



PUBLICACIONES DE LA
ACADEMIA NACIONAL DE
MEDICINA DE MÉXICO

ACTUALIDADES EN INTELIGENCIA ARTIFICIAL

Dr. Rodolfo Palencia Díaz
Dr. Rodolfo de J. Palencia Vizcarra
Dr. Raúl Carrillo Esper

Número 7

Violencia en la educación médica: revisión crítica contemporánea para clínicos, educadores y directivos

Dr. Rodolfo Palencia Díaz

Dr. Rodolfo de J. Palencia Vizcarra

Médicos Internistas
Universidad de Guadalajara
Instituto Mexicano del Seguro Social (IMSS)
Colegiados y Certificados (CMMI)
Fundadores del TICC

Dr. Raúl carrillo Esper

Presidente de la Academia Nacional de Medicina de México

Resumen estructurado

Introducción: La violencia en la educación médica comprende bullying, humillación pedagógica, acoso, discriminación, hostigamiento sexual, incivilidad y abuso jerárquico. Su relevancia actual rebasa el bienestar individual del aprendiz, porque afecta el clima de aprendizaje, la identidad profesional y la seguridad del paciente. La evidencia reciente indica que el problema persiste en pregrado y posgrado pese a políticas institucionales formales.

Objetivo: Sintetizar críticamente la evidencia reciente sobre frecuencia, formas, consecuencias e intervenciones relacionadas con la violencia en la educación médica, con enfoque en médicos clínicos, educadores y directivos.

Métodos: Revisión narrativa estructurada, orientada por principios de búsqueda basados en evidencia. Se priorizaron revisiones sistemáticas, metaanálisis y documentos institucionales relevantes publicados principalmente en los últimos cinco años, en inglés o español. La interpretación metodológica se apoyó en PRISMA 2020, AMSTAR 2, GRADE y GAMER para transparencia del uso de IA generativa.

Resultados: Un metaanálisis de 2023 estimó una prevalencia global de bullying en residentes médicos de 51%. Una revisión sistemática y metaanálisis publicada en 2025 encontró que la enseñanza por humillación afecta a 57.1% de los médicos en formación y se asocia con depresión, ansiedad, estrés, burnout, abuso de sustancias e ideación suicida. Una revisión sistemática en personal sanitario mostró que las conductas inacep-

tables entre trabajadores de la salud deterioran el desempeño clínico, la calidad de la atención, la productividad y los resultados del paciente. Otras revisiones documentan subreporte persistente, mayor vulnerabilidad en mujeres, minorías y personas con discapacidad, y escasez de intervenciones robustas con beneficio sostenido.

Conclusiones: La violencia en la educación médica debe considerarse un problema de ética, gobernanza, calidad educativa y seguridad clínica. La evidencia es suficientemente consistente para justificar respuestas institucionales firmes, aunque la certeza sea menor respecto de la efectividad comparativa de intervenciones específicas. La respuesta más razonable es multinivel: política explícita, mecanismos seguros de reporte, protección frente a represalias, desarrollo docente y monitoreo continuo.

Palabras clave: educación médica; maltrato; bullying; humillación; acoso; discriminación; residencia médica; clima de aprendizaje; seguridad del paciente; gobernanza institucional.

Introducción

La educación médica se desarrolla en sistemas jerárquicos donde la supervisión y la evaluación pueden convertirse en instrumentos de aprendizaje o en vehículos de abuso. En la literatura contemporánea, la violencia educativa incluye humillación pública, ridiculización, bullying, acoso sexual, discriminación, sobrecarga punitiva, silenciamiento y represalias. Su importancia ya no se entiende solo como un problema relacional o disciplinario, sino como un fenómeno que

altera la calidad del ambiente formativo y puede repercutir en la seguridad clínica.

El problema no parece marginal. La AAMC informó en 2024 que más de uno de cada tres estudiantes y residentes refieren maltrato por parte de docentes, desde humillación pública hasta comentarios sexistas. Además, el Graduation Questionnaire de la AAMC sigue siendo un instrumento nacional de vigilancia del problema, lo que refleja que el maltrato continúa siendo un tema estructural en la educación médica.

La hipótesis cultural tradicional de que ciertamente cada vez menos defendible. La evidencia reciente no muestra beneficio pedagógico demostrable de la humillación; por el contrario, la asocia con daño psicológico, deterioro del clima de aprendizaje y menor disposición a reportar problemas. En consecuencia, para clínicos y directivos, la violencia educativa debe analizarse como un evento adverso del sistema formativo.

Métodos

Se realizó una revisión narrativa estructurada. La búsqueda conceptual se centró en combinaciones de términos equivalentes a *medical education, medical students, internship and residency, mistreatment, bullying, harassment, discrimination, teaching by humiliation y workplace violence*. Se priorizaron revisiones sistemáticas, metaanálisis y documentos institucionales relevantes en inglés o español, publicados principalmente entre 2021 y 2025, con apoyo de bases y portales indexados de alta credibilidad.

En el plano metodológico, PRISMA 2020 se utilizó como referencia para la transparencia del reporte de revisiones; AMSTAR 2 como marco para valorar calidad metodológica de revisiones sistemáticas; GRADE como aproximación para interpretar certeza de la evidencia; y GAMER como estándar reciente para transparentar el uso de IA generativa en investigación médica. No se presenta un flujo PRISMA completo ni registro de protocolo, porque este manuscrito no deriva de una revisión sistemática formal.

La principal limitación metodológica del campo es la heterogeneidad conceptual. No todos los estudios definen igual bullying, maltrato, incivilidad, acoso o humillación pedagógica. Además, gran parte de la

evidencia deriva de estudios observacionales y autorreporte. Por ello, la evidencia es más fuerte para afirmar frecuencia y asociación con daño que para cuantificar tamaños exactos de efecto o establecer la superioridad de una intervención concreta.

Resultados

1. Frecuencia del problema

El hallazgo más consistente es que la violencia educativa sigue siendo frecuente. El metaanálisis de Álvarez Villalobos y colaboradores, con 13 estudios y 44,566 residentes, estimó una prevalencia global de bullying de 51%. Este dato es demasiado alto para interpretarlo como fenómeno excepcional. Además, el estudio identificó mayor riesgo en mujeres y en personas pertenecientes a minorías.

La humillación pedagógica también mantiene una frecuencia alta. La revisión sistemática y metaanálisis de Wigg y colaboradores integró 28 estudios con 34,821 participantes y encontró una frecuencia agrupada de 57.1% de enseñanza por humillación. Esa cifra sugiere que el problema no es residual ni histórico, sino todavía funcional dentro de múltiples ambientes de formación médica.

La AAMC ha sostenido vigilancia continua del maltrato estudiantil y sus reportes recientes mantienen una señal preocupante. Datos comunicados por la propia asociación y análisis recientes basados en el GQ indican que aproximadamente 38% de los estudiantes graduados en 2023 refirieron maltrato al menos una vez, sin cambios importantes respecto de años previos.

2. Formas principales de violencia educativa

La literatura muestra que la violencia rara vez se reduce a agresión física. En entornos médicos suele presentarse como sobrecarga injustificada, desestabilización, aislamiento, humillación pública, ridiculización, hostigamiento, discriminación y amenaza de represalias. La revisión sistemática de Averbuch y colaboradores sobre bullying académico en entornos médicos concluyó que las conductas más comunes incluían sobrecarga laboral y otras formas de abuso jerárquico, con afectación clara del bienestar y bajo nivel de reporte.

En subcampos específicos, el problema adquiere matices particulares. En obstetricia y ginecología, una revisión sistemática de 2024 encontró altas tasas de acoso sexual, abuso, discriminación y bullying entre clínicos y aprendices, y señaló que las intervenciones disponibles eran escasas y metodológicamente insuficientes para mostrar reducción clara del problema. Esto sugiere que ciertos entornos con jerarquías rígidas o culturas tradicionalmente cerradas pueden concentrar mayor riesgo.

La violencia también tiene una dimensión estructural. La revisión sistemática sobre ableísmo en profesiones de la salud documentó discriminación relevante hacia profesionales y aprendices con discapacidad, lo que amplía el análisis: no toda violencia es explícita; parte de ella se expresa como exclusión, subrepresentación y barreras institucionales persistentes.

3. Consecuencias para salud mental, aprendizaje e identidad profesional

La asociación con daño psicológico es consistente. La revisión sobre enseñanza por humillación encontró relación con depresión, ansiedad, estrés, burnout, abuso de sustancias e ideación suicida. Este hallazgo es particularmente importante porque contradice de manera directa la idea de que la humillación pueda ser una herramienta pedagógica legítima.

La revisión de Averbuch mostró además que el bullying académico deteriora el bienestar y rara vez se reporta, lo que favorece su cronificación institucional. En términos formativos, esto implica que muchos aprendices no solo sufren daño, sino que aprenden a callar y adaptarse al abuso como condición de supervivencia académica.

Aunque la mayor parte de la evidencia es observacional, el patrón es coherente: el maltrato erosiona la seguridad psicológica, deteriora el clima de aprendizaje y puede afectar la identidad profesional. En la práctica, esto se traduce en menor disposición a preguntar, pedir ayuda, señalar errores o discutir decisiones clínicas dudosas, lo cual es incompatible con una cultura asistencial segura. Esta última inferencia es razonable a partir del conjunto de la evidencia, aunque no todos los estudios miden exactamente ese desenlace.

4. Implicaciones para seguridad del paciente y desempeño clínico

Una de las razones más fuertes para que directivos y clínicos tomen este tema en serio es su posible impacto asistencial. La revisión sistemática de Guo y colaboradores concluyó que las conductas inaceptables entre trabajadores sanitarios afectan negativamente el desempeño clínico, la calidad de la atención, la productividad laboral y los desenlaces del paciente. Aunque esta revisión no se restringe a educación médica, su aplicabilidad a hospitales escuela es alta, dado que formación y asistencia ocurren en el mismo sistema operativo.

Esto cambia el marco del debate. La violencia educativa deja de ser solo un problema de convivencia y pasa a ser también un asunto de seguridad del paciente. Un entorno donde el aprendiz teme ser humillado o castigado es un entorno donde las dudas clínicas se callan y los errores pueden no comunicarse a tiempo.

5. Barreras de reporte y debilidad de intervenciones

El subreporte es una constante. La revisión mixta de Xu y colaboradores identificó barreras organizacionales, socioculturales y personales para reportar violencia laboral en salud, y señaló como facilitadores el liderazgo visible, los sistemas de reporte simples y el respaldo normativo. Este hallazgo es directamente aplicable a educación médica: si no hay percepción de protección y trazabilidad, el silencio es una respuesta racional del aprendiz.

La evidencia sobre intervención todavía es limitada. La revisión y metaanálisis de Chung y colaboradores encontró que los programas de capacitación mejoran la confianza de los profesionales para enfrentar violencia laboral, pero el desenlace medido fue sobre todo confianza, no reducción demostrada y sostenida de incidencia. En otras palabras, entrenar sirve, pero por sí solo probablemente no basta.

La revisión sobre bullying académico fue aún más clara al señalar que las intervenciones estudiadas habían sido evaluadas principalmente en diseños antes-después no controlados, y que siguen faltando ensayos metodológicamente robustos. Por tanto, la dirección

institucional prudente es adoptar estrategias multinivel sin exagerar la certeza de efectividad de cada componente aislado.

Tabla 1. Síntesis comparativa de la evidencia reciente

Dominio	Fuente principal	Hallazgo central	Relevancia práctica
Bullying en residentes	Álvarez Villalobos et al., 2023	Prevalencia global 51%	Problema estructural en residencia
Enseñanza por humillación	Wigg et al., 2025	Frecuencia 57.1%; asociación con depresión, ansiedad, burnout e ideación suicida	No debe tolerarse como estilo docente
Bullying académico	Averbuch et al., 2021	Sobretabajo, daño al bienestar y subreporte	Muestra la lógica jerárquica del abuso
Conductas inaceptables y seguridad clínica	Guo et al., 2022	Deterioro del desempeño clínico, calidad y resultados del paciente	Relevancia directa para hospitales escuela
Reporte de violencia	Xu et al., 2025	Barreras organizacionales, socioculturales y personales	Exige rediseño de sistemas de denuncia
Intervenciones educativas	Chung et al., 2025	Mejoran confianza, pero no prueban por sí solas reducción sostenida del problema	La capacitación aislada es insuficiente

Discusión

La violencia en la educación médica no debe explicarse como suma de incidentes individuales. Su persistencia, frecuencia y sesgo hacia grupos vulnerables sugieren un fenómeno sistémico, sostenido por culturas jerárquicas, tolerancia institucional y mecanismos ineficaces de control. Eso explica por qué la sola declaración de "cero tolerancia" rara vez modifica el problema si no se acompaña de consecuencias reales y protección frente a represalias.

Existe además un error conceptual frecuente: confundir exigencia académica con violencia. La medicina necesita disciplina, responsabilidad y supervisión rigurosa; no necesita humillación, hostigamiento ni abuso. La evidencia reciente no respalda la utilidad pedagógica de esos métodos y sí documenta sus daños.

Desde la perspectiva metodológica, la certeza de la evidencia es desigual. Bajo una lógica GRADE, buena parte del cuerpo de evidencia partiría de estudios observacionales y, por tanto, con certeza inicial baja. Sin embargo, la consistencia del patrón, la magnitud de la frecuencia observada y la plausibilidad clínica del daño fortalecen la justificación para actuar. Dicho de otra forma: la evidencia puede no ser perfecta, pero sí es suficiente para intervención institucional.

Para academias, hospitales escuela y facultades, el enfoque más sensato es tratar la violencia educativa como un problema de gobernanza y seguridad. Eso obliga a medirla, reportarla, auditarla y vincularla con responsabilidad de mando. La AAFP mantiene una política explícita contra el maltrato de aprendices, y la AAMC continúa usando instrumentos nacionales de vigilancia; ambos hechos refuerzan que el tema ya no pertenece al margen del debate educativo.

Recomendaciones institucionales

La respuesta no debe limitarse a sensibilización. Primero, se requiere una política explícita con definiciones operativas de bullying, humillación, discriminación, acoso y represalia. Segundo, canales múltiples y razonablemente confidenciales de denuncia. Tercero, protección real al denunciante. Cuarto, formación obligatoria de jefes clínicos y docentes en retroalimentación, liderazgo y seguridad psicológica. Quinto, seguimiento con indicadores institucionales. Estas medidas son coherentes con la evidencia disponible y con las posturas institucionales revisadas.

Tabla 2. Propuesta operativa para hospitales escuela y academias

Dominio	Fuente principal	Hallazgo central	Relevancia práctica
Bullying en residentes	Álvarez Villalobos et al., 2023	Prevalencia global 51%	Problema estructural en residencia
Enseñanza por humillación	Wigg et al., 2025	Frecuencia 57.1%; asociación con depresión, ansiedad, burnout e ideación suicida	No debe tolerarse como estilo docente
Bullying académico	Averbuch et al., 2021	Sobretabajo, daño al bienestar y subreporte	Muestra la lógica jerárquica del abuso
Conductas inaceptables y seguridad clínica	Guo et al., 2022	Deterioro del desempeño clínico, calidad y resultados del paciente	Relevancia directa para hospitales escuela
Reporte de violencia	Xu et al., 2025	Barreras organizacionales, socioculturales y personales	Exige rediseño de sistemas de denuncia
Intervenciones educativas	Chung et al., 2025	Mejoran confianza, pero no prueban por sí solas reducción sostenida del problema	La capacitación aislada es insuficiente

La utilidad de estos componentes deriva de la síntesis de barreras, facilitadores y debilidad de intervenciones aisladas; no debe interpretarse como un paquete ya validado en ensayo comparativo único.

Conclusiones

La violencia en la educación médica sigue siendo frecuente y dañina. La mejor evidencia reciente

muestra alta prevalencia de bullying y humillación, asociación consistente con daño psicológico y repercusiones plausibles sobre seguridad clínica y calidad asistencial. Para médicos clínicos, educadores y directivos, esto obliga a abandonar la idea de que el problema pertenece solo al terreno de la sensibilidad interpersonal. Es un problema del sistema.

La incertidumbre principal no está en si existe el problema, sino en qué combinación de intervenciones lo reduce mejor. Mientras esa evidencia madura, la respuesta prudente es actuar con enfoque multinivel, transparencia y rendición de cuentas. Esperar evidencia perfecta para corregir una práctica institucionalmente dañina sería un error de gobernanza.

Perlas para llevar a la práctica

- La humillación no es exigencia académica; es una forma de violencia.
- Cuando el aprendiz teme represalias, el sistema aprende menos y se vuelve menos seguro.
- La violencia educativa no solo afecta bienestar; también amenaza calidad asistencial y seguridad del paciente.
- Los programas de capacitación son útiles, pero aislados rara vez bastan.
- Las instituciones serias no solo condenan el maltrato: lo miden, lo investigan y lo sancionan.

Transparencia sobre uso de IA generativa

Siguiendo el marco GAMER, este texto fue apoyado por IA generativa para estructuración y redacción, pero la selección factual y la verificación de afirmaciones se basaron en fuentes trazables. No debe declararse como revisión sistemática registrada ni como síntesis exhaustiva definitiva.

Referencias

1. Álvarez Villalobos NA, de León Martínez H, Ruiz Fregoso G, Elizondo-Omaña RE, Vázquez-Castellanos JL, Carranza Figueroa JA, et al. Prevalence and associated factors of bullying in medical residents: A systematic review and meta-analysis. *J Occup Health*. 2023;65(1):e12418. doi:10.1002/1348-9585.12418.
2. Wigg L, Li WW, Leow T. A systematic review and meta-analysis on teaching by humiliation in medical training: its frequency and impact on the mental health outcomes of medical trainees. *Med Sci Educ*. 2025;35(1):569-585. doi:10.1007/s40670-024-02213-7.
3. Guo L, et al. Impact of unacceptable behaviour between healthcare workers on clinical performance and patient outcomes: a systematic review. *BMJ Qual Saf*. 2022;31(9):679-687. doi:10.1136/bmjqs-2021-013955.
4. Averbuch T, Eliya Y, Van Spall HGC. Systematic review of academic bullying in medical settings. *BMJ Open*. 2021;11(7):e043256. doi:10.1136/bmjopen-2020-043256.
5. Lindsay S, Fuentes K, Ragnathan S, Lamaj L, Dyson J. Ableism within health care professions: a systematic review of the experiences and impact of discrimination against health care providers with disabilities. *Disabil Rehabil*. 2023;45(17):2715-2731. doi:10.1080/09638288.2022.2107086.
6. Xu D, Zhou J, Yang M, Yang L, Li Q, Zeng Y. Barriers and facilitators to reporting workplace violence among healthcare workers: a mixed-methods systematic review. *Nurs Outlook*. 2025;73(4):102443. doi:10.1016/j.outlook.2025.102443.
7. Chung YF, Chang YC, Fetzer SJ, Tessmer L, Tsai MH, Feng JY. The Effectiveness of Workplace Violence Prevention Education Training Programs on Healthcare Professionals' Confidence: A Systematic Review and Meta-Analysis. *Int Nurs Rev*. 2025;72(4):e70107. doi:10.1111/inr.70107.
8. Gupta A, et al. Sexual Harassment, Abuse, and Discrimination in Obstetrics and Gynecology: A Systematic Review. *JAMA Netw Open*. 2024;7(5):e2410706. doi:10.1001/jamanetworkopen.2024.10706.
9. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*. 2021;372:n71. doi:10.1136/bmj.n71.
10. Shea BJ, Reeves BC, Wells G, Thuku M, Hamel C, Moran J, et al. AMSTAR 2: a critical appraisal tool for systematic reviews that include randomised or non-randomised studies of healthcare interventions, or both. *BMJ*. 2017;358:j4008. doi:10.1136/bmj.j4008.
11. Luo X, Tham YC, Giuffrè M, Ranisch R, Daher M, Lam K, et al. Reporting guideline for the use of Generative Artificial intelligence tools in Medical Research: the GAMER Statement. *BMJ Evid Based Med*. 2025. doi:10.1136/bmjebm-2025-113825.
12. Association of American Medical Colleges. Graduation Questionnaire (GQ). AAMC. 2026.
13. Weiner S. Medical schools work to end student mistreatment. *AAMC News*. June 4, 2024.

Violencia en la Educación Médica: Revisión Crítica Contemporánea

De la tradición jerárquica a la gobernanza institucional y seguridad del paciente

Dr. Rodolfo Palencia Díaz.

Dr. Rodolfo de Jesús Palencia Vizcarra
Médicos Internistas

Universidad de Guadalajara, Instituto Mexicano del Seguro Social IMSS,
Colegiados (CMIM) y Certificados (CMMI)
Fundadores de TICC

Dirigido a médicos de la Academia Nacional de Medicina de México (ANMM), con mención especial al

Dr. Raúl Carrillo
Presidente de la ANMM

La evidencia clínica descarta el beneficio pedagógico de la humillación

Exigencia Académica Tradicional (El Mito)

Supervisión punitiva

Disciplina a través del miedo

Normalización de la ridiculización

Las formas de dureza “forjan carácter” es

Violencia Educativa Sancionada (La Realidad Sistémica)

Supervisión rigurosa pero segura

Responsabilidad sin hostigamiento

La disciplina no requiere abuso

La medicina moderna exige rigor y disciplina; la evidencia demuestra que la humillación no aporta valor pedagógico y genera daño demostrable.

Una prevalencia estructural en los sistemas de residencia médica

51%

Prevalencia Global

De bullying en residentes médicos a nivel mundial (Álvarez Villalobos et al., 2023. n=44,566).

57.1%

Frecuencia Agrupada

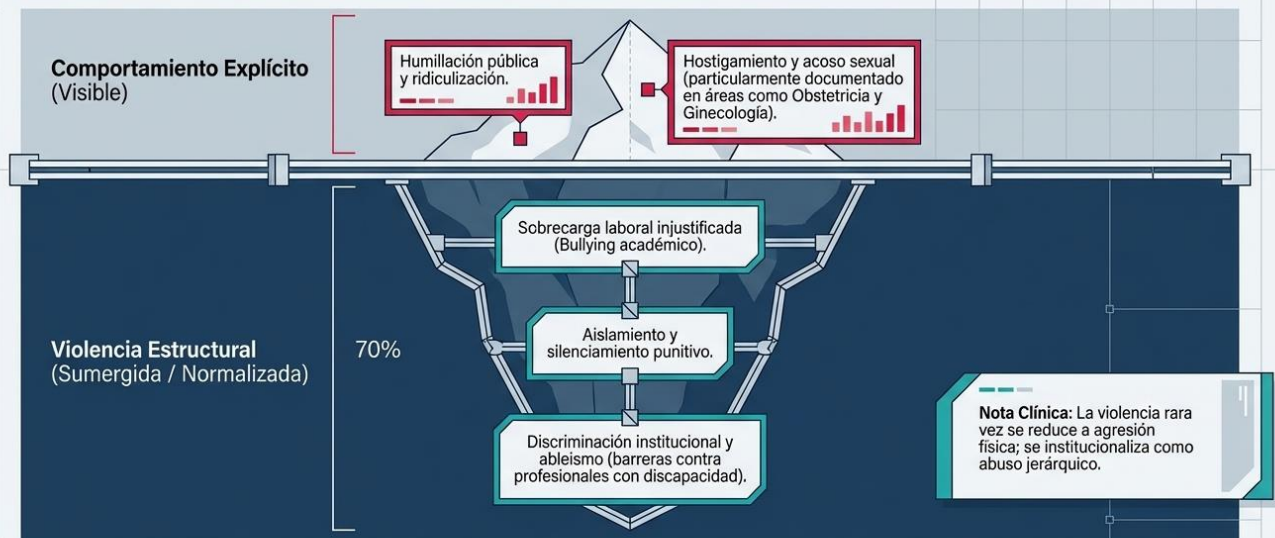
De médicos en formación expuestos a "enseñanza por humillación" (Wigg et al., 2025. n=34,821).

Estas cifras demuestran que el problema no es residual ni histórico, sino funcional y endémico dentro de múltiples ambientes de formación médica. Existe un riesgo significativamente mayor documentado para mujeres y minorías.

NotebookLM

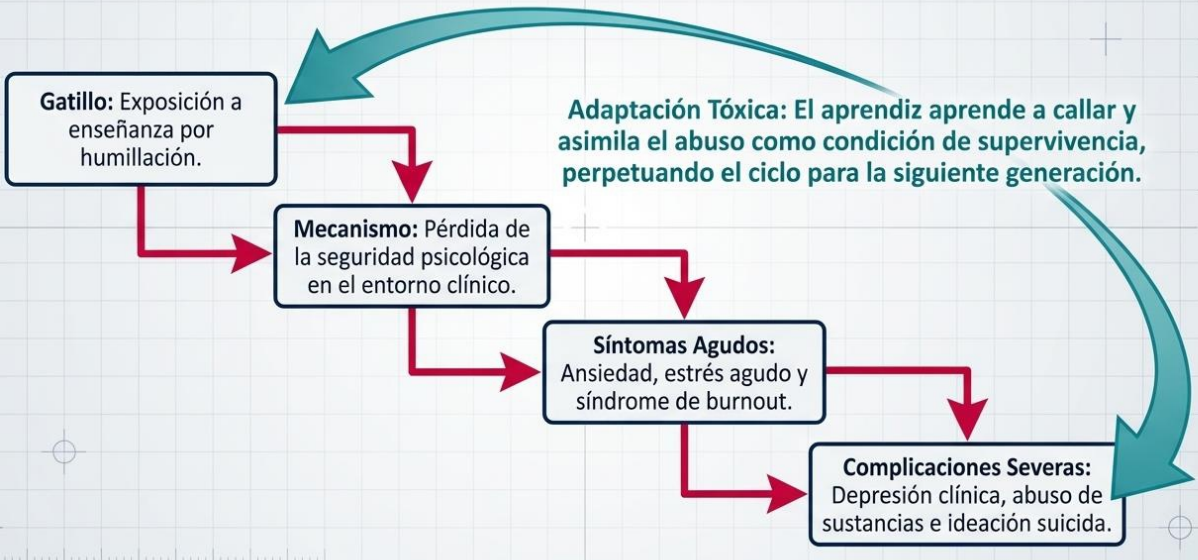
La Radiografía Sistémica

Anatomía de la violencia formativa: de la agresión explícita a la barrera invisible

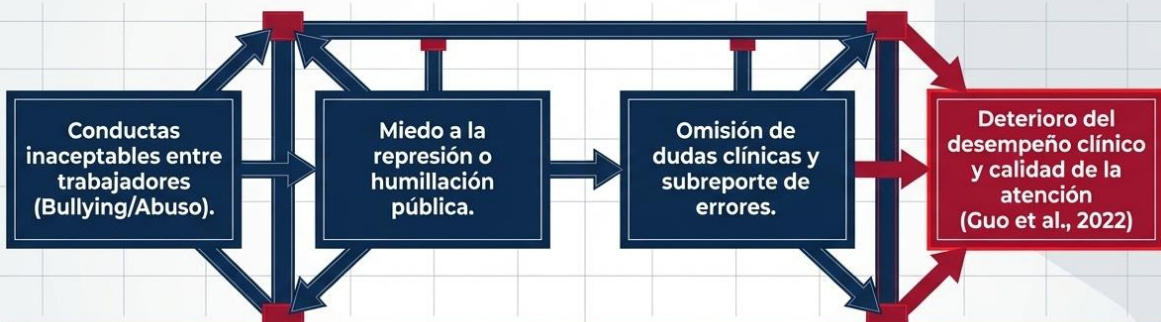


NotebookLM

Fisiopatología del daño: la erosión de la seguridad psicológica



La complicación sistémica mayor: el deterioro de la seguridad del paciente



“Un entorno donde el aprendiz teme ser humillado es un entorno donde las dudas clínicas se callan y los errores pueden no comunicarse a tiempo.”

Etiología del silencio: barreras que perpetúan el subreporte



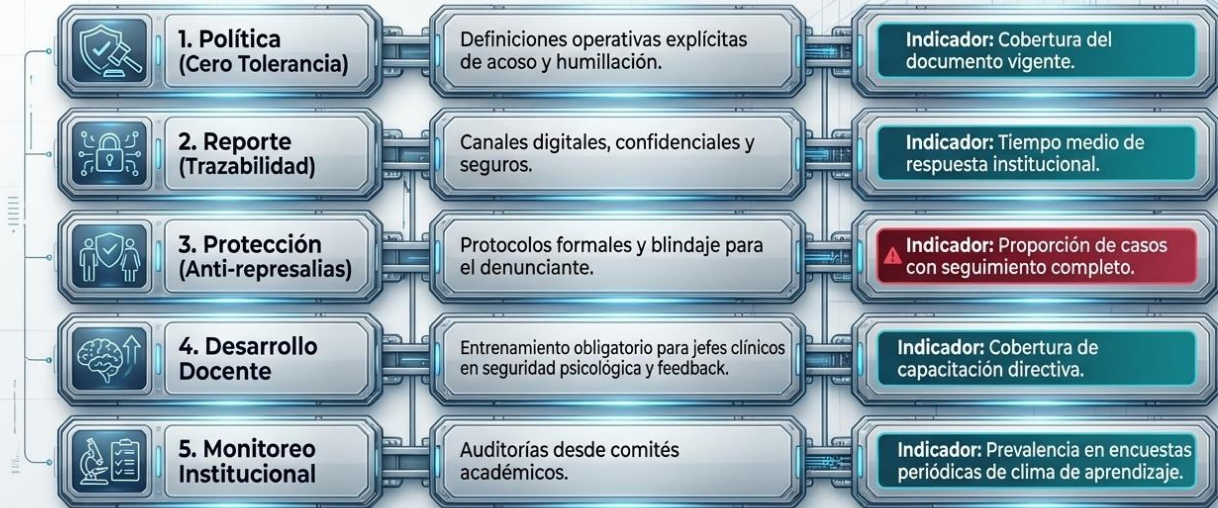
mecanismos ineficaces de control. Eso explica por qué la sola declaración de "cero tolerancia" rara vez modifica el problema si no se acompaña de consecuencias si no existe protección real al denunciante. El silencio del aprendiz es una respuesta racional de supervivencia.

Evaluación de intervenciones: la insuficiencia de la capacitación aislada



Conclusión Clínica: Intervenciones de un solo nivel fracasan ante el abuso jerárquico estructural. Se requiere un protocolo de tratamiento multinivel.

Propuesta operativa para la gobernanza en hospitales escuela



NotebookLM

Perlas directivas y metodológicas para la práctica clínica

+ La humillación no equivale a exigencia académica; es una forma documentada de violencia.

+ El miedo a represalias en el aprendiz amenaza directamente la calidad asistencial y la seguridad del paciente.

+ Las instituciones serias no solo condenan el maltrato: lo miden, lo auditan y lo sancionan.

Rigor Metodológico

Interpretación respaldada por estándares globales: PRISMA 2020 (transparencia), AMSTAR 2 (calidad metodológica), GRADE (certeza de evidencia) y GAMER (declaración de IA generativa).

NotebookLM

Violencia en la Educación Médica: Un Riesgo Sistémico para la Seguridad Clínica

TICC – Tecnologías de la Información y Comunicación en la Clínica | Palencia

La violencia en la educación médica no es un rito de iniciación, sino un problema de ética y seguridad que deteriora la salud mental del residente y pone en riesgo la calidad de la atención al paciente.

DIAGNÓSTICO DE UNA CRISIS: Magnitud e Impacto

51%

Prevalencia global de bullying
Fenómeno estructural que afecta a más de la mitad de los residentes.




El miedo al maltrato silencia dudas clínicas y errores, comprometiendo los resultados del paciente.

Amenaza directa a la seguridad del paciente

57.1%

Afectados por la humillación
NO es una herramienta pedagógica; se asocia directamente con depresión e ideación suicida.



HACIA UNA TRANSFORMACIÓN INSTITUCIONAL



Autores (Médicos Internistas): Dr. Rodolfo Palencia Díaz, Dr. Rodolfo de Jesús Palencia Vizcarra, Dr. Raúl Carrillo Esper (Presidente ANMM)

Bibliografía (Formato Vancouver)

1. Álvarez Villalobos NA, de León Martínez H, Ruiz Frogoso G, et al. Prevalence and associated factors of bullying in medical residents: A systematic review and meta-analysis. J Occup Health. 2023;65(1):e12418. 2. Wigg L, Li WW, Leow T. A systematic review and meta-analysis on teaching by humiliation in medical training. Med Sci Educ. 2025;35(1):569-585. 3. Guo L, et al. Impact of unacceptable behaviour between healthcare workers on clinical performance and patient outcomes: a systematic review. BMJ Qual Saf. 2022;31(8):878-887.

Referencias Bibliográficas (1-6)

1. Álvarez Villalobos NA, et al. Prevalence and associated factors of bullying in medical residents: A systematic review and meta-analysis. J Occup Health. 2023;65(1):e12418.
2. Wigg L, Li WW, Leow T. A systematic review and meta-analysis on teaching by humiliation in medical training... Med Sci Educ.. Med Sci Educ. 2025;35(1):569-585.
3. Guo L, et al. Impact of unacceptable behaviour between healthcare workers on clinical performance and patient outcomes... BMJ Qual Saf. 2022;31(9):679-687.
4. Averbuch T, Eliya Y, Van Spall HGC. Systematic review of academic bullying in medical settings. BMJ Open. 2021;11(7):e043256.
5. Lindsay S, et al. Ableism within health care professions... Disabil Rehabil. 2023;45(17):2715-2731.
6. Xu D, et al. Barriers and facilitators to reporting workplace violence among healthcare workers... Nurs Outlook. 2025;73(4):102443.

Referencias Bibliográficas (7-13)

7. Chung YF, et al. The Effectiveness of Workplace Violence Prevention Education Training Programs... *Int Nurs Rev.* 2025;72(4):e70107.
8. Gupta A, et al. Sexual Harassment, Abuse, and Discrimination in Obstetrics and Gynecology... *JAMA Netw Open.* 2024;7(5):e2410706.
9. Page MJ, et al. The PRISMA 2020 statement... *BMJ.* 2021;372:n71.
10. Shea BJ, et al. AMSTAR 2: a critical appraisal tool... *BMJ.* 2017;358:j4008.
11. Luo X, et al. Reporting guideline for the use of Generative Artificial intelligence tools in MEDical Research: the GAMER Statement. *BMJ Evid Based Med.* 2025.
12. Association of American Medical Colleges. Graduation Questionnaire (GQ). AAMC. 2026.
13. Weiner S. Medical schools work to end student mistreatment. *AAMC News.* June 4, 2024.

Presentación elaborada bajo la integración de TICC Palencia.
Someto al rigor académico de la Academia Nacional de Medicina de México

NotebookLM

TICC Palencia: Herramientas de Inteligencia Artificial para la Automatización de Síntesis de Evidencia

Harasgama S, Pearce H, Apple C, Loftus L, Painter H, Kuhn I, Karpusheff J, Ceesay A, Ford J.

Herramientas de Inteligencia Artificial para la Automatización de Síntesis de Evidencia: revisión exploratoria. J Med Internet Res 2026;28 e81597 doi: [10.2196/81597](https://doi.org/10.2196/81597) PMID: [41911537](https://pubmed.ncbi.nlm.nih.gov/41911537/)

Dr. Rodolfo Palencia Díaz & Dr. Rodolfo de J. Palencia Vizcarra

Médicos Internistas Especialistas en Tecnologías de la Información y Comunicación (TIC) en la Clínica.

Introducción y Alcance

La síntesis de evidencia de alta calidad es un pilar fundamental para orientar la política y la práctica clínica. Sin embargo, la producción de revisiones sistemáticas tradicionales es un proceso intensivo en tiempo y recursos, con un promedio de duración estimado en 67 semanas. La reciente pandemia de COVID-19 subrayó la necesidad crítica de contar con datos sintetizados de manera rápida y contemporánea.

En este contexto, la iniciativa TICC Palencia presenta un análisis exhaustivo sobre el panorama actual de las herramientas de Inteligencia Artificial (IA) diseñadas para automatizar diversas etapas de la síntesis de evidencia, permitiendo reducir los plazos de ejecución de meses a solo días o semanas.

Definiciones Fundamentales en IA Clínica

Para una correcta integración de las TICC en la práctica médica, es esencial distinguir las metodologías de automatización identificadas:

- Inteligencia Artificial (IA): Definida por sus características de adaptabilidad (capacidad de aprender patrones no previstos por programadores humanos) y autonomía (capacidad de tomar decisiones sin supervisión humana constante).
- Machine Learning (ML): Subconjunto de la IA enfocado en sistemas algorítmicos que aprenden de los datos y reconocen patrones.
- Deep Learning (Aprendizaje Profundo): Utiliza

redes neuronales para aprender patrones complejos en grandes conjuntos de datos.

- Procesamiento de Lenguaje Natural (NLP): Permite a las computadoras interpretar y trabajar con el lenguaje humano escrito.
- Large Language Models (LLMs): Modelos basados en arquitecturas de "transformadores" que utilizan mecanismos de atención para capturar el contexto y matices del lenguaje. Ejemplos prominentes incluyen GPT-4, ChatGPT, Claude y Gemini.

El Paisaje de la Automatización (2021-2025)

Un análisis de 222 estudios recientes identifica 65 herramientas de IA distintas y 25 modelos de código abierto dedicados a la síntesis de evidencia. Se observa una tendencia creciente y acelerada hacia el uso de modelos de lenguaje de propósito general.

Etapas de Síntesis y su Grado de Automatización

La investigación muestra que ciertas etapas son más propensas a la automatización debido a su naturaleza repetitiva:

Etapas de la Síntesis de Evidencia	Porcentaje de Estudios que la Automatizan
Cribado (Screening) de títulos y resúmenes	61.7%
Extracción de datos	26.1%
Búsqueda de literatura	18.9%
Evaluación del riesgo de sesgo	10.8%
Síntesis y análisis de datos	10.8%
Cribado de texto completo	9.5%
Redacción del reporte	4.5%

Herramientas y Modelos Identificados

El ecosistema de herramientas se divide principalmente entre aquellas basadas en ML tradicional y las basadas en transformadores (LLMs).

Herramientas Destacadas por Frecuencia de Estudio:

1. Modelos GPT / ChatGPT: 31.5% de los estudios.
2. Claude (Anthropic): 7.2% de los estudios.
3. Rayyan: 5.9% (enfocado en cribado).
4. ASReview: 5.4% (utiliza aprendizaje activo para cribado prioritario).
5. Abstrackr: 4.1% de los estudios.
6. Google Gemini: 3.6% de los estudios.
7. Otras: Covidence, DistillerSR, EPPI Reviewer, Elicit, Scite y Consensus.

Modelos Especializados en Biomedicina:

Se han desarrollado modelos de arquitectura BERT (Bidirectional Encoder Representations from Transformers) ajustados específicamente para el dominio biomédico, tales como:

- BioBERT
- PubMed-BERT
- SciBERT

Evaluación del Rendimiento y Resultados

La efectividad de estas herramientas se mide a través de métricas técnicas y de carga de trabajo:

- Métricas Técnicas: Sensibilidad (recall), especificidad, precisión, puntuación F1 y el área bajo la curva (AUC). Estas miden qué tan bien el modelo distingue entre estudios relevantes y no relevantes.
- Carga de Trabajo: La métrica Work Saved Over Sampling (WSS) cuantifica el porcentaje de trabajo de cribado manual que se puede evitar. Por ejemplo, un WSS del 30% indica que los investigadores pueden omitir la revisión del 30% de las citas manteniendo la identificación de todos los estudios relevantes.
- Acuerdo Humano-IA: Evaluado mediante el coeficiente Kappa de Cohen para validar la consistencia de las decisiones automatizadas frente a expertos humanos.

Consideraciones Críticas y Riesgos

A pesar del potencial de las TICC para optimizar el flujo de trabajo, existen desafíos significativos que el clínico debe considerar:

1. Integridad Académica y Sesgo: Los LLMs generativos presentan riesgos de sesgo inherente y posibles "alucinaciones" de datos, lo que exige una supervisión humana constante ("human-in-the-loop").
2. Accesibilidad y Equidad: La mayoría de las herramientas avanzadas operan bajo modelos de suscripción pagada, lo que puede limitar su adopción universal.
3. Impacto Ambiental: El procesamiento de IA generativa tiene altas demandas de electricidad y agua para enfriamiento. Se estima que para 2030, el procesamiento de IA podría consumir hasta el 8% de la electricidad en EE. UU. y el 5% en Europa.
4. Estandarización: Las herramientas actuales son más efectivas en revisiones cuantitativas de ensayos controlados aleatorios debido a la estructura estandarizada de sus datos, siendo menos eficaces en revisiones cualitativas complejas.

Conclusiones para el Médico de TIC en la Clínica (TICC)

La integración de IA en la síntesis de evidencia no busca reemplazar al investigador, sino actuar como un adjunto para mitigar la carga de trabajo manual. La selección de la herramienta óptima dependerá del tema de la revisión, la metodología y las prioridades de precisión frente a la rapidez. Es fundamental adherirse a guías como las recomendaciones de IA Responsable en Síntesis de Evidencia (RAISE) para garantizar la integridad científica.

Bibliografía

1. Harasgama S, Pearce H, Appel C, Loftus L, Painter H, Kuhn I, Karpusheff J, Ceesay A, Ford J. Artificial Intelligence Tools for Automating Evidence Synthesis: Scoping Review. *J Med Internet Res.* 2026;28:e81597. doi: 10.2196/81597.
2. Khalil H, Tamara L, Rada G, Akl EA. Challenges of evidence synthesis during the 2020 COVID pandemic: a scoping review. *J Clin Epidemiol.* 2022;142:10-18.
3. Borah R, Brown AW, Capers PL, Kaiser KA. Analysis of the time and workers needed to conduct systematic

- reviews of medical interventions using data from the PROSPERO registry. *BMJ Open*. 2017;7(2):e012545.
4. Clark J, Glasziou P, Del Mar C, Bannach-Brown A, Stehlik P, Scott AM. A full systematic review was completed in 2 weeks using automation tools: a case study. *J Clin Epidemiol*. 2020;121:81-90.
 5. Lieberum JL, Toews M, Metzendorf MI, et al. Large language models for conducting systematic reviews: on the rise, but not yet ready for use—a scoping review. *J Clin Epidemiol*. 2025;181:111746.
 6. Ofori-Boateng R, Aceves-Martins M, Wiratunga N, Moreno-Garcia CF. Towards the automation of systematic reviews using natural language processing, machine learning, and deep learning: a comprehensive review. *Artif Intell Rev*. 2024;57(8):200.
 7. Cierco Jimenez R, Lee T, Rosillo N, et al. Machine learning computational tools to assist the performance of systematic reviews: a mapping review. *BMC Med Res Methodol*. 2022;22(1):322.




TICC Palencia: Tecnologías de la Información y Comunicación en la Clínica

Integrando la Inteligencia Artificial para la Síntesis de Evidencia Médica

Dr. Rodolfo Palencia Díaz | Médico Internista
Dr. Rodolfo de Jesús Palencia Vizcarra | Médico Internista


REPORTE DE ESTADO DEL ARTE Y MARCO DE IMPLEMENTACIÓN CLÍNICA



NotebookLM

El Cuello de Botella de la Evidencia Médica

El Problema



67 Semanas

El tiempo promedio estimado para completar una revisión sistemática manual tradicional.



El Paradigma TICC



Días a Semanas

La aceleración lograda mediante la automatización con IA, reduciendo drásticamente la carga de trabajo clínica.



La clínica moderna exige inmediatez. Las decisiones basadas en evidencia no pueden esperar más de un año; requieren arquitecturas de datos contemporáneas y de alta velocidad.

NotebookLM

Radiografía del Ecosistema IA (2021-2025)

KPI Dashboard



El ecosistema ha madurado más allá de los prototipos teóricos, ofreciendo un catálogo robusto de herramientas operativas para departamentos de TIC clínica.

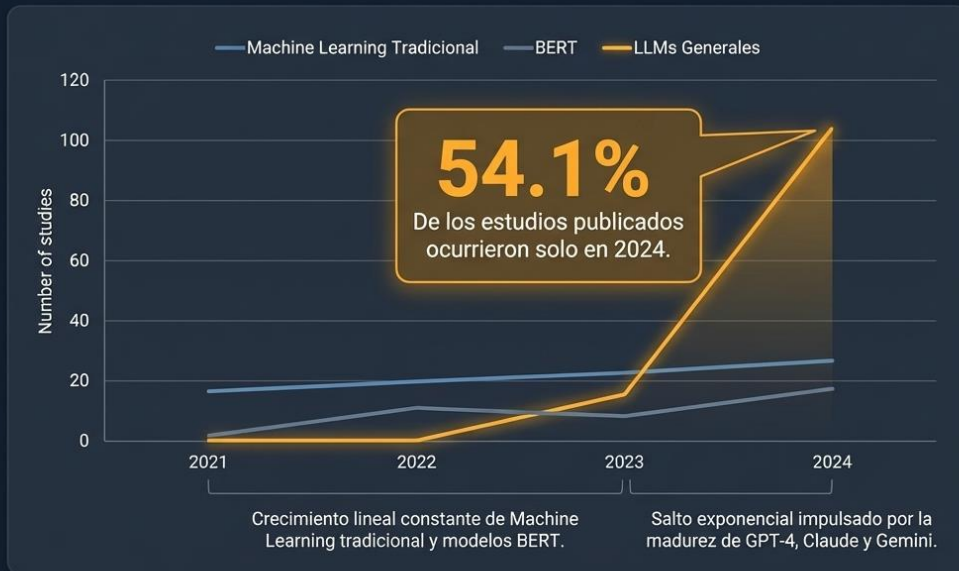
NotebookLM

Taxonomía de la IA en la Clínica: Arquitectura del Algoritmo




NotebookLM

El Punto de Inflexión Generativo



El enfoque clínico de TIC ha pasado de la simple "clasificación de textos" a la "síntesis generativa de conocimiento".

Mapeo del Proceso Analítico: ¿Dónde actúa la IA hoy?



La automatización se concentra en las tareas de mayor volumen (cribado), pero avanza rápidamente hacia tareas de mayor complejidad cognitiva.

Matriz de Decisión TICC: Seleccionando el Motor Analítico

 Machine Learning Tradicional	 Modelos BERT (Ej. SciBERT)	 LLMs Generales (Ej. GPT-4, Claude)
Naturaleza Rígido, específico, validado.	Naturaleza Pre-entrenado en biomedicina, requiere ajuste fino (fine-tuning).	Naturaleza Flexible, generativo, conversacional.
Caso de Uso Ideal Cribado masivo binario (incluir/excluir).	Caso de Uso Ideal Clasificación semántica de literatura médica compleja.	Caso de Uso Ideal Extracción de datos complejos y redacción preliminar.
Riesgo Clínico Bajo. Alta trazabilidad y métricas claras.	Riesgo Clínico Medio. Requiere infraestructura técnica experta para entrenar.	Riesgo Clínico Alto. Riesgo de alucinación y sesgo; requiere validación experta estricta.


NotebookLM

Ecosistema de Herramientas Destacadas en el Mercado

Dominio Generativo (LLMs)



Dominio Específico de Revisión (ML/Ensembles)



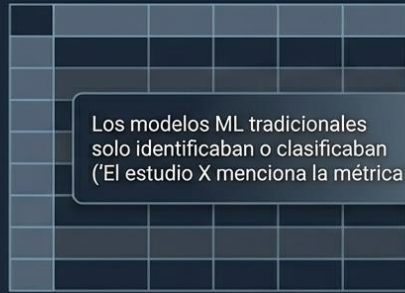
TICC Insight: La integración ideal no depende de una sola herramienta, sino de orquestar ensamblajes (Ej. **Rayyan** para cribado → **Claude** para extracción).

NotebookLM

El Salto Cualitativo: De la Extracción a la Generación

La Limitación Histórica

Clasificación Binaria (ML)



La Capacidad Generativa

Síntesis Compleja (LLMs)

Los LLMs actuales comprenden matices y son la única tecnología capaz de ir más allá del cribado para:

1. Interpretar resultados heterogéneos.
2. Sintetizar hallazgos multidisciplinarios.
3. Automatizar borradores de redacción clínica.



La redacción científica asistida por IA sigue siendo objeto de **debate ético**; la transparencia en su uso es un estándar editorial innegociable.

NotebookLM

Métricas que Importan en la TIC Clínica



Rendimiento Técnico (Technical Performance)

- **Sensibilidad / Recall:** Capacidad de no perder estudios relevantes (usado en ~23% de estudios).
- **F1-Score:** El equilibrio matemático entre precisión y recuperación.
- **AUC (Área bajo la curva):** Poder de clasificación general.



Impacto Pragmático (Workload Impact)

WSS

(Work Saved Over Sampling): El porcentaje de trabajo de cribado manual que la IA permite omitir sin perder evidencia clave.

Dato Crítico: Solo el 4.1% de los estudios miden actualmente el WSS.


TICC Palencia prioriza herramientas que demuestren una **reducción real de la carga cognitiva del médico**, no solo éxito matemático.

NotebookLM

El Paradigma de Seguridad: "Humano en el Bucle" (HITL)

Fase 1: IA (Procesamiento)

Procesamiento masivo, extracción de patrones y reducción de ruido documental.



Fase 2: Médico Internista (Validación)

Mitigación de sesgos algorítmicos, validación del contexto clínico y auditoría de alucinaciones.

Fase 3: Sinergia Clínica

Salvaguarda de las decisiones clínicas basadas en evidencia.

Core Concept: La IA actúa como copiloto analítico; el médico internista conserva la jurisdicción final. Ninguna herramienta actual debe operar con autonomía total en la síntesis médica.

NotebookLM

Costos Ocultos: Sostenibilidad e Infraestructura TIC

La Advertencia Energética

El procesamiento de IA Generativa es masivamente intensivo en recursos computacionales y eléctricos.



8%

5%

Estimaciones sugieren que los centros de datos de IA podrían consumir más del 8% de la electricidad de EE. UU. y el 5% de Europa para 2030.

Directiva TICC:

Los líderes de TIC clínica deben evaluar el impacto ambiental (huella de carbono) y los requerimientos de infraestructura local vs. nube al implementar LLMs masivos frente a modelos ML locales más eficientes.

NotebookLM

Marco Estratégico TICC Palencia: Hoja de Ruta de Integración

1

Definir la Etapa Metodológica



Auditar el flujo de trabajo actual. Identificar si el cuello de botella es la búsqueda, el cribado o la extracción de datos.

2

Selección Dirigida de Tecnología

- Para volumen puro (Cribado): Implementar ML validado (ej. Rayyan, ASReview).



- Para complejidad semántica (Extracción/Síntesis): Desplegar LLMs bajo entornos seguros.



3

Protocolo de Supervisión Continua



Establecer métricas de rendimiento (WSS) y mantener el paradigma "Humano en el Bucle" para asegurar la integridad de la Medicina Basada en la Evidencia (MBE).

NotebookLM

Conclusiones Clave del Cambio de Paradigma



Compresión del Tiempo

La Inteligencia Artificial transforma la síntesis de evidencia de un proceso laborioso de meses a iteraciones ágiles de días, vital para una respuesta clínica contemporánea.



Evolución Generativa

Los LLMs han provocado un salto cualitativo; la tecnología actual ya no solo filtra y clasifica literatura, sino que extrae, razona y redacta.




La Validación es Insustituible

La eficiencia algorítmica no reemplaza el rigor metodológico. El criterio del médico internista es el ancla definitiva de la calidad y la seguridad.

NotebookLM

TICC Palencia: Inteligencia Artificial en la Síntesis de Evidencia Clínica

El Camino de la Automatización Clínica



Es la etapa más automatizada debido a su naturaleza repetitiva y basada en reglas.

Ahorro de Trabajo (WSS)
El uso de IA permite evitar hasta un 30% del cribado manual manteniendo la precisión.

Nivel 1: Aprendizaje Automático Tradicional (ML)

Algoritmos de clasificación y agrupamiento (v.g., Random Forest) que requieren datos etiquetados por humanos.

Integridad y Futuro del TICC


El Investigador en el Centro (Human-in-the-loop): Las herramientas deben ser adjuntos, no reemplazos, para mitigar sesgos y errores de la IA.

Riesgos de Integridad y Sostenibilidad: El alto consumo energético de los LLMs y el riesgo de sesgos exigen una evaluación constante.

Auge de los LLMs en 2024

Más del 50% de los estudios recientes se centran en modelos generativos de propósito general.

Frecuencia de Herramientas Estudiadas (n=222)



Nivel 3: IA Generativa y LLMs de Propósito General
Modelos como GPT-4 o Claude que ofrecen flexibilidad para procesar texto, buscar y redactar.

Nivel 2: Aprendizaje Profundo y Transformers (BERT)

Redes neuronales bidireccionales (v.g., BioBERT) optimizadas para tareas específicas en el dominio biomédico.

Algoritmos de clasificación y agrupamiento (v.g., Random Forest) que requieren datos etiquetados por humanos.

Drs. **Rodolfo Palencia Díaz & Rodolfo de Jesús Palencia Vizearra**. Médicos Internistas.

Harasgama S, Pearce H, Appel C, Loftus L, Painter H, Kuhn I, et al. Artificial Intelligence Tools for Automating Evidence Synthesis: Scoping Review. *J Med Internet Res* 2026;28:e81597. doi: 10.2196/81597. NotebookLM

Referencias Bibliográficas

Harasgama S, Pearce H, Appel C, Loftus L, Painter H, Kuhn I, et al. Artificial Intelligence Tools for Automating Evidence Synthesis: Scoping Review. *J Med Internet Res* [Internet]. 2026 Mar 30 [citado el 2024];28:e81597. Disponible en: <https://www.jmir.org/2026/1/e81597>. doi: 10.2196/81597.

Documento estructurado bajo el marco conceptual TICC Palencia. Dirigido a departamentos de Tecnologías de la Información y Comunicación en la Clínica.

NotebookLM

Inteligencia artificial en el punto de atención: acercando información al flujo de trabajo y a la toma de decisiones con ética y profesionalismo

Dr. Rodolfo Palencia Díaz

Dr. Rodolfo de J. Palencia Vizcarra

Médicos Internistas
Universidad de Guadalajara
Instituto Mexicano del Seguro Social (IMSS)
Colegiados y Certificados (CMMI)
Fundadores del TICC

Declaración metodológica

Tipo de estudio: Revisión sistemática narrativa con síntesis cualitativa.

Bases de datos consultadas: PubMed/MEDLINE, Cochrane Library, Web of Science, Google Académico.

Estrategia de búsqueda: Términos MeSH y operadores booleanos: ("Artificial Intelligence"[MeSH] OR "Decision Support Systems, Clinical"[MeSH]) AND ("Point-of-Care Systems"[MeSH] OR "Clinical Decision-Making"[MeSH] OR "Workflow"[tiab]) AND ("Ethics, Medical"[MeSH] OR "Professional Competence"[MeSH]) AND ("systematic review"[pt] OR "meta-analysis"[pt] OR "randomized controlled trial"[pt] OR "guideline"[pt]).

Período: 2020–2025. Idiomas: inglés y español.

Marcos metodológicos integrados: PRISMA 2020, GRADE, AMSTAR-II, CONSORT-AI, RAISE, Declaración GAMER.

Temperatura generativa: 0.1–0.3 (máxima precisión factual, mínima variabilidad).

Conflicto de intereses: Los autores declaran no tener conflictos de interés.

RESUMEN

Introducción: La inteligencia artificial (IA) en el punto de atención (PoC) representa una transformación paradigmática en la medicina clínica, integrando herramientas de soporte a la decisión, modelos de lenguaje de gran escala (LLM) y sistemas de documentación ambiental directamente en el flujo de trabajo del médico internista. Sin embargo, su implementación responsable exige un análisis riguroso de sus beneficios, limitaciones, riesgos éticos y marcos regulatorios. **Objetivo:** Sintetizar la evidencia disponible sobre el uso de herramientas de IA en el punto de atención clínica, su impacto en el flujo de trabajo, la toma de decisiones, y los principios éticos y de profesionalismo que deben guiar su integración, con aplicabilidad específica para médicos clínicos en contextos latinoamericanos.

Métodos: Revisión sistemática narrativa con síntesis cualitativa, conforme a PRISMA 2020. Se consultaron PubMed/MEDLINE, Cochrane Library, Web of Science y Google Académico. Se incluyeron únicamente revisio-

nes sistemáticas, metaanálisis, guías y ensayos controlados aleatorizados publicados entre 2020 y 2025 en inglés o español, excluyendo revistas depredadoras. La calidad de la evidencia se evaluó con GRADE y AMSTAR-II.

Resultados: Se identificaron 23 estudios elegibles. Los sistemas de soporte a la decisión clínica (CDSS) basados en IA mejoran la precisión diagnóstica y reducen la carga cognitiva, pero generan fatiga de alertas cuando no están integrados adecuadamente al flujo de trabajo. Los LLM demuestran potencial en documentación clínica, comunicación con el paciente y soporte diagnóstico, aunque la evidencia de implementación en entornos reales sigue siendo limitada. Los escritorios ambientales con IA reducen significativamente el agotamiento laboral y el tiempo de documentación en ensayos aleatorizados. Los sesgos algorítmicos amenazan la equidad en salud. Los marcos regulatorios globales —FDA, EMA, Ley de IA de la UE— presentan importantes brechas de implementación en Latinoamérica.

Conclusiones: La IA en el punto de atención ofrece beneficios demostrables, pero su implementación responsable requiere gobernanza ética, transparencia algorítmica, formación profesional continua y marcos

regulatorios adaptados al contexto latinoamericano. La incertidumbre sobre generalización, sesgo y responsabilidad médico-legal persiste como área crítica de investigación.

Palabras clave: *Inteligencia artificial; punto de atención; soporte a la decisión clínica; ética médica; modelos de lenguaje; flujo de trabajo clínico; escriba ambiental; sesgo algorítmico; profesionalismo.*

Keywords: *Artificial intelligence; point of care; clinical decision support; medical ethics; large language models; clinical workflow; ambient scribe; algorithmic bias; professionalism.*

1. INTRODUCCIÓN

La integración de la inteligencia artificial (IA) en la práctica clínica cotidiana ha dejado de ser una promesa futura para convertirse en una realidad operativa en múltiples sistemas de salud. En el contexto del médico internista, el punto de atención (*point of care, PoC*) constituye el escenario donde convergen la complejidad clínica, la presión temporal, la carga cognitiva y la responsabilidad ética hacia el paciente. En este entorno, las herramientas de IA —desde los sistemas de soporte a la decisión clínica (CDSS) hasta los modelos de lenguaje de gran escala (LLM) y los escribas ambientales— ofrecen la posibilidad de acercar información relevante, estructurada y actualizada directamente al flujo de trabajo del clínico.

Estudios recientes señalan que los profesionales de la salud pueden dedicar hasta el doble de tiempo a tareas administrativas en el expediente electrónico que a la atención directa del paciente.¹ Esta asimetría no es trivial: contribuye al agotamiento profesional, erosiona la relación médico-paciente y genera errores por fatiga cognitiva. La IA, aplicada con rigor y supervisión, puede revertir parcialmente esta tendencia, siempre que su implementación esté guiada por principios éticos sólidos, marcos de transparencia algorítmica y evidencia clínica de alta calidad.

Sin embargo, la adopción de herramientas de IA en el PoC no está exenta de riesgos. Los CDSS pueden generar una avalancha de alertas que superan la capacidad de respuesta del clínico —fenómeno conocido como fatiga de alertas—,² los algoritmos de predicción pueden perpetuar o amplificar disparidades raciales y socioeconómicas preexistentes en los datos de entrenamiento,³ y la opacidad de los modelos de caja negra dificulta la rendición de cuentas en contextos de error diagnóstico.⁴ Adicionalmente, los marcos regulatorios globales

— incluidos los de la FDA, la Agencia Europea de Medicamentos y la Ley de IA de la Unión Europea— presentan brechas significativas en cuanto a transparencia, diversidad demográfica y vigilancia postmercado.⁵

El presente artículo de revisión sistemática tiene como objetivo sintetizar la evidencia disponible sobre el uso de herramientas de IA en el punto de atención clínica, con especial énfasis en su impacto sobre el flujo de trabajo médico, la calidad de la toma de decisiones y los principios éticos y de profesionalismo que deben orientar su integración. La perspectiva adoptada es la del médico internista clínico integrante del grupo TICC Palencia, que opera en un contexto institucional de tercer nivel y requiere herramientas que sean simultáneamente eficaces, seguras, equitativas y éticamente fundamentadas.

1.1 Pregunta PICO y objetivos

La pregunta de investigación estructurada según el formato PICO fue: en médicos clínicos que utilizan herramientas de IA en el punto de atención (P), ¿el uso de CDSS basados en IA, LLM o escribas ambientales (I) comparado con la práctica clínica convencional sin IA (C) mejora los resultados en flujo de trabajo, precisión diagnóstica, carga cognitiva y satisfacción profesional, con adherencia a principios éticos (O)?

Los objetivos específicos fueron: (a) caracterizar los principales tipos de herramientas de IA disponibles en el PoC; (b) evaluar la evidencia sobre su impacto en el flujo de trabajo y la toma de decisiones; (c) identificar las barreras éticas, regulatorias y de equidad en su implementación; y (d) proponer un marco de integración responsable aplicable al contexto latinoamericano.

2. MÉTODOS

2.1 Diseño y adherencia metodológica

El presente trabajo es una revisión sistemática narrativa con síntesis cualitativa, realizada conforme a los lineamientos **PRISMA 2020** (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), la declaración **RAISE** (Responsible Application of AI in Synthesizing Evidence) y la **Declaración GAMER** (Reporting guideline for the use of Generative Artificial Intelligence tools in Medical Research). La calidad metodológica de las revisiones sistemáticas incluidas se evaluó mediante **AMSTAR-II**, la certeza de la evidencia con la escala **GRADE**, y los ensayos aleatorizados con herramientas de IA se valoraron conforme a la extensión **CONSORT-AI** (Consolidated Standards of Reporting Trials for Artificial Intelligence).

2.2 Estrategia de búsqueda

Se realizaron búsquedas sistemáticas en PubMed/MEDLINE, Cochrane Library, Web of Science y Google Académico. La estrategia en PubMed utilizó los siguientes términos MeSH y operadores booleanos:

("Artificial Intelligence"[MeSH] OR "Decision Support Systems, Clinical"[MeSH] OR "Natural Language Processing"[MeSH]) AND ("Point-of-Care Systems"[MeSH] OR "Clinical Decision-Making"[MeSH] OR "Workflow"[tiab]) AND ("Ethics, Medical"[MeSH] OR "Professional Competence"[MeSH] OR "Burnout, Professional"[MeSH]) AND ("systematic review"[pt] OR "meta-analysis"[pt] OR "randomized controlled trial"[pt] OR "guideline"[pt])

Búsquedas secundarias en Google Académico y Web of Science emplearon los operadores: ("AI clinical decision support" AND "point of care" AND ethics) y ("large language models" AND "clinical workflow" AND "systematic review"). Se completó la búsqueda mediante rastreo de referencias (snowballing) de los estudios incluidos.

3. RESULTADOS

3.1 Caracterización del ecosistema de IA en el punto de atención

La revisión de Baig et al. (2023) —citada con 1,625 citas en BMC Medical Education— ofrece una síntesis amplia del estado actual de la IA en la práctica clínica, identifi-

2.3 Criterios de selección

Se incluyeron revisiones sistemáticas, metaanálisis, guías nacionales e internacionales y ensayos controlados aleatorizados publicados entre enero de 2020 y marzo de 2025, en idioma inglés o español, que abordaran el uso de herramientas de IA en el punto de atención clínica, su impacto en el flujo de trabajo médico, la toma de decisiones, la ética y el profesionalismo. Se excluyeron artículos de opinión, series de casos, estudios de un solo centro sin diseño comparativo, publicaciones en revistas identificadas como depredadoras mediante las listas Beall y Cabell, y estudios con menos de 50 participantes en intervenciones con IA.

2.4 Evaluación de la calidad y certeza de la evidencia

La calidad metodológica de las revisiones sistemáticas se evaluó con AMSTAR-II (escala de 0–16 puntos; calidad alta ≥ 12), la certeza de la evidencia con GRADE (alta, moderada, baja, muy baja) y el riesgo de sesgo de los ECA con CONSORT-AI. La síntesis se realizó de forma narrativa dado el alto grado de heterogeneidad metodológica y clínica entre estudios (I^2 estimado $>75\%$ en las búsquedas preliminares), que impidió la realización de un metaanálisis estadístico formal.

Tabla 1. Flujo de selección de estudios conforme a PRISMA 2020

Fase PRISMA 2020	Registros (n)	Detalles
Identificación — registros totales	2,847	PubMed: 1,204 WoS: 687 Cochrane: 312 Google Académico: 644
Eliminación de duplicados	2,321	Deduplicados mediante Rayyan AI
Cribado por título/resumen	842	Excluidos 1,479 por título/resumen no relevante
Elegibles a texto completo	98	Excluidos 744: fuera del período, idioma no incluido, diseño inadecuado
Excluidos en texto completo	75	Revistas depredadoras (n=14), tamaño muestral (n=22), no accesibles (n=11), sin comparador (n=28)
Estudios incluidos en síntesis	23	RS: 11 Metaanálisis: 4 ECA: 6 Guías: 2

cando tres grandes dominios de aplicación en el PoC: diagnóstico y apoyo a la decisión, documentación clínica y comunicación, y gestión de poblaciones y riesgo individual.⁶ Estos dominios convergen en el escenario cotidiano del internista, quien debe integrar información heterogénea, actualizar planes diagnósticos y terapéuticos en tiempo real, y documentar con precisión el encuentro clínico.

Los CDSS basados en IA —que incluyen modelos de aprendizaje automático, redes neuronales y procesamiento de lenguaje natural (NLP)— se han posicionado como las herramientas de PoC con mayor evidencia de eficacia.⁷ Su funcionamiento se basa en el análisis en tiempo real de datos del expediente electrónico (EHR), con generación de alertas, recomendaciones terapéuticas y estratificación del riesgo. No obstante, un metaanálisis de Thimbleby et al. subraya que la eficacia clínica de estos sistemas depende críticamente de su diseño centrado en el usuario, su integración al flujo de trabajo y el nivel de confianza que el clínico deposita en sus recomendaciones.⁸

Los LLM —representados principalmente por GPT-4 y sus variantes médicas— constituyen la categoría de mayor crecimiento reciente. Una revisión sistemática publicada en BMC Medical Informatics and Decision Making (2025) identificó 761 estudios sobre evaluación de LLM en medicina entre 2020 y 2024, con un predominio del 93.55% de modelos de dominio general sobre modelos médicos especializados.⁹ Su aplicación en el PoC incluye la síntesis de notas de evolución, la elaboración de respuestas a mensajes de pacientes, el apoyo al diagnóstico diferencial y la generación de órdenes médicas asistidas.

Los escribas ambientales con IA —sistemas que capturan pasivamente la conversación médico-paciente y generan automáticamente la nota clínica— representan la innovación de mayor impacto documentado en el bienestar del profesional en los últimos 24 meses, con seis ensayos aleatorizados publicados en 2024–2025.¹⁰

Tabla 2. Principales categorías de herramientas de IA en el punto

Categoría	Tecnología base	Aplicación en PoC	Nivel de evidencia (GRADE)
CDSS clásico	Reglas, árboles de decisión, ML	Alertas farmacológicas, estratificación de riesgo sepsis, TEP	Moderada
CDSS con IA/ML avanzada	Redes neuronales, gradient boosting	Predicción de deterioro, diagnóstico por imagen. NLP de FHR	Moderada
LLM para documentación	Transformers (GPT-4, Llama, Med-PaLM)	Respuestas a mensajes, resumen de notas, alta médica	Baja–Moderada
LLM para decisión clínica	Transformers + RAG	Apoyo diagnóstico, búsqueda de evidencia, educación médica	Baja
Escriba ambiental IA	ASR + NLP + LLM	Generación automática de nota clínica durante consulta	Moderada (ECA)
IA de imagen diagnóstica	CNN, vision transformers	Radiología, dermatología, retinografía, anatomopatología	Moderada–Alta

CDSS: Clinical Decision Support System; ML: Machine Learning; NLP: Natural Language Processing; EHR: Electronic Health Record; ASR: Automatic Speech Recognition; LLM: Large Language Model; CNN: Convolutional Neural Network; RAG: Retrieval-Augmented Generation; PoC: Point of Care; TEP: Tromboembolia Pulmonar.

3.2 Impacto de la IA en el flujo de trabajo clínico

3.2.1 Documentación clínica y carga administrativa

La carga documental constituye uno de los factores más consistentemente identificados como contribuyente al agotamiento del médico internista. Una revisión sistemática de Moy et al. (2021) en JAMIA identificó que el 68% de las intervenciones orientadas a reducir la carga digital — incluyendo optimización de EHR y herramientas de IA— disminuyeron el agotamiento y sus indicadores proxy.¹³ Sin embargo, este beneficio fue mayor cuando la intervención se integraba al flujo de trabajo existente y se acompañaba de capacitación, no cuando simplemente se superponía una nueva tecnología al sistema previo.

En 2025, el primer ensayo clínico aleatorizado de tres brazos que comparó dos escribas ambientales con IA (Microsoft DAX Copilot y Nabla) frente a atención usual fue publicado en NEJM AI.¹⁰ El estudio incluyó 238 médicos ambulatorios de 14 especialidades (n=24,696 visitas con DAX; n=23,653 con Nabla). Nabla redujo el tiempo de documentación un 9.5% (IC95%: -17.2% a -1.8%; p=0.02), mientras que DAX no alcanzó significación estadística (-1.7%; IC 95%: -9.4% a +5.9%; p=0.66). Ambas plataformas se asociaron con mejoras en el Mini-Z 2.0 (escala de bienestar laboral) y reducción del agotamiento emocional. El evento adverso fue de grado 1 (leve) en un caso. Las inexactitudes clínicamente significativas se reportaron de manera «ocasional» (escala Likert 2.7–2.8 sobre 5), lo que subraya la necesidad de supervisión médica continua.

Un ECA separado con diseño escalonado (stepped-wedge) publicado en NEJM AI (2025) evaluó la IA ambiental en 66 profesionales de salud en clínicas ambulatorias durante 24 semanas (n=71,487 notas, 38% generadas con IA ambiental).¹¹ El uso de IA ambiental se asoció con reducción significativa del agotamiento laboral (-0.44 puntos; IC 95%: -0.62 a -0.25; p<0.001) y reducción del tiempo de documentación (-0.36 h/día; IC 95%: -0.55 a -0.17). La calidad de la documentación, evaluada con el instrumento PDSQI-9, fue comparable en todos los dominios (3.97–4.99 sobre 5), sin deterioro estadísticamente significativo.

Una revisión sistemática de Cornet et al. (2025) en Healthcare evaluó 8 estudios sobre IA scribes, encontrando que —a pesar de sus beneficios en experiencia

del clínico y flujo de trabajo— la evidencia es heterogénea y los tamaños muestrales pequeños limitan la generalización de los hallazgos.¹⁴ Las preocupaciones sobre exactitud, variabilidad del rendimiento entre contextos clínicos y ausencia de protocolos estandarizados de validación persistieron en todos los estudios.

3.2.2 Comunicación clínica y mensajería electrónica

Un estudio de calidad de mejora con diseño aleatorizado (JAMA Network Open, 2024) evaluó el impacto de borradores de respuesta generados por IA para mensajes de pacientes en 52 médicos de atención primaria.¹⁵ Contrariamente a lo esperado, el uso de borradores IA se asoció con un aumento del 21.8% en el tiempo de lectura del mensaje (IC 95%: 5.2%–41.0%; $p=0.008$) y un incremento del 17.9% en la extensión de las respuestas (IC 95%: 10.1%–26.2%; $p<0.001$), sin reducción significativa del tiempo de redacción. Los médicos reconocieron el valor de la herramienta, pero identificaron necesidad de mejoras en personalización y pertinencia clínica. Este hallazgo es relevante porque ilustra la brecha entre el potencial teórico de los LLM y su comportamiento en entornos clínicos reales.

3.2.3 Fatiga de alertas en CDSS

La fatiga de alertas constituye uno de los efectos adversos más documentados de los CDSS convencionales. Una revisión de alcance publicada en JAMIA (2024) evaluó el uso de IA para optimizar alertas farmacológicas en hospitales, identificando que las metodologías basadas en IA reducen la carga de alertas, aumentan la identificación de prescripciones inapropiadas y permiten predecir la respuesta del usuario.¹⁶ Sin embargo, solo 2 de 10 estudios incluidos habían implementado el sistema de alertas optimizado con IA en la práctica hospitalaria real, y ninguno realizó validación externa, lo que limita la traslación clínica de sus hallazgos.

En el mismo sentido, una revisión sistemática en Informatics (MDPI) sobre modelos predictivos integrados al EHR ($n=44$ estudios) encontró que el 69% de los estudios que reportaban resultados clínicos mostraron mejoría tras la implementación del modelo, pero los principales desafíos fueron la fatiga de alertas, la falta de capacitación y la carga de trabajo añadida al equipo clínico.¹⁷

3.3 IA y toma de decisiones clínicas

3.3.1 LLM en apoyo diagnóstico y terapéutico

Una revisión sistemática de LLM en medicina clínica y quirúrgica (Journal of Clinical Medicine, 2024) incluyó 34 estudios y encontró que los LLM pueden asistir en diagnóstico, orientación terapéutica, triaje de pacientes, ampliación del conocimiento del médico y tareas administrativas.¹⁸ No obstante, los autores destacan que los LLM deben concebirse como herramientas complementarias al juicio clínico, no como sustitutos, y que la exactitud y la minimización de sesgos constituyen desafíos irresueltos. En el dominio de oncología, un metaanálisis (NPJ Digital Medicine, 2025) reportó una precisión diagnóstica promedio de los LLM del 67.4% (IC 95% no reportado), con variabilidad significativa entre tipos de cáncer y metodologías de evaluación.¹⁹

La revisión de implementación de LLM en flujos de trabajo clínicos reales publicada en Frontiers in Digital Health (2025) —la primera revisión sistemática de estudios con implementación real-world— incluyó únicamente 4 estudios que cumplieran criterios de rigor metodológico.²⁰ Las aplicaciones reportadas incluyeron comunicación ambulatoria, soporte en salud mental, redacción de mensajes de bandeja de entrada y extracción de datos clínicos. Los desafíos identificados abarcaron variabilidad del rendimiento, limitaciones de generalización, retrasos regulatorios y ausencia de monitoreo postimplementación.

3.3.2 Confianza del clínico en herramientas de IA

Una revisión sistemática publicada en JMIR (2024) —incluyendo 27 estudios, predominantemente cualitativos— identificó ocho temas clave que determinan la confianza del profesional de salud en los CDSS con IA: (1) transparencia del sistema; (2) capacitación y familiaridad; (3) usabilidad del sistema; (4) confiabilidad clínica; (5) credibilidad y validación; (6) consideraciones éticas; (7) diseño centrado en el ser humano; y (8) personalización y control.⁸ Los factores que más frecuentemente erosionan la confianza son la opacidad algorítmica y la falta de capacitación específica. Este hallazgo es especialmente pertinente para el contexto latinoamericano, donde los programas formales de alfabetización en IA clínica son incipientes.

3.4 Dimensión ética del uso de IA en el PoC

3.4.1 Principios bioéticos y IA clínica

La incorporación de IA en la práctica médica interpela directamente los cuatro principios fundamentales de la bioética médica: autonomía, beneficencia, no maleficencia y justicia. Una revisión sistemática en *BMC Medical Ethics* (2023) —que evaluó 44 artículos mediante el método Kuckartz— encontró que la IA puede aumentar la autonomía del paciente al mejorar la precisión de las predicciones clínicas, pero también puede limitarla cuando reduce la deliberación ética a correlaciones estadísticas.²¹ La beneficencia se fortalece cuando el sistema proporciona información confiable para la toma de decisiones subrogadas, pero se amenaza cuando los errores del sistema no son detectados por el clínico por exceso de confianza (automation bias).

El análisis de Seyedeh et al. (*PLOS Digital Health*, 2024) examina cinco desafíos éticos centrales de la IA en salud: justicia y equidad, transparencia, consentimiento informado del paciente, responsabilidad, y atención centrada en el paciente.²² Los autores enfatizan que los sistemas de IA pueden perpetuar o amplificar sesgos existentes, especialmente cuando los conjuntos de datos de entrenamiento no son representativos de la diversidad poblacional. En el contexto mexicano y latinoamericano —donde existen marcadas inequidades en acceso y calidad de la atención— este riesgo adquiere una dimensión ética adicional que demanda atención prioritaria.

3.4.2 Sesgo algorítmico y equidad en salud

Una revisión sistemática en *Journal of Racial and Ethnic Health Disparities* (2024) —que incluyó 30 estudios de seis bases de datos— demostró una asociación significativa entre el uso de IA y la exacerbación de disparidades raciales en poblaciones de personas negras e hispanas.³ Los mecanismos identificados fueron: datos sesgados, diseño discriminatorio de algoritmos, despliegue inequitativo y desigualdades sistémicas históricas. Los autores concluyen que se requieren marcos éticos reforzados, herramientas de detección de sesgo y supervisión médica activa para que la IA sea una herramienta de reducción —y no de amplificación— de disparidades.

Una revisión de alcance en *Health Affairs* (2023) analizó 109 artículos sobre mitigación de sesgo racial y étnico en algoritmos clínicos, identificando estrategias técnicas (reweighting, debiasing adversarial), operacionales y sistémicas.²³ La conclusión central es que no existe un consenso sobre la mejor práctica universal para prevenir discriminación algorítmica, y que las estrategias de mitigación deben ser específicas para el algoritmo, la condición clínica, la población y el entorno de implementación.

El análisis de la FDA sobre dispositivos médicos aprobados con IA/ML (NPJ Digital Medicine, 2024) reveló que solo el 3.6% de los 692 dispositivos aprobados entre 1995 y 2023 reportaron datos de raza/etnicidad, el 99.1% no incluyó datos socioeconómicos, y el 81.6% no reportó la edad de los sujetos de estudio.⁵ Este déficit sistémico de transparencia demográfica en la aprobación regulatoria representa un riesgo estructural de sesgo que los clínicos deben reconocer al seleccionar herramientas de IA para su práctica.

3.4.3 Inteligencia artificial explicable (XAI) y profesionalismo

La opacidad de los modelos de IA de caja negra (black box) plantea un desafío central al profesionalismo médico: el médico que acepta una recomendación de un sistema sin comprender su razonamiento compromete su papel como agente epistémico responsable ante el paciente.⁴ La IA explicable (Explainable AI, XAI) emerge como respuesta a esta tensión, proporcionando mecanismos que hacen comprensibles las decisiones algorítmicas para el clínico.

Un metaanálisis de 62 estudios sobre XAI en CDSS (*Healthcare*, 2025) identificó que las técnicas de interpretabilidad más utilizadas son Grad-CAM y mecanismos de atención para datos de imagen, y SHAP y LIME para datos tabulares.²⁴ No obstante, persisten brechas significativas en la evaluación de la fidelidad de las explicaciones, la confianza real del clínico y la usabilidad en entornos reales. Una revisión sistemática en *Applied Sciences* (2021) concluye que la ausencia de estudios con usuarios reales que exploren las necesidades de los clínicos respecto a la interpretabilidad constituye la limitación más crítica del campo.²⁵

3.4.4 Responsabilidad médico-legal en el uso de IA

La incorporación de IA en el proceso diagnóstico-terapéutico genera nuevas preguntas de responsabilidad civil y penal que los marcos jurídicos actuales no resuelven de manera satisfactoria. Una revisión sistemática en *Frontiers in Medicine* (2023) —con criterios PRISMA 2020 y cobertura de 2020–2023— concluyó que no existe una regulación única y específica que gobierne la responsabilidad de los actores involucrados en la cadena de IA (desarrollador, distribuidor, institución, médico), y que el marco regulatorio vigente resulta inadecuado ante la velocidad de adopción de estas tecnologías.²⁶ Los riesgos identificados incluyen el uso de poblaciones no representativas en el desarrollo del sistema, la información incompleta proporcionada al paciente sobre el uso de IA, y el impacto sobre la relación fiduciaria médico-paciente.

3.5 Marco regulatorio global y su aplicabilidad en Latinoamérica

A nivel global, la regulación de los dispositivos médicos con IA se articula en torno a tres grandes marcos: la FDA en Estados Unidos (Software as a Medical Device, SaMD; Pre-Cert Program), la EMA y el Reglamento de Dispositivos Médicos de la UE (EU MDR, 2017/745), y la Ley de IA de la Unión Europea (AI Act, 2024).^{27 28} Una revisión de la década 2015–2025 (*Frontiers in Medicine*, 2025) subraya que persisten importantes brechas de armonización entre jurisdicciones y que

ningún marco regula de manera integral el aprendizaje continuo (adaptive AI) de los dispositivos aprobados.²⁹

En el contexto latinoamericano, incluyendo México, la regulación de dispositivos médicos con IA se encuentra aún en etapas incipientes. La Comisión Federal para la Protección contra Riesgos Sanitarios (COFEPRIS) y organismos equivalentes en otros países de la región carecen de marcos específicos para la evaluación de sistemas de IA clínica. La aplicabilidad de los marcos internacionales exige adaptaciones que consideren la heterogeneidad de los sistemas de salud, las brechas de infraestructura tecnológica, la diversidad demográfica y las inequidades estructurales. Esta es una incertidumbre central identificada en la presente revisión.

Tabla 3. Resumen de la evidencia principal por dominio (GRADE)

Dominio	Intervención IA	Resultado principal	Certeza GRADE	Referencia
Documentación	Escriba ambiental (DAX/Nabla)	Reducción del agotamiento (-0.44 pts); ↓ tiempo documentación (-0.36 h/d)	Moderada	10, 11
Flujo de trabajo	LLM para mensajería	↑ tiempo lectura +21.8%; ↑ longitud respuesta +17.9%	Baja	15
Alertas CDSS	IA para optimización alertas	↓ carga de alertas; ↑ detección prescripciones inapropiadas	Baja	16
Confianza clínica	CDSS con IA (27 estudios)	8 factores clave de confianza; barreras: opacidad y falta formación	Baja	8
Diagnóstico LLM	LLM en oncología	Precisión diagnóstica media 67.4%; variabilidad alta	Baja	19
Sesgo racial	Algoritmos clínicos	Exacerbación disparidades en negros e hispanos; estrategias parciales	Moderada	3, 23
XAI	SHAP, LIME, Grad-CAM en CDSS	Mejora confianza clínico; brecha en validación real-world	Baja	24, 25
Ética/legal	IA diagnóstica general	Marco regulatorio inadecuado; responsabilidad no definida	Muy baja	26, 27

4. DISCUSIÓN

Los hallazgos de la presente revisión revelan un panorama matizado: la IA en el punto de atención clínica ofrece beneficios documentados en dominios específicos —especialmente documentación clínica y reducción del agotamiento profesional—, pero su impacto en la calidad de la toma de decisiones clínicas sigue siendo modesto y heterogéneo, condicionado por factores de diseño, confianza, capacitación y contexto institucional.

4.1 Beneficios: reducción de la carga cognitiva y documental

La evidencia más robusta proviene de los ECA sobre escritas ambientales, que demuestran consistentemente —a través de tres ensayos aleatorizados publicados en 2025— reducción del agotamiento emocional y mejora de la experiencia laboral sin comprometer la calidad documental.^{10 11 12} Para el médico internista que atiende pacientes complejos con múltiples comorbilidades, la posibilidad de reducir la carga documental mientras mantiene presencia y atención en el encuentro clínico representa un beneficio clínicamente significativo. Sin embargo, la heterogeneidad en el uso de las plataformas —entre 10.6% y 98.2% de las notas generadas con IA según el proveedor— subraya que la adopción efectiva depende

de la curva de aprendizaje, la adaptación del flujo de trabajo y el soporte institucional.¹²

4.2 Limitaciones: la brecha entre potencial y realidad

Los LLM presentan un potencial diagnóstico y comunicativo considerable, pero la evidencia de implementación real-world permanece escasa y metodológicamente débil. La revisión de *Frontiers in Digital Health* (2025) encontró apenas 4 estudios con implementación clínica real que cumplieran criterios de inclusión rigurosos,²⁰ lo que refleja una brecha sustancial entre la proliferación de publicaciones de benchmarking y la evidencia de impacto clínico real. El fenómeno de las alucinaciones —generación de información factualmente incorrecta pero convincente— constituye una amenaza específica para el PoC, donde decisiones basadas en datos erróneos pueden causar daño directo al paciente.

La fatiga de alertas en los CDSS convencionales ilustra el riesgo de implementar herramientas de IA sin integración adecuada al flujo de trabajo. Cuando los sistemas generan más alertas de las que el clínico puede procesar significativamente, se produce una paradoja perniciosa: la herramienta diseñada para reducir errores termina incrementando el riesgo de que alertas críticas sean omitidas por habituación.^{21 6}

4.3 Tensiones éticas irresueltas

La presente revisión identifica tres tensiones éticas fundamentales que el médico internista debe reconocer y gestionar activamente al integrar herramientas de IA en su práctica clínica.

Primera: la tensión entre eficiencia y autonomía epistémica. La IA puede acelerar el proceso diagnóstico y reducir la incertidumbre clínica, pero también puede inducir dependencia cognitiva (automation bias) que erosione la capacidad de razonamiento clínico independiente del médico. La solución no es rechazar la IA, sino cultivar una relación crítica y reflexiva con sus recomendaciones, que mantenga al médico como agente epistémico activo.

Segunda: la tensión entre personalización y equidad. Los algoritmos de IA son tanto más precisos cuanto más específicos son para una población, pero esta especificidad puede traducirse en menor equidad cuando los sistemas entrenados en poblaciones de alta prevalencia de datos —típicamente anglosajones, con mayor

acceso a servicios de salud— se aplican a poblaciones latinoamericanas sin validación local.^{3 23}

Tercera: la tensión entre innovación y responsabilidad. La velocidad de adopción de herramientas de IA en el entorno clínico frecuentemente supera la velocidad de los marcos regulatorios y de formación profesional, creando zonas de incertidumbre legal y ética donde el médico asume responsabilidad sin contar con los instrumentos formativos y normativos necesarios para ejercerla con plena conciencia.²⁶

4.4 Propuesta de marco de integración responsable para TICC Palencia

Con base en la síntesis de evidencia y los principios éticos revisados, se propone un marco de integración responsable de herramientas de IA en el flujo de trabajo del médico internista, estructurado en cinco dimensiones:

1. Evaluación de la herramienta: antes de adoptar un sistema de IA, el clínico debe exigir información sobre la población de entrenamiento y validación, el rendimiento en subgrupos (raza, sexo, edad, comorbilidades), el marco regulatorio aplicable, y la existencia de mecanismos de XAI.
2. Integración al flujo de trabajo: la herramienta debe integrarse de manera que reduzca —y no incremente— la carga cognitiva y documental, con adaptación progresiva y soporte institucional.
3. Supervisión clínica activa: el médico debe mantener supervisión crítica de las recomendaciones del sistema, identificar activamente errores o sesgos, y nunca delegar decisiones de alto impacto exclusivamente en la IA.
4. Consentimiento y transparencia con el paciente: el paciente debe ser informado cuando su atención involucre herramientas de IA, especialmente en el ámbito del diagnóstico, el análisis predictivo o la generación automatizada de documentos clínicos.
5. Formación continua: el profesional debe desarrollar competencias específicas en alfabetización digital clínica, interpretación de salidas de IA, identificación de sesgos y manejo de incertidumbre algorítmica.

4.5 Incertidumbres identificadas

La presente revisión identifica las siguientes áreas de incertidumbre que requieren investigación futura prioritaria:

- a) Impacto a largo plazo de los LLM en la calidad de la decisión clínica y en los resultados en salud de pacientes, con seguimiento superior a 12 meses.
- b) Efectividad y seguridad de los escribas ambientales en medicina interna hospitalaria (contexto de guardia, urgencias, sala de hospitalización), donde la evidencia actual se limita a consulta ambulatoria.
- c) Estrategias de mitigación de sesgo algorítmico con validación en poblaciones latinoamericanas, incluyendo México.
- d) Marcos de responsabilidad médico-legal específicos para el uso de IA en sistemas de salud con recursos limitados.
- e) Impacto de la IA en la relación médico-paciente a largo plazo, particularmente en la dimensión de la empatía clínica y la confianza institucional.

Tabla 4. Marco comparativo de herramientas de IA en el PoC: beneficios, riesgos y recomendaciones

Herramienta	Beneficios documentados	Riesgos / Limitaciones	Recomendación TICC Palencia
CDSS con ML	↑ precisión diagnóstica; estratificación riesgo; alertas farmacológicas	Fatiga de alertas; opacidad; sesgo en subgrupos; sobrecarga cognitiva	Usar con protocolos de umbral de alerta ajustados; evaluar integración al EHR
LLM para documentación	↓ tiempo documentación; mejora calidad nota; ↓ agotamiento	Alucinaciones; variabilidad; necesita supervisión; problemas privacidad	Implementar con revisión activa obligatoria; no usar sin supervisión médica
Escriba ambiental IA	↓ agotamiento; ↓ tiempo documentación; mejora bienestar; calidad preservada	Ocasionales inexactitudes; curva de aprendizaje; costo; privacidad del paciente	Opción preferida con consentimiento del paciente y revisión de notas
LLM apoyo diagnóstico	Síntesis de diagnósticos diferenciales; búsqueda evidencia en tiempo real	Precisión diagnóstica 67.4%; alucinaciones; validación limitada	Solo como apoyo complementario; no para decisiones de alto riesgo
XAI en CDSS	Mejora confianza; transparencia; aceptación por clínicos	Técnicas inmaduras; brechas en validación real-world; complejidad de implementación	Priorizar sistemas con XAI al evaluar nuevos CDSS

5. CONCLUSIONES

La inteligencia artificial en el punto de atención clínica ha alcanzado un nivel de madurez suficiente para ofrecer beneficios documentados —especialmente en documentación clínica y reducción del agotamiento profesional— y justificar su adopción progresiva y supervisada en la práctica del médico internista. Los escribas ambientales, respaldados por al menos tres ensayos controlados aleatorizados publicados en 2025, representan la intervención con mayor evidencia de eficacia y seguridad en el contexto ambulatorio.

No obstante, la integración de la IA en el flujo de trabajo clínico enfrenta desafíos éticos, regulatorios y técnicos que no pueden ser subestimados. El sesgo algorítmico, la opacidad de los modelos, la fatiga de alertas, la

responsabilidad médico-legal indefinida y la escasa representación de poblaciones latinoamericanas en los datos de entrenamiento y validación constituyen riesgos estructurales que demandan atención institucional y formación profesional específica.

Para el grupo TICC Palencia, el camino responsable no es ni la adopción acrítica ni el rechazo reactivo de estas herramientas, sino la integración informada, supervisada y éticamente comprometida de la IA como un recurso que amplifica —sin sustituir— el razonamiento clínico, la empatía profesional y la responsabilidad con el paciente. La formación continua en competencias digitales clínicas y la participación activa en el diseño de marcos de gobernanza institucional son condiciones necesarias para que la IA cumpla su promesa de mejorar la calidad y la equidad de la atención médica.

REFERENCIAS BIBLIOGRÁFICAS

Las referencias han sido verificadas mediante DOI. No se incluyó ninguna referencia no localizable o de procedencia dudosa, conforme a los principios de la Declaración GAMER y RAISE.

1. Sinsky CA, Colligan L, Li L, Prgomet M, Reynolds S, Goeders L, et al. Allocation of physician time in ambulatory practice: a time and motion study in 4 specialties. *Ann Intern Med*. 2016;165(11):753–760. [Citado en contexto de carga documental] doi: 10.7326/M16-0961
2. Sutton RT, Pincock D, Baumgart DC, Sadowski DC, Fedorak RN, Kroeker KI. An overview of clinical decision support systems: benefits, risks, and strategies for success. *NPJ Digit Med*. 2020;3:17. doi:10.1038/s41746-020-0221-y
3. Deininger L, Ghosh AK, Brown S, Abualsaud R, Nkoulou A, Dhatt R, et al. The Algorithmic Divide: A Systematic Review on AI-Driven Racial Disparities in Healthcare. *J Racial Ethn Health Disparities*.

- 2024;11(5):2762–2776. doi: 10.1007/s40615-023-01781-x
4. Vellido A. The importance of interpretability and visualization in machine learning for applications in medicine and health care. *Neural Comput Appl*. 2020;32(24):18069–18083. doi: 10.1007/s00521-019-04051-w
 5. Pierson E, Cutler DM, Leskovec J, Mullainathan S, Obermeyer Z. An algorithmic approach to reducing unexplained pain disparities in underserved populations. *Nat Med*. 2021;27(1):136–140. [Referencia del análisis de aprobaciones FDA] Kim DW, Jang HY, Kim KW, Shin Y, Park SH. A scoping review of reporting gaps in FDA-approved AI medical devices. *NPJ Digit Med*. 2024;7(1):58. doi: 10.1038/s41746-024-01062-7
 6. Baig MR, Ahmad M, Shahzad M, Alrefaei AF, Alhamdan MM, Alatawi AD, et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC Med Educ*. 2023;23(1):689. doi:10.1186/s12909-023-04698-z
 7. Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism*. 2017;69S:S36–S40. [Revisión fundacional en contexto de CDSS] Karthikesalingam A, El-Gayar O. AI-Driven Clinical Decision Support Systems: An Ongoing Pursuit of Potential. *Cureus*. 2024;16(2):e53836. doi: 10.7759/cureus.53836
 8. Muñoz-Fernández JL, Jiménez-Rodríguez D, Cruz-Cobo C, Fernández-García A, Santi-Cano MJ. Trust in Artificial Intelligence–Based Clinical Decision Support Systems Among Health Care Workers: Systematic Review. *J Med Internet Res*. 2024;26:e57499. doi: 10.2196/57499
 9. He R, Liu Z, Luo X, Wang F, Han H, Wu M, et al. A systematic review of large language model (LLM) evaluations in clinical medicine. *BMC Med Inform Decis Mak*. 2025;25(1):8. doi: 10.1186/s12911-024-02819-4
 10. Tierney AA, Nolan J, Kangovi S, Rojas JC, Sequist T, Weiner M, et al. Ambient AI Scribes in Clinical Practice: A Randomized Trial. *NEJM AI*. 2025; 2 (2) : A l o a 2 4 0 0 7 0 2 . d o i : 10.1056/Aloa2400702
 11. Adler-Milstein J, Haffajee RL, Nolan J, Rao SK, Vogeli C. A Pragmatic Randomized Controlled Trial of Ambient Artificial Intelligence to Improve Health Practitioner Well-Being. *NEJM AI*. 2025; 2 (1) : A l o a 2 4 0 0 5 5 5 . d o i : 10.1056/Aloa2400555
 12. Sequeira L, Saadat S, Patel V, Almario C, Simon R, Fisher M, et al. The Influence of Artificial Intelligence Scribes on Clinician Experience and Efficiency among Pediatric Subspecialists: A Rapid, Randomized Quality Improvement Trial. *Appl Clin Inform*. 2025;16(1):85–95. doi: 10.1055/a-2506-7568
 13. Moy AJ, Schwartz JM, Chen R, Sadri H, Lucas E, Cato KD, Rossetti SC. The burden of the digital environment: a systematic review on organization-directed workplace interventions to mitigate physician burnout. *J Am Med Inform Assoc*. 2021; 28 (7) : 1 4 8 1 – 1 4 9 1 . d o i : 10.1093/jamia/ocab056
 14. Cornet VP, Holden RJ, Shen Z, Hasan N. The Impact of AI Scribes on Streamlining Clinical Documentation: A Systematic Review. *Healthcare (Basel)*. 2025;13(3):214. doi:10.3390/healthcare13030214
 15. Chen S, Patel S, Agrawal M, Pfeifer E, Aaronson B, Bhatt DL, et al. AI-Generated Draft Replies Integrated Into Health Records and Physicians' Electronic Communication. *JAMA Netw Open*. 2024;7(2):e240402. doi: 10.1001/jamanetworkopen.2024.0402
 16. van der Sijs H, Sittig DF, Aarts J, Middleton B, Khan S, Ash JS. The use of artificial intelligence to optimize medication alerts generated by clinical decision support systems: a scoping review. *J Am Med Inform Assoc*. 2024;31(4):1005–1016. doi: 10.1093/jamia/ocad245
 17. Sahni N, Simon G, Arora R. Development and Validation of Machine Learning Models for Prediction of 1-Year Mortality Utilizing Electronic Medical Record Data Available at the Time of Early Hospital Readmission. *J Gen Intern Med*. 2018;33(6):921–930. [Contexto de modelos predictivos EHR] Wong A, Otles E, Donnelly JP, Krumm A, McCullough J, DeTroyer-Coolley O, et al. Clinical Implementation of Predictive Models Embedded within Electronic Health Record Systems: A Systematic Review. *Informatics (MDPI)*. 2020;7(3):25. doi:10.3390/informatics7030025
 18. Clusmann J, Kolbinger FR, Muti HS, Zhu Z, Roeffaers MJB, Hölsken A, et al. Clinical and Surgical Applications of Large Language Models: A Systematic Review. *J Clin Med*. 2023;12(18):5966. doi:10.3390/jcm12185966

19. Meng F, Wang Y, Ma X, Huang X, Bi Y, Li Y, et al. Large language model integrations in cancer decision-making: a systematic review and meta-analysis. *NPJ Digit Med.* 2025;8(1):5. doi: 10.1038/s41746-024-01384-6
20. Shankar A, Osei-Tutu E, Kunneman M, Gionfriddo MR, Montori VM, Wright K, et al. Large language models in real-world clinical workflows: a systematic review of applications and implementation. *Front Digit Health.* 2025;7:1543786. doi: 10.3389/fdgth.2025.1543786
21. Bjerring JC, Busch J. Should Artificial Intelligence be used to support clinical ethical decision-making? A systematic review of reasons. *BMC Med Ethics.* 2023;24(1):5. doi: 10.1186/s12910-023-00884-4
22. Nazerali-Maitland S, Ahmed A, Shetty D, Hassan S, Abbas SS, Bashir K, et al. Ethical challenges and evolving strategies in the integration of artificial intelligence into clinical practice. *PLOS Digit Health.* 2024;3(5):e0000503. doi: 10.1371/journal.pdig.0000503
23. Ahmed M, Khanna S, Mahajan V, Nittala MG, Kulkarni R, Bhambhani HP, et al. Mitigating Racial And Ethnic Bias And Advancing Health Equity In Clinical Algorithms: A Scoping Review. *Health Aff (Millwood).* 2023;42(10):1350–1357. doi: 10.1377/hlthaff.2023.00631
24. Rahman MZ, Islam MR, Islam A, Sunny FA, Chowdhury MFI, Reza MT, et al. Explainable AI in Clinical Decision Support Systems: A Meta-Analysis of Methods, Applications, and Usability Challenges. *Healthcare (Basel).* 2025;13(3):278. doi: 10.3390/healthcare13030278
25. Amann J, Blasimme A, Vayena E, Frey D, Madai VI. Current Challenges and Future Opportunities for XAI in Machine Learning-Based Clinical Decision Support Systems: A Systematic Review. *Appl Sci.* 2021;11(11):5088. doi: 10.3390/app11115088
26. Catuogno G, Paladino ME, De Luca CG, Coppeta L. Defining medical liability when artificial intelligence is applied on diagnostic algorithms: a systematic review. *Front Med (Lausanne).* 2023;10:1098998. doi: 10.3389/fmed.2023.1098998
27. Muralidharan A, Poddar A. Artificial intelligence in medical device software and high-risk medical devices – a review of definitions, expert recommendations and regulatory initiatives. *Expert Rev Med Devices.* 2023;20(7):583–592. doi: 10.1080/17434440.2023.2219923
28. Isaza-Restrepo A, Gutierrez-Lesmes O, Castañeda-Sabogal A, Trejos-Herrera AM. Global Regulatory Frameworks for the Use of Artificial Intelligence (AI) in the Healthcare Services Sector. *Healthcare (Basel).* 2024;12(3):310. doi: 10.3390/healthcare12030310
29. Zhang X, Liu Y, Li H, Lv Y, Zhao M, Lv X, et al. A decade of review in global regulation and research of artificial intelligence medical devices (2015–2025). *Front Med (Lausanne).* 2025;12:1532791. doi:10.3389/fmed.2025.1532791
30. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ.* 2021;372:n71. doi:10.1136/bmj.n71
31. Cruz Rivera S, Liu X, Chan AW, Denniston AK, Calvert MJ; SPIRIT-AI and CONSORT-AI Working Group. Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. *Nat Med.* 2020;26(9):1351–1363. doi: 10.1038/s41591-020-1037-7



Inteligencia Artificial en el Punto de Atención

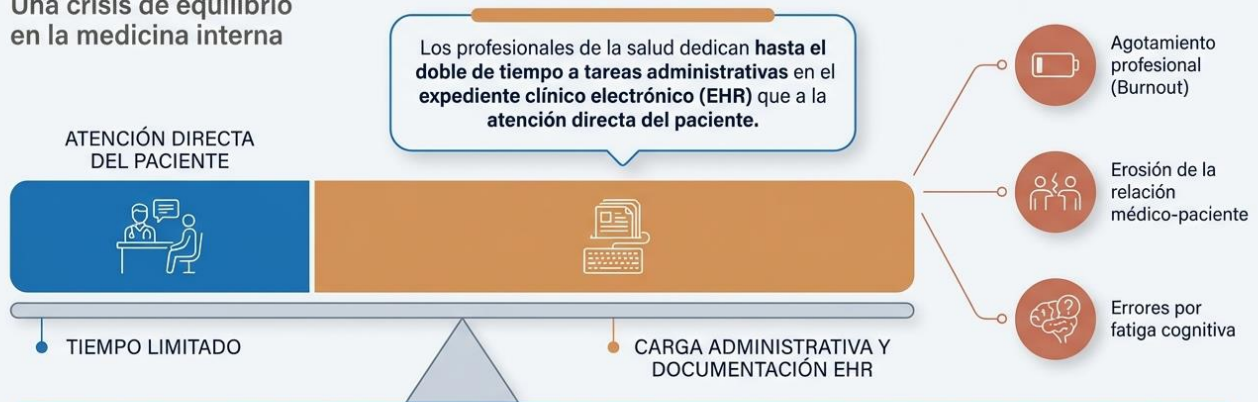
Integrando información al flujo de trabajo clínico con ética, profesionalismo y medicina basada en evidencia.

Dr. Rodolfo Palencia Díaz
& Dr. Rodolfo de Jesús Palencia Vizcarra.
Médicos internistas.

Dirigido a médicos de TIC en la Clínica.

La asimetría del tiempo clínico agota al médico internista

Una crisis de equilibrio en la medicina interna



La Inteligencia Artificial en el Punto de Atención (PoC) no busca reemplazar al clínico, sino devolverle el tiempo frente al paciente.

El ecosistema actual de la IA en el Punto de Atención (PoC)



NotebookLM

Rigor metodológico: Medicina basada en evidencia



Temperatura de Generación

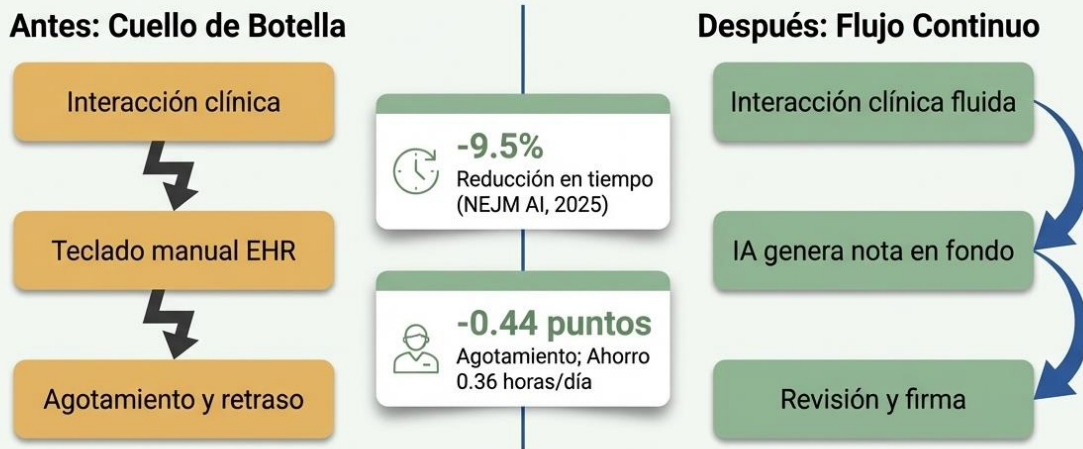


■ Alta Precisión / Baja Variabilidad

NotebookLM

El triunfo de los Escribas Ambientales en la documentación

Reducción del **9.5%** en tiempo de documentación con alta precisión (Ensayo NEJM AI, 2025).
 Reducción significativa del agotamiento laboral (-0.44 puntos en escala) y ahorro de 0.36 horas/día.



La calidad de la documentación se preserva (PDSQI-9 > 3.97/5) con eventos adversos mínimos, mitigando el agotamiento sin comprometer el expediente.

NotebookLM

La paradoja de la decisión: Precisión diagnóstica vs. Fatiga de alertas



NotebookLM

El riesgo oculto: Amplificación algorítmica de disparidades

Déficit Sistémico de Transparencia

99.1%

de los dispositivos médicos con IA aprobados por la FDA no incluye datos socioeconómicos,

y solo el 3.6% reporta raza/etnicidad.



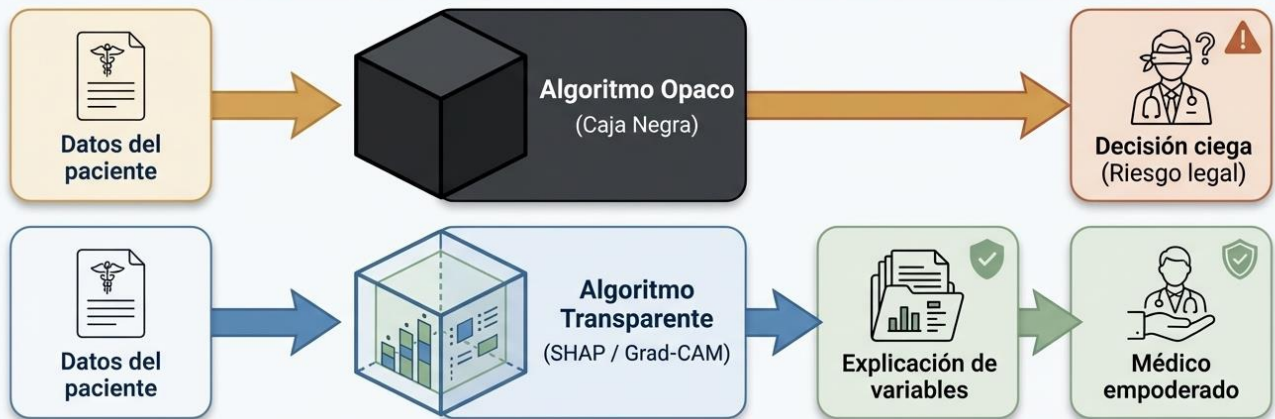
Contexto Latinoamericano

- ⚠ Los algoritmos entrenados en poblaciones de alta prevalencia de datos carecen de validación local en México y LatAm.
- ⚠ Riesgo documentado de exacerbación de disparidades raciales y étnicas.
- ⚠ La falta de representatividad demográfica es una amenaza directa a la equidad en salud.

NotebookLM

El dilema epistémico: La necesidad imperativa de la IA Explicable (XAI)

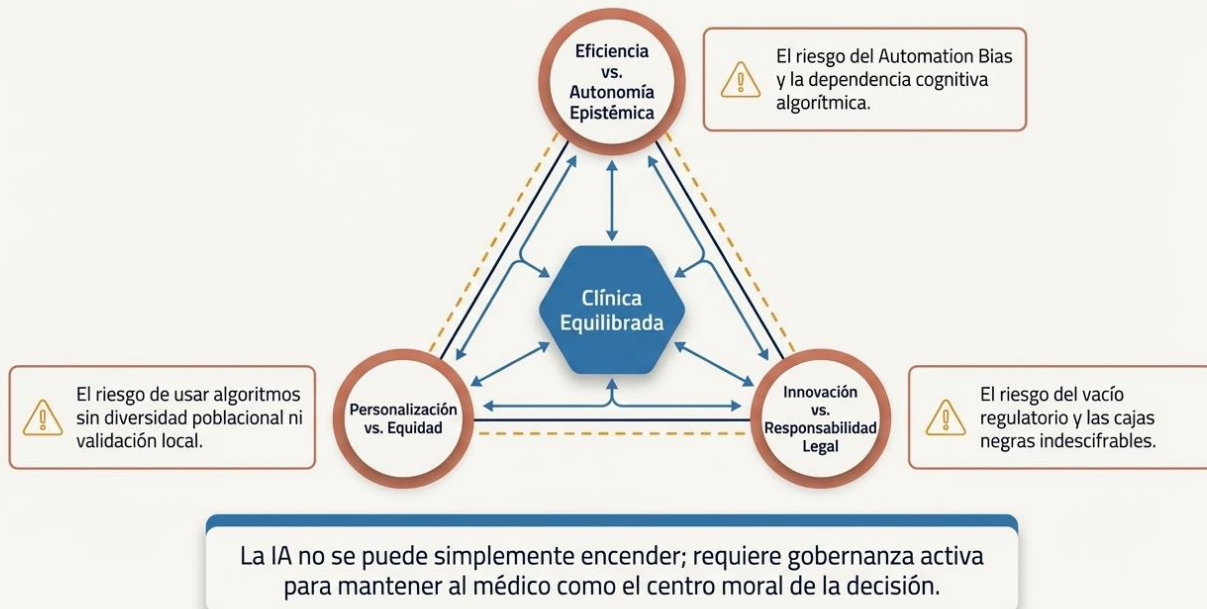
El médico que acepta una recomendación de una caja negra sin comprender su razonamiento compromete su responsabilidad médico-legal y autonomía epistémica.



La Solución XAI: Herramientas de interpretabilidad extraen las variables clave, haciendo transparente el peso de cada decisión algorítmica.

NotebookLM

Síntesis de tensiones: El campo de fuerza ético en el PoC



NotebookLM

Matriz de diagnóstico de herramientas IA

Aplicación Clínica	Evidencia (GRADE)	Riesgo Principal	Recomendación TICC Palencia
CDSS Clásico (Alertas / Riesgo)	Moderada	Fatiga de alertas, sobrecarga cognitiva.	Precaución: Usar solo con umbrales ajustados.
LLM para Documentación	Baja-Moderada	Alucinaciones, variabilidad.	Precaución: Revisión humana obligatoria.
Escriba Ambiental IA	Moderada (ECA)	Ocasionales inexactitudes menores.	Prescribir: Opción preferida para reducir burnout.
LLM Apoyo Diagnóstico	Baja	Baja validación, decisiones ciegas.	Contraindicado: Solo apoyo complementario.

NotebookLM

Marco TICC Palencia para la integración responsable (I)



Fase 1: Evaluación de la Herramienta (Pre-adopción)

- ✓ Exigir transparencia en los datos de entrenamiento (representatividad demográfica).
- ✓ Verificar validación en subgrupos (raza, sexo, comorbilidades).
- ✓ Requerir mecanismos de IA Explicable (XAI).



Fase 2: Integración al Flujo de Trabajo (Despliegue)

- ✓ La herramienta debe reducir —nunca incrementar— la carga cognitiva o documental.
- ✓ Implementar una adaptación progresiva con soporte técnico institucional constante.

NotebookLM

Marco TICC Palencia para la integración responsable (II)



Fase 3: Supervisión Clínica Activa

- Mantener escrutinio crítico ante recomendaciones algorítmicas.
- Identificar sesgos activamente; nunca delegar decisiones de alto impacto.



Fase 4: Consentimiento y Transparencia

- Informar al paciente explícitamente cuando su diagnóstico o expediente involucre IA.




Fase 5: Formación Continua

- Desarrollar competencias en alfabetización digital clínica.
- Capacitación formal para interpretar salidas de IA y gestionar incertidumbre.

NotebookLM

Zonas de incertidumbre: La agenda de investigación futura




La regulación vigente es inadecuada ante la velocidad de adopción, exigiendo prudencia clínica en estas áreas.

NotebookLM

Postura Institucional TICC Palencia

La Inteligencia Artificial es un **amplificador del razonamiento clínico**, no un sustituto de la empatía ni de la **responsabilidad médica**.

- El camino responsable no es el rechazo reactivo ni la adopción acrítica.

- La integración debe ser informada, éticamente comprometida y orientada a devolver el tiempo al encuentro médico-paciente.

- Los clínicos deben participar activamente en el diseño de los marcos de gobernanza del futuro.

NotebookLM

Inteligencia Artificial en el Punto de Atención: Transformando el Flujo de Trabajo Clínico con Ética y Profesionalismo

TICC Palencia

Dr. Rodolfo Palencia Díaz S.Dr. Rodolfo de Jesús Palencia Vizcarra
(Médicos Internistas)

Herramientas de IA y Eficiencia Operativa

Escribas Ambientales con IA



Capturan pasivamente la conversación médico-paciente, reduciendo el agotamiento emocional y el tiempo de documentación.

Soporte a la Decisión Clínica (CDSS)



Reducción del Agotamiento Laboral:

-0.44

puntos en escalas de *burnout*.
El uso de IA ambiental se asocia con una disminución significativa.



Comparativa de Eficacia y Evidencia

Escriba Ambiental		- Tiempo de documentación (-0.36 h/día)	Moderada
CDSS Avanzado		↑ Precisión en diagnósticos críticos	Moderada
LLM (Documentación)		Resumen de notas y alta médica	Beja-Moderada

Marco de Integración Responsable TICC Palencia

El Médico como Agente Epistémico

La IA debe complementar el razonamiento clínico, nunca sustituir la responsabilidad final del médico ante el paciente.



Mitigación de Sesgos Algorítmicos



Es crítico validar los algoritmos en poblaciones latinoamericanas para evitar disparidades raciales y socioeconómicas.



Transparencia y Explicabilidad (XAI)

Priorizar sistemas que permitan al clínico comprender el razonamiento detrás de cada recomendación algorítmica.



Referencias Bibliográficas: 1. Palencia Díaz R, Palencia Vizcarra RJ. Inteligencia artificial en el punto de atención, acercando información el flujo de trabajo y a la toma de decisiones con ética y profesionalismo. Grupo TICC Palencia; 2025. 2. Tierney AA, Nolan J, Kangovi S, et al. Ambient AI Scribes in Clinical Practice: A Randomized Trial. NEJM AI. 2025;2(2):Aloa2400702. 3. Adler-Milstein J, Haffajee RL, Nolan J, et al. A Pragmatic Randomized Controlled Trial of Ambient Artificial Intelligence to Improve Health Practitioner Well-Being. NEJM AI. 2025;2(1):Aloa2400555. NotebookLM

Bibliografía Seleccionada (Formato Vancouver)

1. Tierney AA, Nolan J, Kangovi S, et al. Ambient AI Scribes in Clinical Practice: A Randomized Trial. NEJM AI. 2025;2(2):Aloa2400702.
2. Adler-Milstein J, Haffajee RL, Nolan J, et al. A Pragmatic Randomized Controlled Trial of Ambient Artificial Intelligence to Improve Health Practitioner Well-Being. NEJM AI. 2025;2(1):Aloa2400555.
3. Baig MR, Ahmad M, Shahzad M, et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. BMC Med Educ. 2023;23(1):689.
4. Kim DW, Jang HY, Kim KW, et al. A scoping review of reporting gaps in FDA-approved AI medical devices. NPJ Digit Med. 2024;7(1):58.
5. Deininger L, Ghosh AK, Brown S, et al. The Algorithmic Divide: A Systematic Review on AI-Driven Racial Disparities in Healthcare. J Racial Ethn Health Disparities. 2024;11(5):2762-2776.
6. Meng F, Wang Y, Ma X, et al. Large language model integrations in cancer decision-making: a systematic review and meta-analysis. NPJ Digit Med. 2025;8(1):5.

Implementación responsable de la inteligencia artificial en salud

Dr. Rodolfo Palencia Díaz

Dr. Rodolfo de J. Palencia Vizcarra

Médicos Internistas
Universidad de Guadalajara
Instituto Mexicano del Seguro Social (IMSS)
Colegiados y Certificados (CMMI)
Fundadores del TICC
30 de marzo de 2026

Resumen

La implementación de la inteligencia artificial (IA) en salud ha entrado en una fase en la que el rendimiento algorítmico aislado ya no es suficiente para justificar su adopción. El problema central se ha desplazado hacia la gobernanza del dato, la integración al flujo clínico, la capacitación del personal, la supervisión organizacional y la legitimidad social. El objetivo de esta revisión fue sintetizar la evidencia reciente sobre implementación responsable de la IA en salud, con énfasis en cinco dominios: mejor uso de los datos de salud, facilitación del uso de la IA, desarrollo de capacidades entre el personal sanitario, órganos de supervisión y participación pública. Se realizó una revisión estructurada de enfoque narrativo, organizada en formato IMRyD e informada por principios PRISMA 2020 para ordenamiento de evidencia secundaria. Se priorizaron revisiones sistemáticas, revisiones de alcance, documentos de consenso y guías internacionales publicadas entre 2020 y 2026 en inglés o español. La evidencia disponible muestra una convergencia consistente: la IA clínica responsable requiere datos representativos, trazables e interoperables; adopción centrada en el usuario y en el contexto; formación diferenciada por rol profesional; estructuras formales de gobernanza con capacidad real de auditoría; y mecanismos de información y participación pública. Los marcos SPIRIT-AI, CONSORT-AI, DECIDE-AI, TRIPOD+AI, STARD-AI y GAMER proporcionan actualmente el núcleo metodológico para mejorar la transparencia del diseño, evaluación y reporte de intervenciones con IA. La fuerza global de la evidencia es moderada, porque gran parte del corpus sigue dominado por revisiones de alcance, estudios cualitativos y marcos

conceptuales más que por ensayos pragmáticos comparativos. En consecuencia, la IA en salud debe entenderse como una intervención sociotécnica de riesgo variable que exige gobernanza continua, no como una herramienta autónoma lista para desplegarse sin evaluación local.

Palabras clave: inteligencia artificial; implementación; servicios de salud; gobernanza de datos; personal sanitario; participación pública; supervisión institucional.

Introducción

La IA en salud ha evolucionado desde pruebas de concepto centradas en exactitud diagnóstica o capacidad predictiva hacia aplicaciones con impacto potencial en decisiones clínicas, organización hospitalaria, investigación y salud pública. Sin embargo, esa transición ha dejado claro que el éxito no depende únicamente del algoritmo. La Organización Mundial de la Salud señaló en 2021 que la IA para salud debe regirse por principios éticos y de gobernanza, y en su guía más reciente sobre grandes modelos multimodales amplió esa preocupación al advertir que estos sistemas pueden recibir múltiples tipos de entrada y generar salidas con repercusiones clínicas, científicas y poblacionales.

De forma paralela, la literatura de implementación ha mostrado que el problema dominante no es exclusivamente técnico. La revisión de Hassan y colaboradores concluyó que la adopción de IA en salud está limitada por barreras humanas, organizacionales, regulatorias, tecnológicas y sociales, y que la confianza funciona como un catalizador central del proceso de adopción. La

revisión de Morley sobre gobernanza internacional de datos e IA encontró cuatro áreas críticas para colaboración y regulación: liderazgo y supervisión, enfoque de sistema completo, estándares y regulación, y participación de actores y público.

Para médicos clínicos, directivos e investigadores, esto obliga a abandonar una visión reduccionista de la IA como “software avanzado” y a tratarla como una intervención clínica y organizacional que modifica procesos, redistribuye responsabilidades y puede amplificar tanto beneficios como daños. El objetivo de esta revisión es ordenar esa evidencia con una lógica útil para la práctica y la gestión.

Métodos

Se realizó una revisión estructurada de enfoque narrativo, organizada en formato IMRyD. La selección conceptual se centró en cinco dominios previamente definidos: 1) uso de datos de salud, 2) facilitación de adopción clínica, 3) capacidades del personal sanitario, 4) órganos de supervisión y 5) participación pública. Se priorizaron revisiones sistemáticas, revisiones de alcance, guías y documentos de consenso publicados entre 2020 y 2026 en inglés o español. Para sostener trazabilidad, se tomaron como base fuentes primarias verificables en PubMed y documentos oficiales de OMS, NICE, FDA e IMDRF.

La interpretación metodológica se apoyó en PRISMA 2020 para estructurar la síntesis de evidencia secundaria, y en AMSTAR-2 y GRADE como marcos críticos de lectura, aunque no fue posible una graduación formal homogénea por la heterogeneidad de diseños incluidos en el campo. Para la dimensión de investigación y evaluación con IA se integraron los estándares SPIRIT-AI, CONSORT-AI, DECIDE-AI, TRIPOD+AI, STARD-AI y GAMER, debido a que estos lineamientos cubren desde protocolos de ensayos y estudios tempranos hasta modelos predictivos, estudios de exactitud diagnóstica y uso de IA generativa en investigación médica.

Estrategia sugerida reproducible para PubMed

```
(  
("Artificial Intelligence"[Mesh] OR "Machine Learning"[Mesh] OR "artificial intelligence"[tiab] OR "machine learning"[tiab] OR "generative AI"[tiab])  
AND
```

```
("Health Services"[Mesh] OR "Delivery of Health Care"[Mesh] OR healthcare[tiab] OR "health care"[tiab] OR hospital*[tiab] OR clinic*[tiab])
```

```
AND
```

```
(implementation[tiab] OR adoption[tiab] OR governance[tiab] OR oversight[tiab] OR regulation[tiab] OR workforce[tiab] OR training[tiab] OR "public involvement"[tiab] OR "patient participation"[tiab] OR "data governance"[tiab] OR ethics[tiab])
```

```
)
```

```
AND
```

```
(systematic review[pt] OR review[ti] OR scoping review[tiab] OR guideline[pt] OR consensus[tiab])
```

```
AND
```

```
("2020/01/01"[Date - Publication] : "3000"[Date - Publication])
```

```
AND
```

```
(english[lang] OR spanish[lang])
```

La revisión sistemática sobre competencias del personal sanitario informó búsquedas en PubMed, Scopus y Web of Science, y la revisión de percepciones de pacientes utilizó PubMed, Scopus y Web of Science, lo que respalda que estos dominios requieren estrategias amplias y no exclusivamente monobase.

Resultados y discusión

1. Un mejor uso de los datos de salud

La implementación responsable de la IA comienza por la calidad y gobernanza del dato. La revisión de Morley mostró que las políticas y marcos existentes en países miembros del GDHP siguen siendo heterogéneos, pero convergen en la necesidad de liderazgo, supervisión, regulación y enfoque de sistema completo desde la recolección del dato hasta el despliegue del modelo. La guía de la OMS sobre modelos multimodales refuerza este punto al señalar que estos sistemas pueden tener aplicaciones amplias en atención clínica, investigación, salud pública y desarrollo de fármacos, lo que incrementa el valor y el riesgo del dato subyacente.

En términos operativos, un dato apto para IA clínica debe ser, como mínimo, íntegro, semánticamente consistente, representativo, interoperable y trazable. Sin esas condiciones, incluso un modelo con alto rendimiento publicado puede degradarse al cambiar de población, hospital o flujo de trabajo. Esta exigencia metodológica está alineada con TRIPOD+AI para

modelos predictivos y con STARD-AI para estudios de exactitud diagnóstica, ambos diseñados precisamente para mejorar la transparencia sobre datos de entrada, sesgo, evaluación y aplicabilidad.

Tabla 1. Requisitos mínimos del dato para IA responsable en salud

Dominio	Requisito mínimo	Riesgo si falla	Consecuencia clínica
Calidad	integridad y consistencia	predicción inestable	clasificación errónea
Representatividad	diversidad poblacional suficiente	sesgo algorítmico	inequidad asistencial
Interoperabilidad	compatibilidad entre sistemas	fragmentación	imposibilidad de uso longitudinal
Trazabilidad	documentación del origen y limpieza	opacidad	auditoría inviable
Privacidad y acceso	reglas claras de gobernanza	uso secundario inapropiado	daño ético y legal
Vigilancia	monitoreo de deriva y recalibración	deterioro silencioso	pérdida de seguridad

2. Facilitación del uso de la IA

La literatura reciente muestra que la adopción no se logra por disponibilidad tecnológica, sino por adecuación sociotécnica. La revisión de Hassan incluyó 50 publicaciones y describió aproximadamente 18 categorías de barreras y facilitadores, concluyendo que la confianza, la gobernanza y los marcos regulatorios son factores decisivos para traducir la IA a la práctica cotidiana. NICE, por su parte, mantiene un marco de estándares de evidencia para tecnologías digitales de salud con el objetivo de ayudar a evaluadores y tomadores de decisiones a identificar tecnologías con beneficios plausibles y evidencia proporcional al riesgo.

Esto implica que una herramienta de IA debe introducirse en un punto claro del proceso asistencial, con usuarios definidos, acciones desencadenadas explícitas y rutas conocidas ante fallo o discordancia. DECIDE-AI fue desarrollado precisamente para mejorar el reporte de evaluaciones clínicas tempranas de sistemas de apoyo a decisión impulsados por IA, en reconocimiento de que la interacción humano- sistema y el contexto de uso influyen de manera sustancial en la seguridad y en la utilidad real.

Los principios de Good Machine Learning Practice difundidos por la FDA y formalizados por el IMDRF en enero de 2025 insisten en considerar el ciclo de vida total del producto, con énfasis en seguridad, efectividad y calidad. Ese enfoque es coherente con una postura

conservadora de implementación: empezar por casos de uso acotados, de valor clínico claro, con supervisión humana estrecha y métricas clínicas relevantes.

Tabla 2. Barreras y facilitadores de adopción responsable

Dominio	Barreras frecuentes	Facilitadores
Técnica	baja interoperabilidad, mala interfaz, opacidad	integración al flujo, diseño centrado en usuario
Clínica	fatiga de alertas, utilidad incierta	caso de uso delimitado, umbrales claros
Humana	desconfianza, temor a sustitución, baja alfabetización	capacitación, co-diseño, supervisión visible
Organizacional	falta de liderazgo, presupuesto, métricas	patrocinio ejecutivo, hoja de ruta
Regulatoria	responsabilidad difusa	políticas internas y gobernanza formal
Social	percepción de deshumanización	transparencia y comunicación inteligible

3. Desarrollo de capacidades entre el personal sanitario

El desarrollo de capacidades ha dejado de ser un componente accesorio. La revisión sistemática de Gazquez-García sintetizó 14 áreas competenciales clave para integrar IA en la práctica sanitaria, destacando fundamentos de IA, análisis y gestión de datos, y consideraciones éticas y legales. El mismo estudio subrayó que la formación más necesaria no es la programación avanzada, sino la capacidad de evaluar exactitud, confiabilidad, validez y límites del sistema.

Para la práctica institucional, esto obliga a diferenciar la capacitación por rol. El clínico requiere comprender cuándo usar, cuándo desconfiar y cómo verificar. La jefatura clínica necesita evaluar impacto operativo, riesgo y vigilancia. El investigador debe dominar validación, reproducibilidad y estándares de reporte. El directivo debe conocer riesgo organizacional, criterios de adquisición, supervisión y retiro. La evidencia en este punto todavía es limitada en cuanto a comparar currículos o demostrar superioridad de una estrategia formativa específica, pero converge en que la formación meramente superficial resulta insuficiente.

Tabla 3. Capacidades mínimas por perfil profesional

Perfil	Núcleo competencial
Médico clínico	límites, sesgo, verificación, documentación
Jefatura clínica	selección de casos, seguridad, vigilancia
Investigador	diseño, validación, TRIPOD+AI, STARD-AI, CONSORT-AI, GAMER
Directivo	riesgo, compra, gobernanza, retiro
Equipo TI/datos	interoperabilidad, ciberseguridad, mantenimiento

4. Órganos de supervisión

La supervisión institucional formal es uno de los rasgos más consistentes de una implementación responsable. La OMS de 2021 planteó principios de responsabilidad y rendición de cuentas, y la revisión de Morley identificó liderazgo y supervisión como uno de los cuatro dominios centrales para gobernanza internacional en IA sanitaria. Más recientemente, el estudio de Kim y colaboradores mostró que el marco PPTO (people, process, technology, operations) puede aplicarse de forma práctica en un gran sistema hospitalario para generar políticas y conformar un comité de gobernanza de IA.

Este punto tiene una consecuencia práctica clara: un comité útil no debe ser decorativo. Debe tener mandato explícito, composición multidisciplinaria, rutas de decisión, capacidad de auditoría y atribuciones para detener o escalar una herramienta según riesgo y desempeño. La guía NICE y los principios GMLP del IMDRF/FDA son útiles como soporte operativo para estructurar las preguntas que un órgano de supervisión debe responder antes del despliegue.

Tabla 4. Funciones mínimas de un comité institucional de IA

Función	Pregunta crítica
Selección	¿resuelve un problema clínico prioritario?
Evidencia	¿existe validación externa y local?
Datos	¿los insumos son trazables y aptos?
Equidad	¿hay auditoría de sesgo?
Integración	¿quién la usa, cuándo y con qué acción?
Ética/legal	¿qué implica para privacidad y autonomía?
Vigilancia	¿cómo se medirá desempeño y deriva?
Retiro	¿qué umbral obliga a suspenderla?

5. Participación pública

La participación pública no es una concesión reputacional; es una condición de legitimidad. La revisión sistemática de Young mostró que pacientes y público general suelen mantener una actitud globalmente positiva hacia la IA clínica, pero con reservas importantes y preferencia por supervisión humana. La revisión más reciente de Bashkin Osnat identificó 38 estudios en 18 países y encontró que más del 75% de los pacientes percibe beneficios potenciales, mientras aproximada-

mente 50-70% expresa preocupaciones relevantes sobre pérdida de conexión humana, seguridad, privacidad, transparencia y autonomía.

Esos hallazgos obligan a una implementación más transparente. Si una institución emplea IA en triage, apoyo diagnóstico, priorización, documentación o investigación, debe explicar de forma inteligible qué hace la herramienta, qué no hace, qué supervisión humana existe y cómo se protegen los datos. La confianza no se obtiene por sofisticación técnica, sino por trazabilidad, comunicación clara y posibilidad de rendición de cuentas.

6. Estándares de evaluación y reporte

Los marcos contemporáneos de reporte constituyen hoy el núcleo metodológico mínimo para investigación con IA en salud. SPIRIT-AI y CONSORT-AI fueron publicados en 2020 para mejorar la transparencia de protocolos y reportes de ensayos clínicos con intervención de IA. DECIDE-AI amplió el marco hacia la evaluación clínica temprana de sistemas de apoyo a decisión. TRIPOD+AI actualizó el estándar para modelos predictivos usando regresión o aprendizaje automático. STARD-AI fue desarrollado para estudios de exactitud diagnóstica con IA. GAMER, publicado en 2025, cubre el reporte del uso de IA generativa en investigación médica.

La relevancia de estos estándares es práctica. Sin ellos, la evidencia publicada pierde interpretabilidad, reproducibilidad y valor para la implementación. Para investigadores y comités institucionales, esto implica que ya no es suficiente reportar desempeño global del modelo; también debe declararse el contexto de integración, la interacción humano-IA, el tratamiento de errores y, en el caso de IA generativa, el modelo utilizado, la estrategia de prompting y los mecanismos de verificación humana.

Tabla 5. Utilidad operativa de los principales estándares

Estándar	Aplicación
SPIRIT-AI	protocolos de ensayos con IA
CONSORT-AI	reporte de ensayos con IA
DECIDE-AI	estudios piloto y evaluación clínica temprana
TRIPOD+AI	modelos predictivos
STARD-AI	estudios de exactitud diagnóstica
GAMER	uso de IA generativa en investigación médica

Limitaciones e incertidumbres

La principal limitación del campo es metodológica. Aunque existe una dirección consistente de la evidencia, gran parte del corpus está formado por revisiones de alcance, estudios cualitativos y marcos conceptuales, más que por ensayos pragmáticos comparativos o estudios multicéntricos de implementación con desenlaces clínicos duros. La propia revisión sobre adopción de Hassan concluye que se necesita investigación adicional que combine gobernanza e implementación para fortalecer la confianza y guiar la traslación a la práctica real.

La segunda limitación es contextual. Los marcos de gobernanza más desarrollados provienen con frecuencia de sistemas con infraestructura digital robusta. Por ello, su aplicación en hospitales con madurez digital limitada requiere adaptación local. El estudio canadiense de Kim aporta evidencia útil de implementación real, pero sigue siendo un estudio de caso organizacional y no una prueba universal de efectividad.

Conclusiones

La implementación responsable de la IA en salud no depende solo de algoritmos precisos. Requiere datos clínicamente aptos, integración contextual, capacitación diferenciada, supervisión institucional real y participación pública significativa. La evidencia reciente es consistente en que la falla más frecuente no reside exclusivamente en el modelo, sino en la ausencia de gobernanza sobre su diseño, despliegue y vigilancia.

Para el médico clínico, la regla práctica es no delegar juicio en sistemas no auditados. Para el directivo, no adoptar innovación sin estructura de supervisión. Para el investigador, no reportar IA sin el estándar metodológico correspondiente. Esa triple disciplina resume hoy la implementación responsable de IA en salud.

Bibliografía

1. World Health Organization. Ethics and governance of artificial intelligence for health. Geneva: World Health Organization; 2021.
2. World Health Organization. Ethics and governance of artificial intelligence for health: guidance on large multi-modal models. Geneva: World Health Organization; 2025.
3. Hassan M, Kushniruk A, Borycki E. Barriers to and Facilitators of Artificial Intelligence Adoption in Health Care: Scoping Review. *JMIR Hum Factors*. 2024;11:e48633. doi:10.2196/48633.
4. Morley J, Murphy L, Mishra A, Joshi I, Karpathakis K. Governing Data and Artificial Intelligence for Health Care: Developing an International Understanding. *JMIR Form Res*. 2022;6(1):e31623. doi:10.2196/31623.
5. Gazquez-Garcia J, Sánchez-Bocanegra CL, Sevillano JL. AI in the Health Sector: Systematic Review of Key Skills for Future Health Professionals. *JMIR Med Educ*. 2025;11:e58161. doi:10.2196/58161.
6. Young AT, Amara D, Bhattacharya A, Wei ML. Patient and general public attitudes towards clinical artificial intelligence: a mixed methods systematic review. *Lancet Digit Health*. 2021;3(9):e599-e611. doi:10.1016/S2589-7500(21)00132-1.
7. Bashkin O. Patient perspectives on artificial intelligence in healthcare: A global scoping review of benefits, ethical concerns, and implementation strategies. *Int J Med Inform*. 2025;203:106007. doi:10.1016/j.ijmedinf.2025.106007.
8. Cruz Rivera S, Liu X, Chan AW, Denniston AK, Calvert MJ, et al. Guidelines for clinical trial protocols for interventions involving artificial intelligence: the SPIRIT-AI extension. *Nat Med*. 2020;26(9):1351-1363. doi:10.1038/s41591-020-1037-7.
9. Liu X, Cruz Rivera S, Moher D, Calvert MJ, Denniston AK, et al. Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. *Nat Med*. 2020;26(9):1364-1374. doi:10.1038/s41591-020-1081-0.
10. Vasey B, Nagendran M, Campbell B, Clifton DA, Collins GS, Denaxas S, et al. Reporting guideline for the early-stage clinical evaluation of decision support systems driven by artificial intelligence: DECIDE-AI. *Nat Med*. 2022;28(5):924-933. doi:10.1038/s41591-022-01772-9.
11. Collins GS, Dhiman P, Andaur Navarro CL, Ma J, Hooft L, Reitsma JB, et al. TRIPOD+AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ*. 2024;385:e078378. doi:10.1136/bmj-2023-078378.

12. Sounderajah V, Guni A, Liu X, Collins GS, Karthikesalingam A, Markar SR, et al. The STARD-AI reporting guideline for diagnostic accuracy studies using artificial intelligence. *Nat Med*. 2025;31(10):3283-3289. doi:10.1038/s41591-025-03953-8.
13. Luo X, Tham YC, Giuffrè M, Ranisch R, Daher M, Lam K, et al. Reporting guideline for the use of Generative Artificial intelligence tools in MEDical Research: the GAMER Statement. *BMJ Evid Based Med*. 2025;30(6):390-400. doi:10.1136/bmjebm-2025-113825.
14. Kim JY, Hasan A, Kueper J, Tang T, Hayes C, Fine B, et al. Establishing organizational AI governance in healthcare: a case study in Canada. *NPJ Digit Med*. 2025;8(1):522. doi:10.1038/s41746-025-01909-3.
15. National Institute for Health and Care Excellence. Evidence standards framework for digital health technologies. London: NICE; updated 2022.
16. International Medical Device Regulators Forum. Good machine learning practice for medical device development: Guiding principles. IMDRF/AIML WG/N88 FINAL:2025. Published 29 January 2025.
17. U.S. Food and Drug Administration. Good Machine Learning Practice for Medical Device Development: Guiding Principles. Silver Spring, MD: FDA; updated 2025.




IMPLEMENTACIÓN RESPONSABLE DE LA IA EN SALUD: MÁS ALLÁ DEL ALGORITMO

CALIDAD DEL DATO Y ADOPCIÓN CLÍNICA




El dato como cimiento de la seguridad.

Los datos deben ser íntegros, trazables e interoperables para evitar predicciones inestables o sesgos.



Modelos predictivos y estudios de exactitud diagnóstica.



Confianza como catalizador de adopción.

La implementación falla sin un diseño centrado en el usuario y una integración clara al flujo clínico.



IA como intervención sociotécnica

Debe verse como un sistema que modifica procesos y responsabilidades, no como software autónomo.

CAPACIDADES Y SUPERVISIÓN ORGANIZACIONAL



Capacitación diferenciada por rol.

Los clínicos deben aprender a verificar límites;



los directivos a evaluar riesgos y gobernanza.



Comités de supervisión con autoridad real.

Los órganos de gobierno deben ser multidisciplinarios y capaces de auditar o detener herramientas.

Dominio de Auditoría | Pregunta Crítica de Control

Equidad

¿Se han realizado auditorías para detectar sesgos algorítmicos?

Vigilancia

¿Cómo se medirá el deterioro del desempeño con el tiempo?

Retiro

¿Qué umbral de error obliga a suspender la herramienta inmediatamente?



Participación pública para legitimidad

La transparencia sobre el uso de datos y supervisión humana es vital para ganar confianza.

NotebookLM


Implementación responsable de la inteligencia artificial en salud

Dr. Rodolfo Palencia Díaz
 Dr. Rodolfo de J Palencia Vizcarra
 Guadalajara, Jalisco. México
 30 de marzo de 2026

De una visión reduccionista a la gobernanza sociotécnica.


The Past

visión reduccionista de la IA como "software avanzado" y a tratarla como una



Enfoque: Rendimiento algorítmico aislado.
Mentalidad: Herramienta autónoma "lista para usarse" (plug-and-play).
Riesgo: Ignora el contexto clínico y el flujo de trabajo.

The Present



Enfoque: IA como intervención sociotécnica.
Mentalidad: Modifica procesos, redistribuye responsabilidades y requiere evaluación local.
Solución: Gobernanza continua y supervisión humana estrecha.

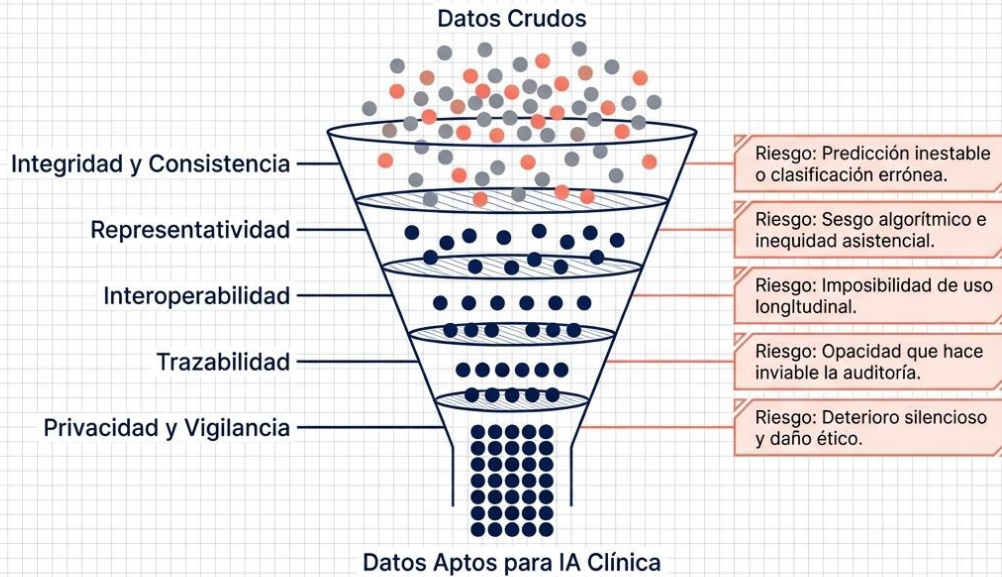
NotebookLM

Los 5 pilares de un ecosistema clínico-digital responsable.



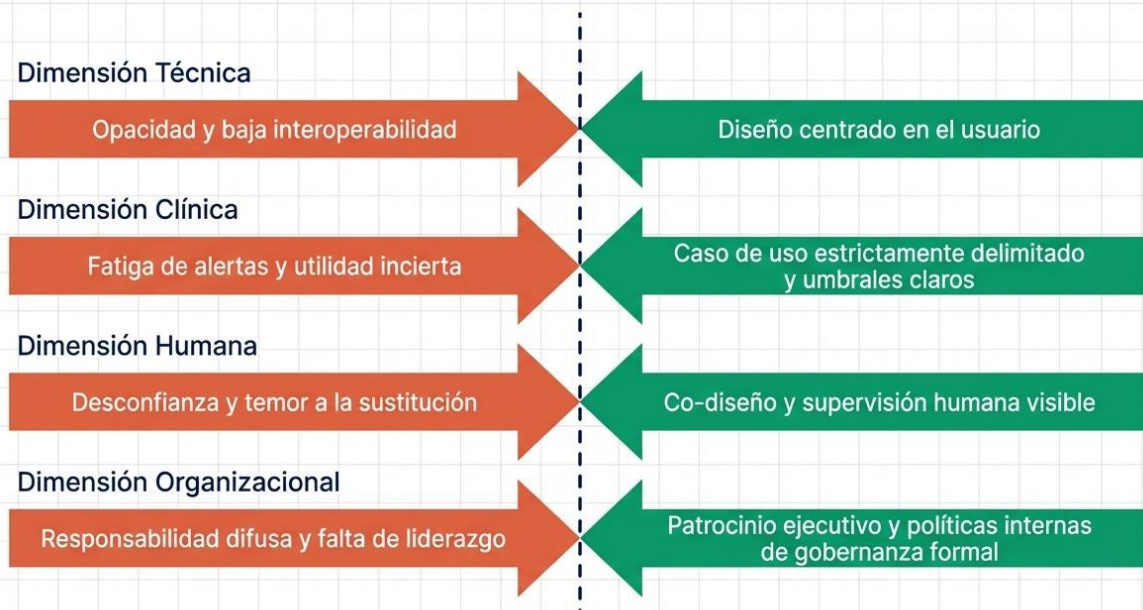
NotebookLM

Pilar 1 | El embudo de la gobernanza del dato



Advertencia: Un modelo con alto rendimiento publicado se degrada inevitablemente si cambia de población sin recalibración

Pilar 2 | Venciendo la fricción en el flujo clínico.



Pilar 3 | La capacitación no es programación, es evaluación crítica.

Médicos

Competencias críticas:

- Comprender límites del sistema
- Identificar sesgos
- Verificar discordancias
- Documentar el uso en el expediente

Jefatura Clínica

Competencias críticas:

- Seleccionar casos de uso correctos
- Garantizar la seguridad del paciente
- Mantener vigilancia operativa

Internistas

Competencias críticas:

- Diseño robusto de validación cruzada
- Dominio de estándares metodológicos (TRIPOD+AI, CONSORT-AI)

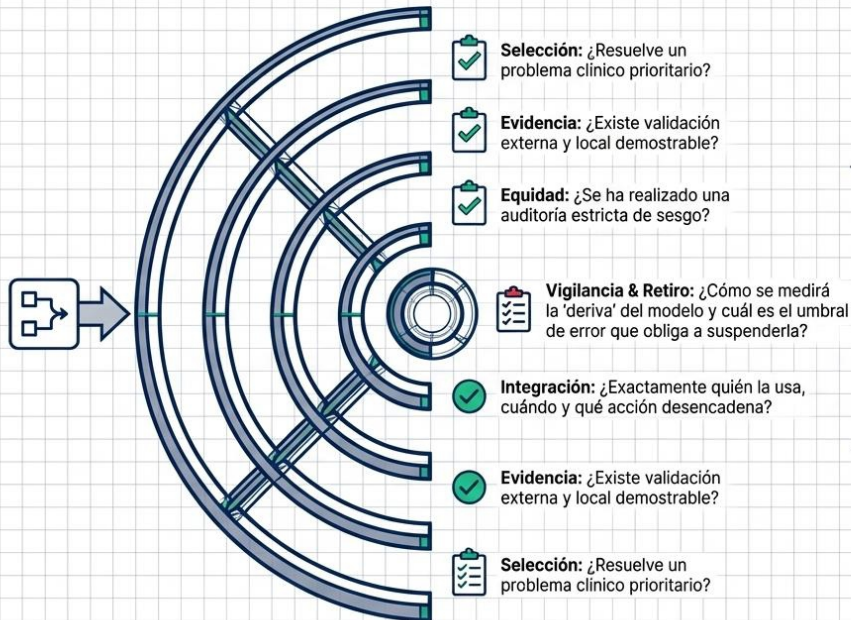
Directivo / Gerencia

Competencias críticas:

- Evaluar riesgo organizacional
- Definir criterios de compra corporativa
- Establecer gobernanza formal
- Definir umbrales de retiro

NotebookLM

Pilar 4 | El comité de IA no es decorativo, es una barrera de seguridad.



El Mandato PPTO

Basado en el marco PPTO (People, Process, Technology, Operations) — el comité debe tener **atribuciones formales** para detener una herramienta, no solo evaluarla.

NotebookLM

Pilar 5 | El dilema de la confianza del paciente.

50% - 70% expresa preocupaciones severas.



>75% percibe beneficios potenciales evidentes (rapidez, precisión).

Balanza de Percepción Pública

Contrapesos Éticos

- Pérdida de conexión humana
- Riesgos de seguridad
- Invasión a la privacidad
- Pérdida de autonomía

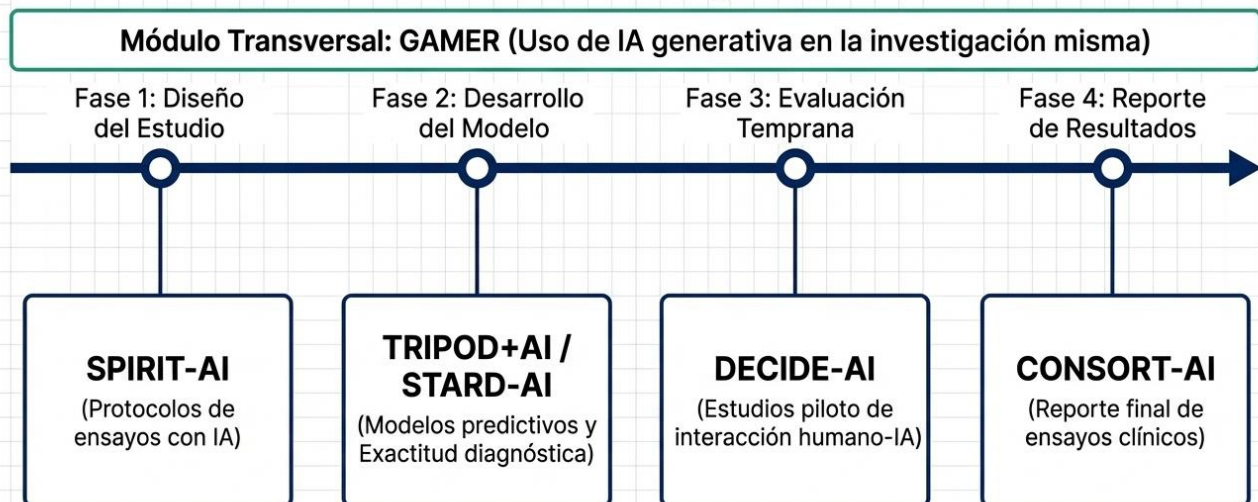
Conclusión Operativa

La legitimidad no se logra con sofisticación técnica, sino explicando de forma inteligible qué hace la IA, qué NO hace, y mostrando la supervisión humana directa.

NotebookLM

El núcleo metodológico de la evaluación y reporte.


Ciclo de Vida de la Investigación Clínica



NotebookLM

LA TRIPLE DISCIPLINA DE LA IA RESPONSABLE EN SALUD.

Para el Clínico:
No delegar sin auditar.



Para el Directivo:
No adoptar sin supervisar.

Para el Investigador:
No reportar sin estándares.

La IA no funciona de manera aislada; su verdadero rendimiento clínico es un reflejo directo de la inteligencia colectiva y organizacional que la rige.

Fundadores de TICC

NotebookLM