for the evaluation of syndromic surveillance systems: a case study of England. *BMC Public Health*. 2018;18(1):544. doi:10.1186/s12889-018-5422-9
21. Fleuren LM, Klausch TLT, Zwager CL, et al. Machine learning for the prediction of sepsis: a systematic review and meta-analysis of diagnostic test accuracy. *Intensive Care Med*. 2020;46:383–400. doi:10.1007/s00134-019-05872-y
22. Cui Q, Zhang F, Fu S, et al. High Spatiotemporal Resolution PM2.5 Concentration Estimation with Machine Learning Algorithm: A Case Study for Wildfire in California. *Remote Sens*. 2022;14:1635. doi:10.3390/rs14071635
23. Wong PY, Su HJ, Lung SC, et al. Explainable geospatial-artificial intelligence models for the estimation of PM2.5 concentration variation during commuting rush hours in Taiwan. *Environ Pollut*. 2024;349:123974. doi:10.1016/j.envpol.2024.123974
24. Kassem H, Beevi AA, Basheer S, et al. Investigation and Assessment of AI's Role in Nutrition—An Updated Narrative Review of the Evidence. *Nutrients*. 2025;17:190. doi:10.3390/nu17010190
25. Choochaiwattana W, Jaruariyanon P, Jitpranee A, et al. AI powered dietary proportion assessment for improving accuracy and practicality of the balanced meal plate model. *Sci Rep*. 2025;15:29631. doi:10.1038/s41598-025-29631-w
26. Kaliappan S, Maranan R, Niveditha VR, et al. Enhancing the Efficiency of Computational Genetic Epidemiology using HPC-Driven AI Models. In: 3rd IEEE International Conference on ICT in Business Industry and Government (ICTBIG). IEEE; 2023. p. 1-6. doi:10.1109/ICTBIG59752.2023.10455975
27. Ding X, Shang B, Xie C, et al. Artificial intelligence in the COVID-19 pandemic: balancing benefits and ethical challenges in China's response. *Humanit Soc Sci Commun*. 2025;12:245. doi:10.1057/s41599-025-04564-x
28. El-Helaly M. Artificial Intelligence and Occupational Health and Safety, Benefits and Drawbacks. *Med Lav*. 2024;115: e2024014. doi:10.23749/mdl.v115i2.15835
29. Agostinelli T, Generosi A, Ceccacci S, et al. Validation of computer vision-based ergonomic risk assessment tools for real manufacturing environments. *Sci Rep*. 2024;14:27785. doi:10.1038/s41598-024-79373-4
30. Yang Z, Song D, Ning J, et al. A Systematic Review: Advancing Ergonomic Posture Risk Assessment through the Integration of Computer Vision and Machine Learning Techniques. *IEEE Access*. 2024;12:1-1. doi:10.1109/ACCESS.2024.3509447
31. Rana R, Higgins N, Stedman T, et al. Passive AI Detection of Stress and Burnout Among Frontline Workers. *Nurs Rep*. 2025;15:373. doi:10.3390/nursrep15110373
32. Cavique L. Implications of causality in artificial intelligence. *Front Artif Intell*. 2024;7:1439702. doi:10.3389/frai.2024.1439702
33. Ghassemi M, Oakden-Rayner L, Beam AL. The false hope of current approaches to explainable artificial intelligence in health care. *Lancet Digit Health*. 2021;3:e745–e750. doi:10.1016/S2589-7500(21)00208-9
34. Finlayson SG, Subbaswamy A, Singh K, et al. The Clinician and Dataset Shift in Artificial Intelligence. *N Engl J Med*. 2021; 385:283–286. doi:10.1056/NEJMc2104626
35. Martinez O, Martinez C, Parra CA, et al. Machine learning for surgical time prediction. *Comput Methods Programs Biomed*. 2021;208:106220. doi:10.1016/j.cmpb.2021.106220