Ángel L. Martín de Francisco
Catedrático de Medicina Universidad de Cantabria

INTELIGENCIA ARTIFICIAL en MEDICINA DE URGENCIAS

De la intuición al algoritmo

Gonzalo Pérez Roji
Ana Rosa Alconero Camarero
Itziar Ostolaza Tazón
Cristina Pérez Tejedor

Sociedad Española de Nefrología
NEFROLOGÍA AL DÍA



Víctor Lorenzo Sellares
Juan Manuel López Gómez
Miquel Blasco Pelicano
Editores Nefrología al Día

UC UNIVERSIDAD DE CANTABRIA
Valdecilla Instituto de Investigación Sanitaria IDIVAL

INTELIGENCIA ARTIFICIAL EN MEDICINA DE URGENCIAS

De la intuición al algoritmo

Ángel L. Martín de Francisco

Gonzalo Pérez Roji
Ana Rosa Alconero Camarero
Itziar Ostolaza Tazón
Cristina Pérez Tejedor

Inteligencia Artificial en medicina de urgencias. De la intuición al algoritmo
Monografías de Nefrología al Día.
Grupo Editorial de la Sociedad Española de Nefrología. Edición 2025.

ISBN 978-84-129769-6-0

Editores
Víctor Lorenzo Sellares
Juan Manuel López Gómez
Miquel Blasco Pelicano

ÍNDICE

Autores v
Contribución de los autores vi

Dedicatoria 1
Prefacio 3
Agradecimientos 5

1.
Introducción 7

2.
Inteligencia artificial. Conceptos básicos **9**

2.1 Funcionamiento de la IA **9**
2.1.1 Lenguaje de Programación 10
2.1.2 ¿Por qué se sigue usando programación con IA? 11
2.1.3 Similitudes entre la Inteligencia Humana y la Inteligencia artificial 11
2.1.4 Fuentes de información de la IA 12
2.1.5 Programación: el punto de partida de la IA 12

2.2 Subtipos de la IA **15**
2.2.1 Modelos de Aprendizaje Automático (Machine Learning ML) 15
2.2.2 Modelos de Aprendizaje Profundo (Deep Learning): Redes Neuronales Artificiales 20
2.2.3 Ética y peligros de la utilización de PLN en Medicina 35

2.3 Plataformas y webs especializadas en IA médica 36

3.
Objetivos generales. IA en Medicina de Urgencias **39**

3.1 Urgencias: un escenario perfecto para la IA **40**

3.2 Objetivos de la IA en un departamento de urgencias **40**

4.
Objetivos clínicos de la IA en Urgencias **45**

4.1 Mejorar el triaje inicial **46**
4.1.1 Características clave del triaje: 46
4.1.2 El triaje en España y Europa 46
4.1.3 Comparación entre Sistemas de Triaje: ESI, Manchester y SET-MAT 47
4.1.4 Etapas del triaje IA 48
4.1.5 Análisis comparativo: Triaje tradicional vs. Triaje con IA 49
4.1.6 Principales estudios internacionales y nacionales recientes sobre el uso de IA en el triaje 50
4.1.7 Algoritmos utilizados en el triaje con IA (Tabla 4) 52
4.1.8 Caso práctico: Sistema de IA para triaje en el Servicio de Urgencias Hospitalarias 53
4.1.9 Limitaciones Éticas y Técnicas de la IA en el Triaje de Urgencias 55
4.1.10 Proyección Futura de la IA en Urgencias 56

4.2 Asistencia en el diagnóstico médico **57**
4.2.1. Identificación de patrones en síntomas, analíticas e imágenes 57
4.2.2 Detección temprana de condiciones críticas 59
4.3 Recomendaciones terapeuticas 65
4.3.1 Optimización de la Toma de Decisiones Terapéuticas 66
4.3.2 Alerta de Interacciones Medicamentosas y Alergias 67
4.3.3 Seguridad y Reducción de Errores 68
4.3.4 Aplicaciones Clínicas en la farmacovigilancia 68
4.4 Seguimiento en tiempo real **69**
4.4.1 Seguimiento en tiempo real y monitorización continua de parámetros vitales 69
4.4.2 Generación de alertas predictivas ante descompensaciones 71
4.4.3 Desafíos para Implementar Sistemas de Seguimiento en Tiempo Real con IA en Urgencias 73

5. Objetivos operativos y logísticos de la IA en urgencias **83**

5.1 Optimización del flujo de pacientes 84
5.1.1 Herramientas 84
5.1.2 Algoritmos de Flujo de Pacientes en Urgencias 84
5.1.3 Gestión Operativa del Flujo de Pacientes en Urgencias en España 86
5.1.4 Predicción de tiempos de espera 86
5.1.5 Gestión Dinámica de Camas y Recursos 87
5.2 Reduccion del tiempo de atencion 87
5.2.1 Automatización de Tareas Repetitivas 87
5.2.2 Asistencia en la Generación de Informes Clínicos 87
5.3 Asignacion inteligente de personal 87
5.3.1 Análisis Predictivo de Picos de Demanda 88
5.3.2 Planificación de Turnos en Función de la Carga Asistencial Esperada 88

6. Objetivos de gestión y toma de decisiones **91**

6.1 Soporte en Decisiones Administrativas **91**
6.1.1 Evaluación del Rendimiento del Servicio en Tiempo Real 92
6.1.2 Identificación de Cuellos de Botella y Propuestas Automáticas de Mejora 93
6.2 Análisis de datos para mejora continua **94**
6.2.1 Detección de Patrones 94
6.2.2 Informes Periódicos 95

7. Objetivos de seguridad del paciente **97**

7.1. Prevención de errores médicos **97**
7.1.1 Verificación automatizada de procedimientos 97
7.2 Mejor control de infecciones **98**
7.2.1 Identificación de brotes en tiempo real 98

8.

Objetivos educativos y formativos 101

8.1 **Apoyo al aprendizaje clínico** 101
8.1.1 Simulación de casos clínicos reales mediante IA 101
8.1.2 Retroalimentación personalizada para residentes y estudiantes 102

8.2 **Evaluación continua del conocimiento** **102**
8.2.1 Análisis de decisiones clínicas 102
8.2.2 Recomendaciones de mejora 104

8.3 **Impacto en el futuro de la Educación médica** **104**
8.3.1 Integración de currículos personalizados apoyados en IA 104
8.3.2 Optimización del Aprendizaje Basado en Problemas (ABP) con escenarios dinámicos 104
8.3.3 Colaboración global mediante plataformas inteligentes 105

8.4 **Riesgos y estrategias educativas para la supervisión clínica del uso de IA** **105**
8.4.1 Evaluación de trabajos clínicos cuando los estudiantes han usado PLN (Chat GPT, Gemini, Claude,Perplexity, Grok, Copilot …) sin esfuerzo propio (copiar y pegar) 108
8.4.2 Detección de dependencia excesiva en herramientas de IA 110
8.4.3 Estrategias de supervisión docente con rubricas especificas 113
8.4.4 Promoción del pensamiento critico 114
8.4.5. Plataformas y webs de Inteligencia Artificial Médica 115

9.

Recomendaciones de mejora basadas en IA para la evaluación continua en la actuación en medicina de Urgencias 119

9.1 **Contexto y Propósito** **119**

9.2 **Programa Práctico: Recomendaciones de Mejora Basadas en IA** **120**
9.2.1 Estructura del Programa 120
9.2.2 Implementación en Medicina de Urgencias 122

9.3 **Beneficios del Programa** **122**

9.4 **Consideraciones Éticas y Técnicas** **122**

9.5 **Caso de Estudio Práctico** **123**

9.6 **Aplicación a Enfermería en Urgencias** **123**
9.6.1 Contexto y Propósito 123
9.6.2 Programa Práctico en Enfermería 123
9.6.3 Ejemplo Concreto (Caso de Estudio) 124
9.6.4 Beneficios para Enfermería 124

9.7 TABLA comparativa de aplicaciones de IA en urgencias Médicos vs Enfermería 125

10.

Apéndice 127

10.1 Resumen de publicaciones sobre aplicaciones de IA en urgencias 127

11.

Conclusión 141

AUTORES

Ángel Luis Martin de Francisco Hernández
Catedrático de Medicina Universidad de Cantabria
Especialista en Nefrología
Servicio de Nefrología Hospital Universitario Valdecilla Santander Cantabria

Gonzalo Pérez Roji
Coordinador Urgencias HU Valdecilla
Especialista en Medicina Familiar y Comunitaria.
Servicio de Urgencias Hospital Universitario Valdecilla Santander Cantabria

Ana Rosa Alconero Camarero
Doctora en Ciencias de la Salud.
Profesora Titular de Universidad. Universidad de Cantabria.

Itziar Ostolaza Tazón
F.E.A de Urgencias
Especialista en Medicina Familiar y Comunitaria.
Servicio de Urgencias Hospital Universitario Valdecilla Santander Cantabria

Cristina Pérez Tejedor
Supervisora del Servicio de Urgencias
Diplomada Universitaria en Enfermería.
Hospital Universitario Valdecilla Santander Cantabria

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización y redacción del borrador original: Martín de Francisco A. L.

Revisión y edición: Pérez Roji G, Alconero AR, Ostolaza Tazón I, Pérez Tejedor C.

Todos los autores han leído y aprobado la versión final del manuscrito.

DEDICATORIA

Una noche en urgencias, un paciente asustado preguntó: «¿Y si no me da tiempo?». Una enfermera le tomó la mano y, con una sonrisa tranquila, respondió: «Aquí el tiempo lo ponemos nosotros, usted solo respire».

A quienes, sin importar la hora —mañana, tarde, noche o madrugada—, están siempre presentes, recibiendo a cada paciente en los servicios de urgencias con dedicación, profesionalismo y empatía. Ellos son los médicos, enfermeras, auxiliares, celadores, personal administrativo y de seguridad, cuyo esfuerzo silencioso sostiene el pulso constante de los hospitales.
Por esa entrega incansable, por ser el primer rostro de calma en medio de la confusión y la angustia, por brindarnos humanidad cuando más la necesitamos. Este libro es para vosotros, que con vocación y entrega inspiráis respeto, gratitud y esperanza. Esos pequeños actos de dedicación diaria son los que tejen la verdadera grandeza de los seres humanos.

Ángel L. Martín de Francisco
Gonzalo Pérez Roji
Ana Rosa Alconero Camarero
Itziar Ostolaza Tazón
Cristina Pérez Tejedor

PREFACIO

Es un honor prologar este libro sobre IA en Medicina de Urgencias, que se suma a una trayectoria iniciada con las obras previas: *ARTIFICIAL: La Nueva Inteligencia y su Aplicación en Nefrología [1]* y *Medicina Renal Inteligente. El futuro de la nefrología clínica con inteligencia artificial* [2] Ambas publicaciones han sido referencia en el ámbito de la Nefrología, mostrando el impacto de la IA en la transformación de la práctica clínica, el diagnóstico y la personalización de los tratamientos, y sentando las bases para explorar su potencial en otras especialidades médicas.

La inteligencia artificial y el aprendizaje automático (Machine o Deep Learning) están transformando rápidamente el trabajo clínico, con aplicaciones que ya están siendo validadas en la mayoría de los campos de la medicina. Estas herramientas prometen una mayor precisión y eficiencia tanto en el diagnóstico como en la toma de decisiones, así como el acceso a una atención sanitaria de alta calidad. La medicina de urgencias representa uno de los escenarios más exigentes y dinámicos de la atención sanitaria. En este entorno, la capacidad de respuesta rápida y precisa puede marcar la diferencia entre la vida y la muerte. La IA, al integrarse en los servicios de urgencias, promete una revolución en la forma de abordar los problemas clínicos, optimizando los procesos de triaje, diagnóstico y tratamiento, y permitiendo una gestión más eficiente de los recursos disponibles [3].

Para médicos, enfermería y estudiantes, este libro ofrece una visión actualizada y rigurosa sobre cómo la IA se convierte en un aliado imprescindible en la toma de decisiones clínicas. Estamos aún en una fase inicial, pero es muy aconsejable avanzar con el conocimiento y desarrollo progresivo de una metodología que va a cambiar el paradigma científico. Los sistemas inteligentes pueden analizar en tiempo real grandes volúmenes de datos, identificar patrones invisibles al ojo humano y sugerir diagnósticos o tratamientos basados en la evidencia más reciente, contribuyendo así a reducir errores y mejorar los resultados clínicos. La IA no sustituye el juicio profesional, eso es importante, sino que lo potencia, liberando tiempo para la atención directa al paciente, facilitando la colaboración multidisciplinar.

El interés de este libro no se limita al ámbito profesional; los pacientes son los principales beneficiados de la implantación de la IA en urgencias. El acceso a diagnósticos más rápidos y precisos, la priorización de los casos más graves y la personalización de los tratamientos se traducen en una atención más segura, eficiente y humana. Además, la capacidad predictiva de la IA permite anticipar complicaciones y adaptar los recursos a la demanda, mejorando la experiencia global en el sistema sanitario.

La obra que el lector tiene ante sí, es fruto de un trabajo conjunto con expertos en medicina de emergencia, los doctores Gonzalo Pérez Roji e Itziar Ostolaza Tazón junto a profesorado

de enfermería Ana Rosa Alconero y Supervisión de enfermería de urgencias Cristina Pérez Tejedor, y recoge tanto los fundamentos técnicos como las aplicaciones prácticas y los retos éticos de la IA en urgencias. Se abordan desde algoritmos de apoyo a la decisión clínica hasta herramientas de procesamiento del lenguaje natural y sistemas de imagen médica, ilustrando cómo la innovación tecnológica puede integrarse de manera efectiva en la rutina asistencial y educativa.

A medida que la IA se consolide en los departamentos de urgencias, la atención será cada vez más rápida, precisa y segura, permitiendo a los equipos sanitarios anticipar riesgos, optimizar recursos y, sobre todo, ofrecer un cuidado centrado en la persona. Este libro invita a médicos, estudiantes y gestores sanitarios a liderar este cambio, formándose y adaptándose a una realidad en la que la tecnología y la humanidad avanzan de la mano.



Ángel Luis Martín de Francisco
Catedrático de Medicina. Universidad de Cantabria
Servicio de Nefrología. HU Valdecilla Santander Cantabria

Referencias

1 De Francisco ALM. Artificial. La Nueva Inteligencia y su Aplicación en Nefrología. En Lorenzo V, López Gómez JM (Eds) Nefrología al Día ISBN 978-84-127624-1-9.

2 De Francisco ALM Medicina Renal Inteligente. El futuro de la nefrología clínica con inteligencia artificial En Lorenzo V, López Gómez JM (Eds) Nefrología al Día ISBN 978-84-129769-3-9

3 Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. Nat Med. 2019 Jan;25(1):44-56

AGRADECIMIENTOS

Se reconoce el uso de sistemas de inteligencia artificial (ChatGPT 5, Grok 3 y Copilot) como herramientas de apoyo en la consulta de literatura, la estructuración de contenidos y la generación de tablas y material complementario.
No obstante, los autores declaran que todas las decisiones intelectuales, la interpretación crítica de la información y la redacción final de esta obra han sido realizadas de manera independiente y son de su exclusiva responsabilidad.
Asimismo, algunos fragmentos de texto generados con dichos sistemas fueron revisados, cotejados y validados por los autores antes de su inclusión definitiva.

1.

INTRODUCCIÓN

Un servicio de urgencias hospitalarias saturado es el reflejo de una crisis asistencial que se repite con frecuencia en muchos centros sanitarios y que hemos vivido en su grado máximo durante la crisis del Covid. Al cruzar la puerta de urgencias, el primer impacto es el de una sala de espera abarrotada, con pacientes y familiares ocupando cada asiento disponible y, en ocasiones, incluso de pie, formando largas colas que llegan hasta la entrada del hospital. Muchos de estos pacientes esperan durante horas, algunos sin saber si su situación es realmente grave o si pueden esperar, lo que genera ansiedad e incertidumbre tanto en ellos como en sus acompañantes [1].

En los pasillos, las camillas se alinean a ambos lados, convertidos en improvisadas áreas de atención ante la falta de camas disponibles. Los profesionales sanitarios, visiblemente agotados, se ven obligados a hacer lo imposible para encontrar un lugar donde atender a cada paciente, mientras las ambulancias se acumulan en la entrada, inoperativas, porque no hay espacio donde trasladar a los recién llegados. La falta de personal es palpable: enfermeras y médicos corren de un lado a otro, intentando atender a decenas de pacientes con recursos insuficientes.



La búsqueda de información clínica se convierte en una carrera contrarreloj. Una enfermera pregunta por el paradero de un paciente que debía ser trasladado a rayos, mientras otro sanitario intenta localizar los resultados de una analítica en un sistema informático saturado y poco intuitivo. El médico, por su parte, busca con urgencia el informe de una radiografía para poder tomar una decisión crítica, pero el documento tarda en llegar a la pantalla o se pierde entre múltiples peticiones pendientes.
El caos organizativo es evidente: pacientes que requieren atención inmediata pueden pasar inadvertidos entre la multitud, mientras otros, menos graves, ocupan recursos durante horas. La falta de una visión global y en tiempo real del estado de cada paciente y de la carga asistencial dificulta la priorización y la gestión eficiente de los recursos. Los profesionales se ven obligados a improvisar, a menudo sin datos suficientes para decidir a quién atender primero o cómo redistribuir las tareas del equipo. En este contexto, que afortunadamente no es diario, pero sí frecuente, la incertidumbre y la presión aumentan el riesgo de errores, retrasos en diagnósticos y tratamientos, y una experiencia angustiosa tanto para los pacientes como para el personal sanitario. La saturación y el desorden no solo comprometen la calidad asistencial, sino que también generan un clima de estrés crónico y desgaste profesional [2].
¿Podrá la IA ayudar a mejorar la situación en un servicio de urgencias hospitalarias?
Este libro surge como una necesidad de solucionar todo lo anterior y responder a esa pregunta. Frente a un sistema desbordado y unas urgencias al límite, la inteligencia artificial se presenta como una oportunidad transformadora. No se trata solo de implementar tecnología, sino de reimaginar los procesos asistenciales con herramientas capaces de aprender, adaptarse y colaborar con los profesionales. Desde algoritmos de triaje inteligente hasta sistemas que integran y priorizan información clínica en tiempo real, la IA puede convertirse en un aliado crucial para recuperar el control, reducir los tiempos de espera y aumentar la seguridad del paciente [3]. El reto no es menor, y aún deben superarse muchos retos, pero la pregunta ya no es si la IA tiene potencial, sino cómo y cuándo seremos capaces de integrarla de forma ética, efectiva y humana en los servicios de urgencias.
Vamos a ello

Referencias

1 Pearce S, Marr E, Shannon T, Marchand T, Lang E. Overcrowding in emergency departments: an overview of reviews describing global solutions and their outcomes. Intern Emerg Med. 2024 Mar;19(2):483-491.

2 Tudela P, Módol JM . La saturación en los servicios de urgencias hospitalarios. Emergencias. 2015;27(2):113-120

3 Rajkomar A, Dean J, Kohane I. Machine learning in medicine. N Engl J Med. 2019 Apr 4;380(14):1347-1358

2.

INTELIGENCIA ARTIFICIAL. CONCEPTOS BÁSICOS

Antes de avanzar sobre los objetivos de este libro que vendrán definidos a continuación, parece aconsejable introducirnos en conceptos básicos de la inteligencia artificial desde cero, ocupándonos de lo más básico para entender su funcionamiento
Se invita al lector a consultar el siguiente video en Nefrología al Día ,que incluye una sencilla explicación del texto que vamos a desarrollar
---
Inteligencia artificial desde cero Una guía esencial en 50 minutos
Angel Luis Martin de Francisco Hernández
[https://www.nefrologiaaldia.org/es-inteligencia-artificial-desde-cero]

La inteligencia artificial (IA) es un conjunto de tecnologías que permiten a las máquinas simular la inteligencia humana para realizar tareas como el reconocimiento de voz, la toma de decisiones, el procesamiento del lenguaje natural y la visión por computadora. Funciona a través de algoritmos y modelos de aprendizaje que procesan grandes cantidades de datos para identificar patrones y hacer predicciones o tomar decisiones. Los sistemas de IA «aprenden» a través de numerosas repeticiones y el correspondiente feedback (entrenamiento) cómo alcanzar mejor una solución predeterminada (por ejemplo, diagnóstico, pronóstico de una enfermedad), lo que permite que el resultado sea más preciso y los procedimientos más eficientes [1][2].

2.1 FUNCIONAMIENTO DE LA IA

La IA funciona gracias a (*Figura 1*)**:**

1. Herramientas informáticas: son los ordenadores y los programas que usan.

2. Fórmulas matemáticas: que ayudan a esos programas a aprender de los datos, como si buscaran patrones o repeticiones.

3. Y con estas fórmulas se crean Algoritmos, que son las instrucciones o pasos que se suceden secuencialmente para llevar a cabo una acción concreta. Supongamos que queremos ordenar una lista de nombres.

El algoritmo podría ser:

- Comparar el primer nombre con el segundo.
- Si el primero va antes que el segundo, dejarlos en ese orden.
- Si el segundo va antes que el primero, intercambiarlos.
- Repetir estos pasos para todos los nombres de la lista.

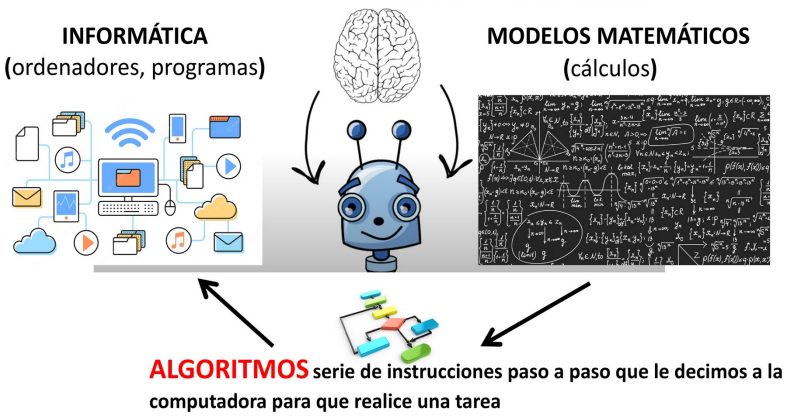


Figura 1. Funcionamiento de la Inteligencia Artificial

Veamos otros ejemplos prácticos de algoritmos:

- Reconocimiento facial: Un algoritmo analiza las características de una cara (ojos, nariz, boca) y las compara con una base de datos para identificar a una persona.
- Recomendaciones en Netflix: Un algoritmo analiza tus películas favoritas y te sugiere otras que podrían gustarte, basándose en los gustos de otros usuarios con preferencias similares.
- Traducción automática: Un algoritmo analiza un texto en un idioma y lo traduce a otro, identificando patrones en las palabras y las frases.
- Coches autónomos: Un algoritmo procesa información de sensores (cámaras, radares) para tomar decisiones sobre la conducción, como acelerar, frenar o girar

2.1.1 Lenguaje de Programación

Es la herramienta para decirle a las computadoras qué hacer. Explicado de una manera sencilla es como un idioma especial que usamos para decirle a un ordenador lo que queremos que haga. En vez de hablarle como a una persona, usamos palabras y reglas que la máquina sí puede entender, para que siga nuestras instrucciones y realice tareas como mostrar una página web, sumar números o mover un personaje en un videojuego. Hay diferentes tipos según lo fácil que sean de usar y lo cerca que estén del lenguaje de las máquinas o de las personas. Los más usados son Python (el más utilizado) y Java Script.

Un ejemplo fácil:

- Usamos **input()** para pedirle al usuario que escriba algo.
- Usamos **print()** para mostrar mensajes o resultados en pantalla.

¿Cómo funciona un programa?
Un programa sigue una serie de pasos (llamados instrucciones o algoritmo) para hacer lo que queremos. Estos pasos pueden incluir operaciones matemáticas y decisiones, como:

- **if** (si pasa algo, hacer esto)
- **else** (si no, hacer otra cosa)
- **for** y **while** (repetir acciones varias veces)

Veamos un ejemplo sencillo en Python:

- nombre = input («¿Cómo te llamas? «)
- **print**(«Hola, « + nombre)

¿Qué hace este programa?

1. La primera línea pregunta tu nombre y guarda lo que escribes en una "caja" llamada **nombre**.
2. La segunda línea muestra un saludo usando el nombre que escribiste.

Cuando lo ejecutas, vemos algo así:

text
¿Cómo te llamas? Ana
Hola, Ana

El lenguaje de programación se sigue utilizando (y más que nunca) con la inteligencia artificial. De hecho, los lenguajes de programación son fundamentales para crear, entrenar y desplegar sistemas de IA. La IA no reemplaza la necesidad de programar; más bien, cambia la forma en que se programa y amplía lo que se puede hacer con la programación

2.1.2 ¿Por qué se sigue usando programación con IA?

Aunque la IA ha avanzado muchísimo —incluso puede escribir código—, los lenguajes de programación siguen siendo la base de todo sistema inteligente. Así como necesitamos palabras para construir frases, necesitamos lenguajes de programación para construir modelos de IA y aplicaciones que los usen. Se explica porque:

1. La IA se programa: Para que una IA pueda reconocer una imagen o entender una pregunta, primero hay que escribir instrucciones en un lenguaje que la computadora entienda, como Python. Con Python, usamos programas especiales llamados TensorFlow o PyTorch. Estos programas ayudan a "enseñar" a la IA, mostrándole muchos ejemplos para que aprenda a reconocer cosas, como fotos de gatos o el significado de una pregunta.
2. La IA necesita integrarse en aplicaciones: Una IA por sí sola no sirve si no está conectada a un programa que la use. Para eso, se sigue programando. Por ejemplo, se puede usar JavaScript para hacer que una IA funcione dentro de una página web.
3. La IA no es mágica: Aunque hay herramientas que generan código automáticamente, es importante que una persona sepa leer, entender y corregir ese código. La programación sigue siendo clave para tener el control y garantizar que la IA funcione como queremos.
4. La IA ayuda, pero no sustituye al programador: Herramientas como GitHub Copilot o ChatGPT pueden ayudar a escribir código más rápido, pero no reemplazan la necesidad de saber programar. Al contrario, hacen que aprender a programar sea más accesible y productivo.

2.1.3 Similitudes entre la Inteligencia Humana y la Inteligencia artificial

(*Figura 2*). La inteligencia artificial tiene muchas similitudes con la inteligencia humana. Nosotros tenemos 5 biosensores (vista, oído, olfato, gusto y tacto) que están permanentemente captando información del medio que nos rodea, y transformándola en información bioeléctrica para mandarla a nuestro procesador, que es nuestro cerebro, donde se encuentran los mejores algoritmos que jamás se hayan diseñado sobre esta tierra y que tienen cientos de miles de años de evolución. Con esa

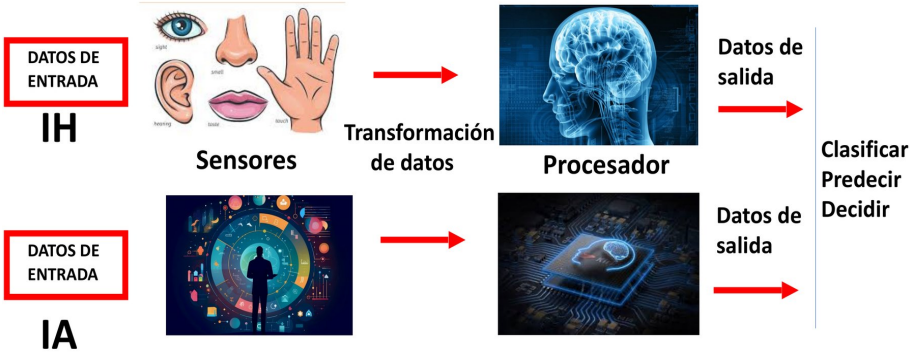


Figura 2. Similitudes Inteligencia humana e Inteligencia artificial

información buscan patrones, los clasifican y generan conocimiento para tomar decisiones. La IA actúa de la misma manera. Tenemos sensores que captan información que a través del procesador la analiza y clasifica para predecir y decidir

2.1.4 Fuentes de información de la IA

(Figura 3). La IA puede obtener información y datos de diversas fuentes, toda la imaginable de cuantas fuentes existen en el mundo. Algunas de las cuales incluyen:

- Bases de datos y conjuntos de datos
- Sensores y dispositivos de temperatura, humedad, luz
- Registros médicos electrónicos y otros datos de atención médica
- Publicaciones
- Redes sociales y otras plataformas en línea
- Cámaras y sistemas de vigilancia
- Transcripciones de conversaciones y grabaciones de audio
- Información de encuestas y estudios de mercado
- Datos meteorológicos y geoespaciales

2.1.5 Programación: el punto de partida de la IA

Aunque ya hemos visto brevemente este tema de programación, vamos a volver ya que es el punto de inicio de la IA. Para estructurar un capítulo sobre los subtipos de IA, es fundamental comenzar desde la base: la programación. Ya hemos dicho que la programación es la disciplina fundacional que permite el desarrollo de cualquier sistema informático, pero no es IA en sí misma. Sin embargo, es el punto de partida imprescindible para comprender cómo se construyen y evolucionan los sistemas inteligentes. A partir de ahí, se puede avanzar hacia los distintos subtipos de IA: Machine Learning (ML), Deep Learning (DL) e Inteligencia Artificial Generativa (GAI o GenAI) *(Figura 4).*
Programar consiste en dar instrucciones explícitas a una máquina para que realice tareas determinadas. Esto implica lógica, algoritmos y estructuras de datos, pero no inteligencia ni capacidad de aprendizaje autónomo. La programación clásica resuelve problemas mediante reglas fijas y procesos definidos por humanos, sin que el sistema aprenda o se adapte por sí mismo [3]



Figura 3. Fuentes de información de la IA

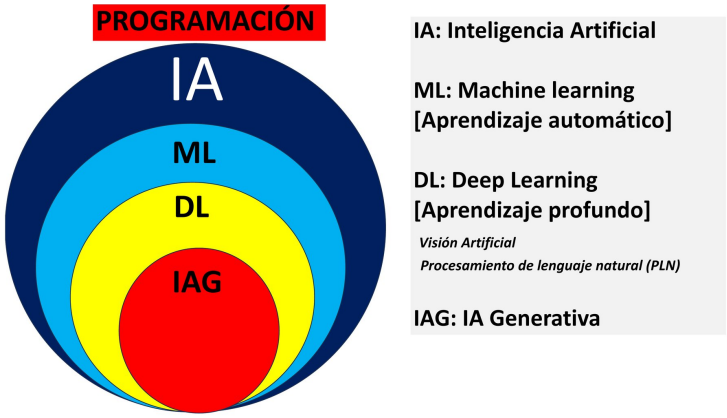


Figura 4. Programación y subtipos de inteligencia artificial

La programación es la base sobre la que se construyen los sistemas de IA. Sin conocimientos sólidos de programación, es imposible desarrollar algoritmos de aprendizaje automático o redes neuronales. Ya hemos visto que lenguajes como Python o JavaScript son ampliamente utilizados tanto en programación tradicional como en IA, ya que ofrecen potentes bibliotecas y herramientas especializadas para el desarrollo de modelos inteligentes [4]. En la programación tradicional tenemos los datos de entrada, un algoritmo conocido

escrito por programadores y los datos de salida no conocidos *(Figura 5)*.
Veamos un **ejemplo de Programación de facturación de una tienda**. En la programación tradicional, como hemos dicho, tenemos los datos de entrada conocidos, un algoritmo conocido escrito por programadores y los datos de salida que no conocemos *(Figura 6)*.

- Entradas conocidas

  A_1: Precio unitario del producto; B_1: Cantidad de productos; C_1: % de descuento

- Algoritmo conocido:

  1. Multiplicar el precio unitario (A_1) por la cantidad (B_1) para obtener el subtotal.
  2. Calcular el monto de descuento aplicando el porcentaje (C_1) al subtotal.
  3. Restar el descuento al subtotal para obtener el total final.

- Salidas (no conocidas hasta ejecutar el algoritmo)



Figura 5. Ejemplo de programación



Figura 6. Ejemplo de programación en la compra de tres ejemplares de un producto

A_2: Subtotal (precio unitario × cantidad); B_2: Monto de descuento; C_2: Total a pagar (subtotal - descuento)

Ejemplo con valores concretos:

- A_1 = €20 (precio unitario); B_1 = 3 (cantidad); C_1 = 10% (descuento)

Aplicando el algoritmo:

- A_2 = 20 × 3 = €60 (subtotal)
- B_2 = 10% de €60 = $6 (descuento)
- C_2 = $60 - $6 = €54 (total a pagar)

Así, el proceso sigue exactamente el flujo: partimos de tres entradas conocidas, aplicamos un algoritmo definido por el programador y obtenemos tres salidas que no se conocen hasta ejecutar el cálculo. Así que como hemos comentado previamente la programación tiene reglas fijas y procesos definidos por humanos, sin que el sistema aprenda o se adapte por sí mismo como es la Inteligencia Artificial.

2.2 SUBTIPOS DE LA IA

La IA surge cuando los sistemas informáticos dejan de limitarse a ejecutar instrucciones fijas y empiezan a simular capacidades humanas como el razonamiento, el aprendizaje y la toma de decisiones autónomas. A continuación, se presentan los principales subtipos de IA, en orden de especialización y complejidad

1. Modelos de Aprendizaje Automático (ML: Machine Learning)
2. Modelos de Aprendizaje Profundo (DL: Deep Learning)

2.2.1 Modelos de Aprendizaje Automático (Machine Learning ML)

En el Machine Learning tenemos los datos de entrada y de salida, pero lo que no tenemos es el algoritmo. Es decir, conocemos los datos de entrada y los de salida y con estos datos entrenamos al sistema para que encuentre el algoritmo por prueba y error. Se dan ejemplos y resultados, y el sistema aprende solo las reglas internas, incluso sin intervención humana. Luego, probamos el sistema para determinar si aprendió correctamente y le seguimos dando más datos para que siga perfeccionando su algoritmo *(Figura 7)*.



Figura 7. Aprendizaje Automatico o Machine Learning

Ejemplo 1 de ML: Predecir el precio de una casa

- Entrada (Conocida): A1 Tamaño en m²; B1 número de habitaciones, C1: ubicación
- Salida (Conocida): Precios de venta de cada casa según las diferentes características: 250.000 € ;300.000 € ;350.000 € ;400.000 €…
- El sistema aprende a estimar precios en función de esos factores.

Ejemplo 2 de ML: Predecir supervivencia a un año de un paciente con enfermedad renal crónica

- Datos de Entrada (conocidos): Edad del paciente, estadio de la ERC (Ej. Estadio 3b, 4, 5)), tasade filtrado glomerular (TFG), presión arterial sistólica y diastólica, niveles de creatinina y potasio, presencia de diabetes o hipertensión, albúmina en orina (proteinuria), adherencia al tratamiento
- Datos de Salida (conocidos): Paciente sobrevivió o no al año (Sí / No). (Estos datos se recogen de registros clínicos reales)
- Entrenamiento del Modelo: con los datos de miles de pacientes, el algoritmo aprende a detectar qué combinaciones de variables aumentan o reducen la probabilidad de supervivencia
- Predicción para Nuevos Pacientes: se introducen los datos de un nuevo paciente y el sistema te devuelve: la probabilidad de supervivencia a 1 año, digamos 85%. Incluso puede recomendarte variables críticas a corregir (ejemplo: controlar mejor la hipertensión o la proteinuria).
- Este tipo de modelo se usa en la práctica con algoritmos como regresión logística, árboles de decisión o XGBoost, y ayuda a los médicos a identificar pacientes de mayor riesgo y ajustar su manejo clínico.

Obviamente, el Machine Learning necesita muchos datos para entrenar. Pongamos otro ejemplo: miles de fotos de manzana (eso lo llamamos DATASET) para que aprenda (color, forma, etc) y luego probamos con una naranja a ver si aprendió o no.

Los tipos de algoritmos en ML son:

- Regresión: Predice valores numéricos. Ejemplo: predecir el precio de una casa según sus características.
- Clasificación: Asigna una categoría o etiqueta. Ejemplo: diferenciar manzana de pera
- Clustering o agrupamiento: Agrupa elementos similares sin saber de antemano a qué grupo pertenecen. Ejemplo: segmentar clientes por comportamiento de compra
- Asociación: Encuentra relaciones entre elementos. Ejemplo: "quien compra pan suele comprar leche" (como en los supermercados).

AUROC: Área bajo la curva

Cada algoritmo de IA tiene una sensibilidad y especificidad determinadas. Gráficamente, esto se representa en la (*Figura 8)* en un diagrama donde el eje x corresponde a (1 - especificidad) es decir la tasa de falsos positivos y

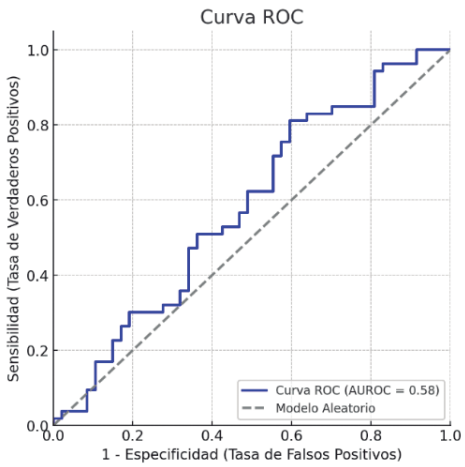


Figura 8. Área bajo la curva de la característica operativa del receptor (AUROC)

el eje y a la sensibilidad que representa la tasa de verdaderos positivos El «área bajo la curva de la característica operativa del receptor» (AUROC) se utiliza para evaluar el rendimiento del modelo.
Cuanto mayor sea la AUROC, mejor distinguirá el modelo: valores por debajo de 0.7 suelen ser poco informativos y valores superiores a 0.9 se consideran excelentes.

2.1.1.1 Tipos de aprendizaje automático (ML)
Existen tres modelos: supervisado, no supervisado y reforzado *(Figura 9)*.

- Aprendizaje Supervisado: En este modelo, el algoritmo aprende a partir de datos etiquetados, es decir, ejemplos en los que la respuesta correcta ya es conocida. Enseñamos al sistema los resultados que queremos obtener, es decir la respuesta correcta (*Figura 10)*. Es lo que venimos comentando con el ejemplo anterior de predicción del precio de una casa. Si te digo **al 1 le corresponde el 2** y al 2 el 4 y al 4 el 8, con seguridad tú habrás asociado a que el algoritmo es multiplicar por 2. Otro ejemplo sería el de la **diferenciación de perros y gatos**: el aprendizaje automático supervisado distingue perros de gatos analizando miles de imágenes etiquetadas y aprendiendo patrones visuales como la forma de las orejas, el



Figura 9. tipos de Machine Learning (aprendizaje automático)

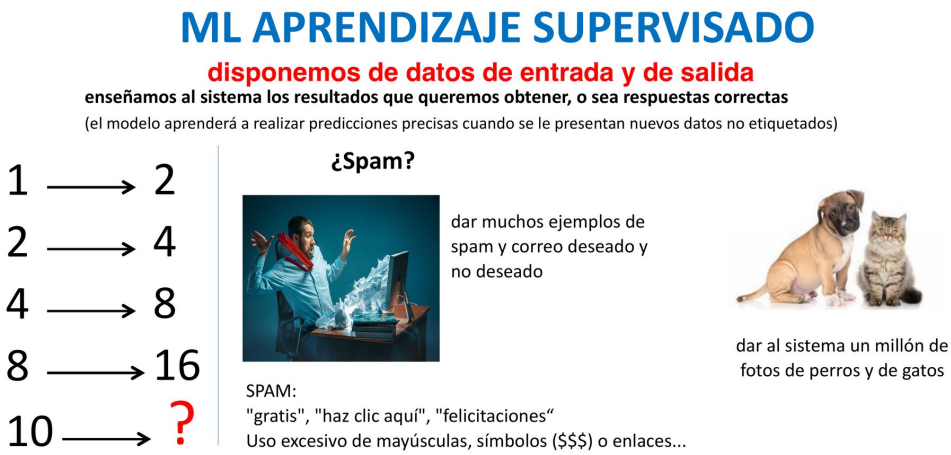


Figura 10. Aprendizaje Supervisado

tamaño del hocico o la textura del pelaje para predecir a qué clase pertenece una imagen nueva. Otro ejemplo sería la relación en un correo electrónico entre **spam y correo deseado**. Solo hay que dar muchos ejemplos de spam y correo deseado y su clasificación, y aprenderá a distinguirlos. Detecta palabras o frases clave: como «gratis», «haz clic aquí», «felicitaciones», uso excesivo de mayúsculas, símbolos ($$$) o enlaces.
La IA ajusta su modelo en función de los datos de entrenamiento para hacer predicciones precisas en nuevos casos.

- Aprendizaje no supervisado (agrupación): Solo disponemos de datos de entrada No enseñamos al sistema los resultados que queremos obtener. Encuentran los patrones subyacentes (clusters) en los datos a analizar *(Figura 11)*. Su objetivo es encontrar la estructura oculta del conjunto de datos, agruparlos según sus semejanzas y devolver una representación útil del conjunto buscando patrones de similitud de los datos de entrada. Esta solución de inteligencia artificial es perfecta para incluir en la estrategia de marketing. Por ejemplo, las personas que compran el artículo X (supongamos que un teléfono móvil) también tienden a comprar el artículo Y (un cargador o unos auriculares inalámbricos). Es lo que hace **Netflix** para recomendarte películas en función de tus gustos. O sea, agrupa los datos a analizar por características comunes.
En triaje de urgencias, un algoritmo de **clustering** analiza signos vitales y datos iniciales sin etiquetas previas, agrupando a los pacientes en perfiles de riesgo (bajo, medio, alto) para priorizar la atención
- Aprendizaje por refuerzo: Este modelo se basa en un agente que aprende a **tomar decisiones mediante prueba y error, recibiendo recompensas o penalizaciones según sus**

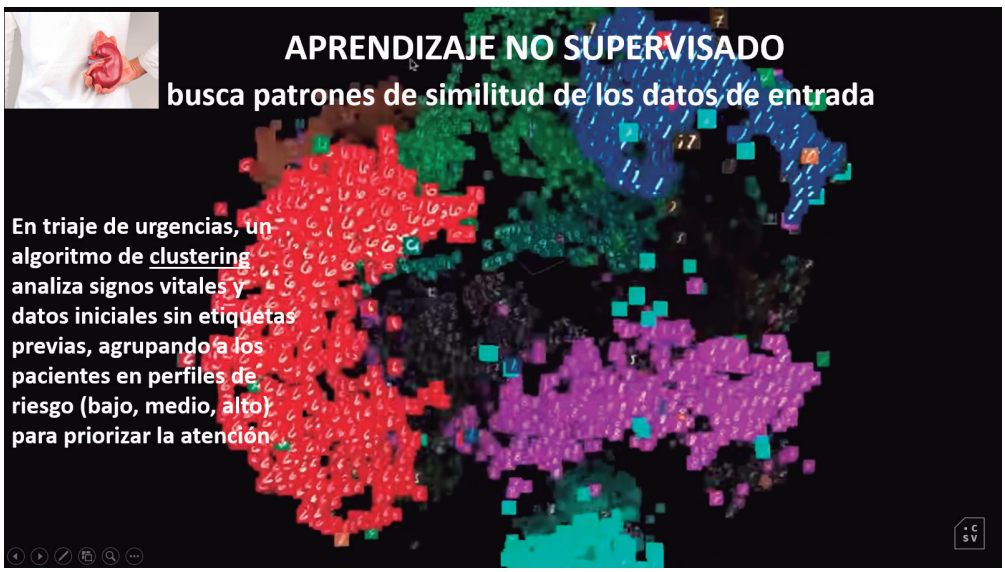


Figura 11. Aprendizaje no supervisado

acciones (*Figura 12*). Veamos un ejemplo simple de aprendizaje reforzado que ilustra los conceptos básicos de esta técnica de aprendizaje automático. Imaginemos un ***robot aspirador*** que debe limpiar una habitación. El robot no tiene instrucciones explícitas sobre cómo limpiar la habitación, sino que debe aprender por sí mismo cómo hacerlo. El robot comienza por explorar la habitación y recopilando información sobre el entorno. Luego, el robot comienza a tomar acciones, como mover sus ruedas y su cepillo. El robot recibe una recompensa cuando limpia una zona de la habitación y una penalización cuando se atasca o choca con un obstáculo: un valor numérico positivo o negativo. A medida que el robot toma más acciones, aprende a limpiar la habitación de manera más eficiente. El robot aprende a evitar obstáculos, a limpiar todas las zonas de la habitación y a terminar su trabajo en el menor tiempo posible. Imagina que el robot está en una habitación y encuentra una zona sucia. Si se mueve hacia esa zona y la limpia, recibirá una recompensa alta. Esta recompensa positiva reforzará la acción de moverse hacia zonas sucias. Por el contrario, si choca con una pared, recibirá una recompensa negativa, lo que le enseñará a evitar los obstáculos.

Otro ejemplo muy práctico de aprendizaje reforzado es un ***coche autónomo*** que debe conducir por una carretera. El coche no tiene instrucciones explícitas sobre cómo conducir, sino que debe aprender por sí mismo cómo hacerlo. El coche utiliza sensores para recopilar información sobre el entorno, como la posición de otros vehículos, las señales de tráfico y las condiciones de la carretera. Luego, el coche utiliza esta información para tomar decisiones sobre cómo conducir, como acelerar, frenar o girar. El coche recibe una recompensa cuando conduce de manera segura y eficiente y una penalización cuando se produce un accidente o cuando se incumplen las normas de tráfico.

A medida que el coche toma más decisiones, aprende a conducir de manera más segura y eficiente. El coche aprende a evitar otros vehículos, a seguir las señales de tráfico y a



Figura 12. Aprendizaje reforzado

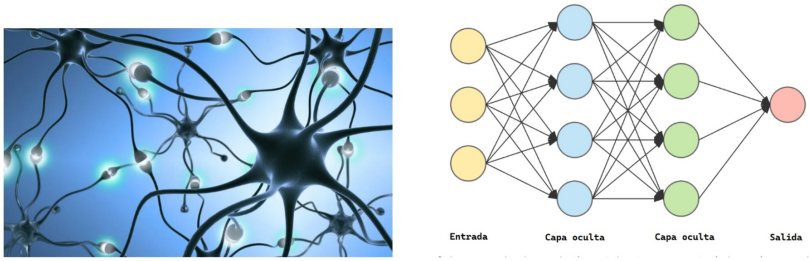
adaptarse a las condiciones de la carretera. Así que, en el aprendizaje por refuerzo, el agente no solo toma decisiones, sino que aprende de sus errores mediante un proceso de prueba y error. En el caso del ***triaje en urgencias***, cuando el sistema prioriza mal a un paciente (por ejemplo, atendiendo primero al paciente con fractura en lugar del que tiene dolor torácico agudo), recibe una recompensa negativa o penalización basada en los resultados clínicos adversos, como empeoramiento o mayor tiempo de espera para casos urgentes. Entonces, el agente ajusta su política para evitar repetir ese error en el futuro, «volviendo» a probar nuevas acciones y estrategias hasta optimizar la toma de decisiones. Este ciclo de ensayo, error y ajuste es fundamental en aprendizaje por refuerzo y permite que el sistema mejore continuamente, aprendiendo a priorizar correctamente.

2.2.2 Modelos de Aprendizaje Profundo (Deep Learning): Redes Neuronales Artificiales

El Aprendizaje Profundo (DL) es una rama de la inteligencia artificial que utiliza redes neuronales para imitar la forma en que el cerebro humano aprende y procesa información [1]. El DL es un tipo de Machine Learning supervisado, donde el modelo aprende patrones a partir de grandes volúmenes de datos etiquetados, es decir, **se le proporciona tanto la entrada como la salida esperada**. Por ejemplo, para entrenar una red neuronal a reconocer cáncer de pulmón en imágenes, se le muestran miles de fotos de entrada, junto con la etiqueta correspondiente conocida (cáncer sí, o cáncer no) como salida. Con el tiempo, la red aprende a identificar cáncer de pulmón por sí sola en nuevas imágenes.

Las neuronas artificiales son iguales que las biológicas (*Figura 13*). Se llaman perceptrón y son unidades matemáticas: reciben, procesan y envían la información a otras neuronas formando una gran red. Cada neurona recibe entradas, realiza cálculos y produce una salida. Estas salidas se transmiten a través de las conexiones a otras neuronas y así sucesivamente, hasta obtener una salida final. Cada neurona procesa una tarea especifica y envía sus resultados a las otras neuronas de su red para trabajar juntas. Cuantas más capas más problemas complejos podrá resolver

Una neurona artificial (o perceptrón) es una unidad matemática. Podemos imaginar que una red neuronal es una hoja de cálculo gigante con miles de fórmulas interconectadas: cada celda es como una neurona que calcula algo,



Conexiones neuronales **Red Neuronal Artificial**

Figura 13. Conexiones y redes neuronales

pasa el resultado a otra, y así se construye una cadena de decisiones. Las neuronas artificiales no existen físicamente como elementos separados, sino que son estructuras lógicas dentro de un programa de ordenador. Están almacenadas como números en la memoria del ordenador.

2.2.2.1 Cómo funcionan las redes neuronales

Como ya hemos comentado, las redes neuronales son un tipo de algoritmo de aprendizaje automático que se inspira en el cerebro humano. Aunque pueden parecer complejas, las redes neuronales se componen de estructuras y componentes básicos que trabajan juntos para procesar información y producir una salida.

2.2.2.1.1 Estructura y componentes básicos de una red neuronal

La estructura básica de una red neuronal consta de capas de neuronas interconectadas. La capa de entrada recibe los datos y los envía a través de la red, mientras que la capa de salida produce la salida final. Entre la capa de entrada y la capa de salida, hay una o más capas ocultas que procesan la información. Cada neurona en la red neuronal está conectada a otras neuronas a través de conexiones que, al igual que en el mundo biológico, son conocidas como sinapsis. Cada sinapsis tiene un peso asociado que determina la fuerza de la conexión, (lo veremos en la práctica más adelante) y durante el proceso de entrenamiento, estos pesos se ajustan mediante el aprendizaje para mejorar la precisión y el resultado de la salida de la red.

2.2.2.1.2 Proceso de entrenamiento y ajuste de pesos

El proceso de entrenamiento de una red neuronal implica proporcionarle datos de entrada y esperar una salida ya conocida. Si la salida no coincide con la salida deseada, retrocede y ajusta los pesos de las conexiones en la red para mejorar la precisión. Este proceso se repite muchas veces hasta que la red aprende a producir la salida deseada. Hay varios algoritmos de entrenamiento utilizados en las redes neuronales, incluyendo el algoritmo de retropropagación. En este algoritmo, se calcula el error de la salida de la red en comparación con la salida deseada y se ajustan los pesos de las conexiones para minimizar ese error.

2.2.2.1.3 Funciones de activación y su importancia

Las funciones de activación son una parte fundamental de cómo funcionan las redes neuronales. Cada neurona en la red neuronal utiliza una función de activación para determinar su salida en función de la entrada que recibe. Las funciones de activación pueden ser lineales o no lineales. Las funciones lineales simplemente multiplican la entrada por un peso y agregan un término de sesgo. Las funciones no lineales, por otro lado, son más complejas y permiten a la red modelar relaciones no lineales en los datos. La elección de la función de activación puede tener un impacto significativo en la capacidad de la red para aprender y generalizar a nuevos datos. Algunas funciones de activación comunes incluyen la función sigmoide, la función ReLU y la función tangente hiperbólica.

2.2.2.2 Ejemplos de funcionamiento de redes neuronales *(Figura 14)*

Las neuronas funcionan de la siguiente manera: En primer lugar, tienen datos de entrada y cada uno tiene un peso w que significa la importancia de este dato. Por ejemplo, la edad tendrá un peso de gran valor porque es muy importante en el cálculo de la supervivencia mientras que por ejemplo los hábitos de lectura no lo serán tanto. Luego estos datos y sus pesos se multiplican y se suman en el cuerpo de la neurona o perceptrón. Después, el resultado de ese

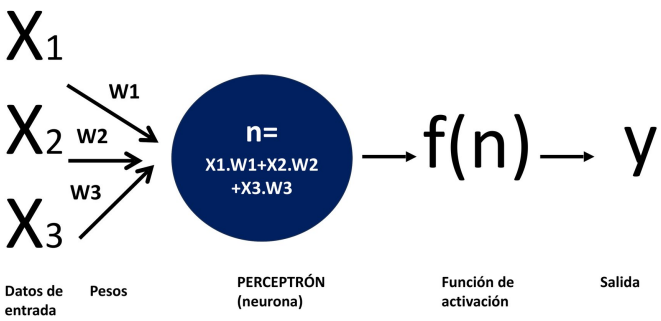


Figura 14. Funcionamiento de red neuronal

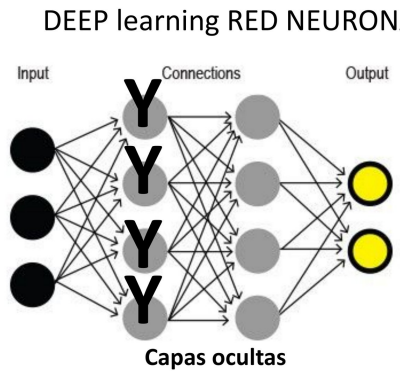


Figura 15. El dato de salida es el dato e entrada de una o más neuronas en la red

cálculo se pasa por una función matemática de activación que da el dato de salida. Y como vemos en la siguiente *(Figura 15),* ese dato Y de salida es el dato de entrada de una o más neuronas en la red.

Las redes neuronales son aprendizaje supervisado. Es decir, reciben una serie de datos de entrenamiento y sus respectivos valores de salida correctos, lo que significa que ya conocemos cuales son las respuestas. Con estos datos, el sistema intenta calcular los pesos y aplica la función de activación al resultado. La salida se compara con el resultado real, el que conocemos de antemano y se encuentra el error promedio, es decir la diferencia con el resultado que ya conocíamos. Con ese error promedio se regresa hacia atrás a través de todas las capas de la red (back) para ajustar los pesos. Con los pesos ajustados, se vuelven a hacer todos los cálculos (forward) y se vuelve a comparar la salida con el resultado de entrenamiento, se calcula el error y de nuevo se vuelve hacia atrás. Este proceso de ajustar, volver a encontrar lo errores, volver a ajustar y en cada vuelta volver a hacerlo mejor se repite varias veces hasta que el error de 0 o lo más cercano a 0. Es por eso por lo que decimos que los modelos se perfeccionan a sí mismo

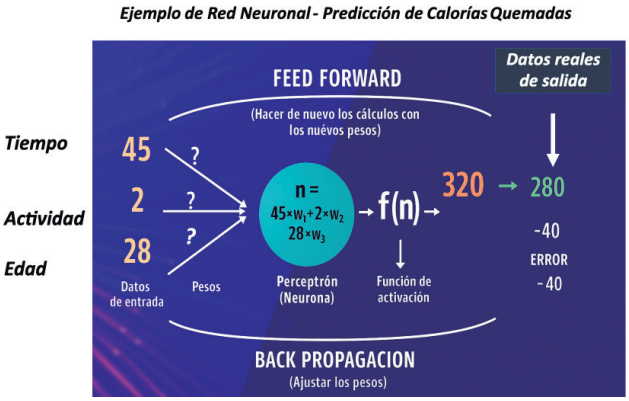


Figura 16. Predicción de calorías quemadas

sin intervención humana. Cada uno de estos pesos son ajustados en cada vuelta o época y cada uno de ellos se conoce como parámetro. Como ejemplo, Chat GPT tiene 175 millones de parámetros. Veamos ejemplos

Ejemplo 1: Predicción de calorías quemadas *(Figura 16)*

Datos de entrada:

- Minutos de ejercicio: 45
- Tipo de actividad (codificado): 2 (por ejemplo, 1=caminata, 2=correr, 3=bicicleta)
- Edad del usuario: 28

Fórmula del perceptrón (neurona):

$n = (45 \times w_1) + (2 \times w_2) + (28 \times w_3)$

Los pesos w_1, w_2, w_3 son los que la red debe aprender automáticamente para predecir bien.

Proceso:

1. Se hace el cálculo con pesos iniciales al azar (Feed Forward).
2. Se obtiene un resultado: por ejemplo, 320 calorías.
3. Se compara con el valor real que conocemos por estudios previos en esas condiciones exactas: por ejemplo, 280 calorías.
4. Se mide el error.
5. Se vuelve atrás y se reajustan los pesos para mejorar (esto se llama Backpropagation).
6. Se repite el proceso hasta que el error sea muy pequeño.

Resultado:

La red aprende a predecir, con buena precisión, cuántas calorías quema una persona según su tiempo de ejercicio, tipo de actividad y edad.

Ejemplo 2: préstamo *(Figura 17)*

Imaginemos que somos un banco y queremos decidir si otorgar o no un préstamo a un cliente. Tradicionalmente, esta decisión se basaba en un conjunto de reglas establecidas (edad, ingresos, historial crediticio, etc.). Sin embargo, con el aprendizaje profundo, podemos analizar una cantidad mucho mayor de datos y de una manera más compleja.

¿Cómo funciona?

A. Recopilación de datos: El banco recopila una gran cantidad de información sobre sus clientes, como:
   1. Datos demográficos (edad, sexo, ubicación).

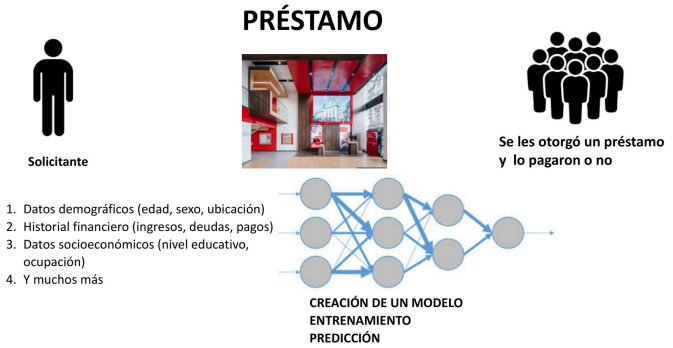


Figura 17. Ejemplo de concesión de préstamo

2. Historial financiero (ingresos, deudas, pagos).
3. Comportamiento en línea (interacciones con la app, búsquedas).
4. Datos socioeconómicos (nivel educativo, ocupación).
5. Y muchos más...

B. Creación de un modelo: Se crea un modelo de aprendizaje profundo (una red neuronal) que aprende a identificar patrones en estos datos. Estos patrones pueden ser muy complejos y difíciles de detectar por un humano.

C. Entrenamiento del modelo: El modelo se entrena con una gran cantidad de datos históricos de clientes a los que se les otorgó un préstamo y sabemos si lo pagaron o no. De esta manera, el modelo aprende a asociar ciertas características de los clientes con una mayor o menor probabilidad de impago.

D. Predicción: Una vez entrenado, el modelo puede analizar los datos de un nuevo cliente y predecir la probabilidad de que pague el préstamo.

Supongamos que el modelo identifica que los clientes con un historial de pagos puntuales en servicios públicos, un alto nivel de educación y una búsqueda frecuente de productos financieros en línea tienen una probabilidad muy baja de impago. Si un nuevo cliente cumple con estas características, el modelo recomendará otorgarle el préstamo.

Ejemplo 3: ¿será contratado un candidato? *(Figura 18)*
En este ejemplo, los datos de entrada son los años de experiencia, el nivel de inglés y el número de certificaciones de un candidato. Pero todas estas entradas no tienen la misma importancia. Cada dato se multiplica por un peso que representa su importancia (por ejemplo, las certificaciones pesan más que el inglés). Luego, todos los resultados se suman en una "neurona" y se aplica una función de activación que decide si el valor total supera un umbral. Si lo supera, la red responde **«Sí» (será contratado)**; si no, responde **«No»**. Así, la red aprende a tomar decisiones evaluando múltiples factores a la vez.

Entradas (características del candidato):

- Años de experiencia: 5
- Nivel de inglés (0 a 10): 7
- Número de certificaciones: 2

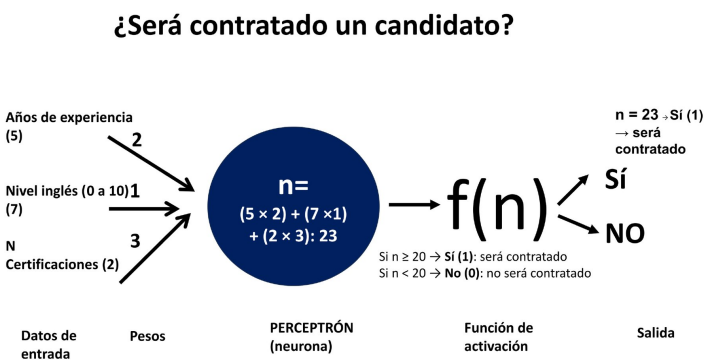


Figura 18. Ejemplo de contratación de un candidato

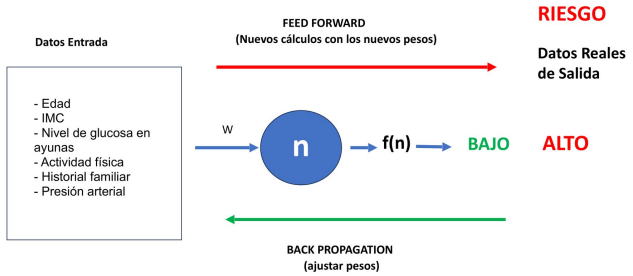


Figura 19. Red neuronal para predicción de riesgo de diabetes

Pesos asignados (importancia de cada característica):

- Experiencia × 2
- Inglés × 1
- Certificaciones × 3

Cálculo del perceptrón (n):
n = (Experiencia × 2) + (inglés × 1) + (Certificaciones × 3) n = (5 × 2) + (7 × 1) + (2 × 3)
n = 10 + 7 + 6 = 23

Función de activación:
- Si n ≥ 20 → **Sí (1)**: será contratado
- Si n < 20 → **No (0)**: no será contratado

Resultado final:
- n = 23 → **Sí (1) → El candidato es contratado**

Ejemplo 4: predicción del riesgo de diabetes *(Figura 19)*
Una red neuronal puede predecir el riesgo de diabetes tipo 2 analizando variables clínicas como:

- Edad
- IMC
- Nivel de glucosa en ayunas
- Actividad física
- Historial familiar
- Presión arterial

Cada valor se pondera con un peso aprendido y se combina en una neurona. La función de activación transforma el total en una predicción:

0 = bajo riesgo, 1 = alto riesgo.

El sistema ajusta sus pesos comparando la predicción con la realidad que conocemos basados en miles de casos registrados, mejorando con cada nuevo ejemplo analizado.

Ejemplo 5 Triaje en Urgencias *(Figura 20)*

- Datos de entrada: Se incluyen variables clínicas relevantes como signos vitales, síntomas, dolor torácico, disnea, antecedentes y edad. Estos datos son los que habitualmente recopila el personal de triaje y constituyen la base para la toma de decisiones automatizada.
- Datos de salida conocidos: Riesgo alto o bajo según la realidad previa de miles de casos
- Red Neuronal (n): Representa el nodo o neurona artificial que recibe los datos ponderados (w) y aplica una función de activación (f(n)) para generar una salida. El proceso de "feed forward" implica calcular la salida a partir de los datos y los pesos actuales de la red.
- Backpropagation: Es el mecanismo de aprendizaje supervisado mediante el cual la red ajusta sus pesos en función del error cometido, (por ejemplo, calculó inicialmente riesgo bajo cuando en base a los datos conocidos con experiencia práctica anterior introducida en el sistema a ese paciente le corresponde riesgo alto) optimizando así la precisión en la clasificación de los niveles de urgencia.
- Salida Nivel de Urgencia: La red neuronal clasifica a los pacientes en niveles de urgencia: bajo, medio o alto. Esta categorización es fundamental para priorizar la atención en situaciones de saturación y mejorar la gestión de los recursos disponibles.

2.2.2.3 Aplicaciones de Aprendizaje profundo (DL)

2.2.2.3.1 Vision artificial

La visión artificial entrena a las computadoras para «ver» y entender imágenes o videos mediante algoritmos, cámaras y datos, replicando aspectos de la visión humana. A diferencia de los humanos, que usamos retinas y el cerebro, las máquinas usan sensores (como cámaras), bases de datos y redes neuronales para procesar información visual.
Se apoya principalmente en algoritmos de aprendizaje profundo (Deep Learning), sobre todo en redes neuronales convolucionales (CNNs), que están especialmente diseñadas para identificar patrones espaciales (como bordes, formas, colores y texturas) en imágenes [5][6].

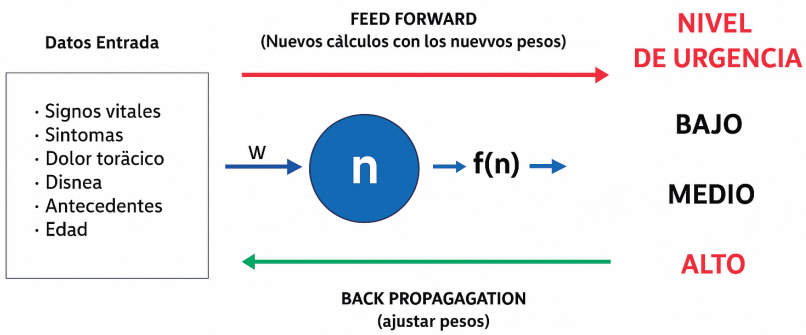


Figura 20. Red neuronal para triaje en urgencias

2.2.2.3.1.1 Pixeles

Los píxeles son la base de las imágenes digitales. Cada imagen se descompone en una cuadrícula de píxeles, que son pequeños puntos con valores numéricos (*Figura 21)* que representan:

- Intensidad de color: En imágenes en escala de grises, cada píxel tiene un valor entre 0 (negro) y 255 (blanco). En imágenes a color, los píxeles se dividen en canales RGB (rojo, verde, azul), donde cada canal tiene un valor de 0 a 255, combinándose para formar colores.
- Información espacial: Los píxeles están organizados en una matriz (por ejemplo, 1920x1080 píxeles), lo que permite a los algoritmos analizar patrones espaciales.

Como vemos la imagen se reduce a una matriz numérica donde cada píxel describe un fragmento de la imagen. Los algoritmos de visión artificial analizan estos números para identificar formas, bordes o patrones.

Cada píxel de una imagen a color se representa por tres números (RGB: rojo, verde y azul), cada uno con un valor entre 0 y 255. Estos números determinan la intensidad de cada color primario en ese píxel, y al combinarlos obtenemos la amplia gama de colores que vemos en las imágenes digitales

2.2.2.3.1.2 Fases del funcionamiento de la visión artificial (Tabla 1)

Su funcionamiento se organiza en una serie de fases secuenciales que permiten transformar una imagen en información útil para la toma de decisiones automatizadas. Estas fases comienzan con la **adquisición de la imagen** mediante cámaras o sensores, seguida del **preprocesamiento**, donde se mejora la calidad visual para facilitar el análisis. Posteriormente, se realiza la **segmentación** de la imagen en regiones relevantes, y la **extracción de características** para identificar patrones visuales significativos. A continuación, se procede a la **clasificación o reconocimiento** de objetos mediante algoritmos de aprendizaje

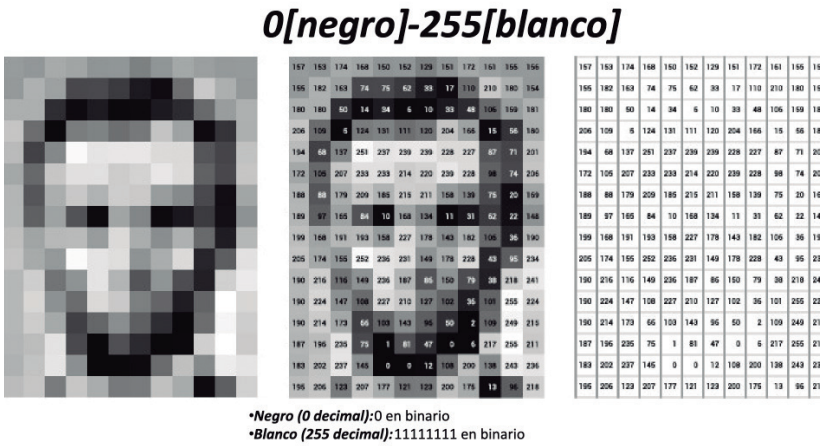


Figura 21. Matriz numérica donde cada píxel describe un fragmento de la imagen.

Tabla 1. Fases del funcionamiento de la visión artificial

FASE	DESCRIPCIÓN
1. Adquisición de imagen	Captura de imágenes mediante sensores ópticos o cámaras digitales que transforman la realidad en datos visuales.
2. Preprocesamiento	Optimización de la imagen: reducción de ruido, mejora de contraste, filtrado y normalización.
3. Segmentación	Separación de la imagen en regiones o estructuras relevantes (objetos, bordes, áreas de interés).
4. Extracción de características	Obtención de atributos como formas, colores, texturas o patrones geométricos.
5. Clasificación / Reconocimiento	Asignación de etiquetas o categorías a los elementos detectados mediante Machine Learning o redes neuronales profundas.
6. Interpretación / Decisión	Análisis contextual para diagnóstico, predicción o control de procesos (ej.: detección de tumores, control de calidad).
7. Retroalimentación / Acción	En sistemas autónomos, ejecución de la respuesta adecuada (ej.: mover un robot, emitir una alerta, ajustar parámetros).

automático. La fase de **interpretación o decisión** analiza los datos visuales en su contexto para generar una respuesta adecuada, que finalmente puede traducirse en una **acción automatizada** si el sistema lo requiere. Esta secuencia es clave para aplicaciones en medicina, robótica, industria y vehículos autónomos, entre otros campos.

2.2.2.3.1.3. Aplicación de la visión artificial en Medicina

La IA está transformando el análisis de imágenes médicas. Gracias a técnicas como el aprendizaje profundo, hoy es posible automatizar la detección de alteraciones en estudios como ecografías, tomografías y biopsias digitalizadas. Estas herramientas no solo aumentan la precisión diagnóstica, sino que también reducen el tiempo de interpretación y facilitan la identificación de patrones sutiles que pueden pasar desapercibidos al ojo humano. La IA representa, así, un aliado prometedor para los médicos, con el potencial de mejorar el seguimiento clínico, optimizar recursos y ofrecer una medicina más personalizada [1]. Un ejemplo puede ser:

Detección de melanoma cutáneo con visión artificial

1. Se toman miles de fotos de lunares benignos y malignos ya clasificados por dermatólogos.
2. Se entrena una red neuronal convolucional con estas imágenes.
3. El sistema aprende a distinguir características sutiles: forma irregular, bordes borrosos, variación de color.
4. Cuando se le da una imagen nueva, el sistema compara y predice si se parece más a un melanoma o no.
5. Resultado *"Probabilidad de melanoma: 87% – Requiere derivación a dermatología urgente"*.

Este tipo de sistemas, entrenados adecuadamente, han demostrado en algunos estudios igualar o superar la precisión de dermatólogos humanos en la detección temprana de cáncer de piel [7].

Detección de neumonía con IA en un departamento de urgencias [8]
En la (Tabla 2) podemos ver el flujo diagnóstico de detección de neumonía.

2.2.2.3.2 Procesamiento del lenguaje natural (PLN)

El Procesamiento del Lenguaje Natural (PLN), o Natural Language Processing (NLP), es una rama de la inteligencia artificial que permite a las máquinas comprender, interpretar, generar y responder al lenguaje humano, ya sea en formato oral o escrito [9] A diferencia de entradas más estructuradas como imágenes o datos numéricos, el lenguaje humano es inherentemente complejo debido a su ambigüedad, contexto, emociones, errores gramaticales y matices culturales. El PLN busca que los sistemas informáticos procesen este tipo de información de manera similar a como lo hace un ser humano, pero claro existen limitaciones por ejemplo en la interpretación de contextos altamente subjetivos o especiales de culturas diferentes.

Tabla 2. Detección de neumonía con IA en un departamento de urgencias

ETAPA	DESCRIPCIÓN
1. Adquisición de la imagen	Al paciente con síntomas respiratorios se le realiza una radiografía de tórax, que es el método de imagen de primera línea en urgencias para evaluar anormalidades pulmonares.
2. Análisis automatizado	La imagen se introduce en un sistema de IA entrenado previamente con miles de radiografías de tórax de pacientes con y sin neumonía. Estos sistemas suelen estar basados en redes neuronales convolucionales (CNN), capaces de identificar patrones y características sutiles en las imágenes que pueden pasar desapercibidos al ojo humano.
3. Procesamiento y predicción	El algoritmo analiza la radiografía, detectando signos típicos de neumonía (infiltrados, consolidaciones, distribución de las lesiones, etc.). El sistema compara la imagen nueva con los patrones aprendidos y calcula la probabilidad de que exista neumonía, e incluso puede sugerir la severidad o el tipo (viral o bacteriana).
4. Resultado inmediato	En cuestión de segundos, el sistema emite un informe automático, por ejemplo: "Probabilidad de neumonía: 92%. Hallazgos compatibles con neumonía en lóbulo inferior derecho. Requiere valoración clínica y tratamiento antibiótico urgente."
5. Apoyo a la decisión médica	El resultado se presenta al médico de urgencias, quien lo utiliza como apoyo para tomar decisiones rápidas sobre el tratamiento, la necesidad de aislamiento, ingreso hospitalario o realización de pruebas adicionales.

2.2.2.3.2.1 Funcionamiento del PLN

El PLN se basa en múltiples niveles de análisis lingüístico y etapas técnicas que permiten descomponer y procesar el lenguaje humano de manera sistemática. Estas etapas y niveles se detallan en las (*Tabla 3*) y (*Tabla 4*).

Tareas del PLN

El PLN abarca una amplia variedad de tareas que permiten a los sistemas interpretar, generar y analizar lenguaje humano. Estas tareas tienen aplicaciones prácticas en diversos sectores, desde el comercio hasta la medicina (*Tabla 5*).

Tabla 3. Niveles de análisis lingüístico en PLN

NIVEL DE ANÁLISIS	DESCRIPCIÓN
Análisis morfológico	Descompone palabras en morfemas para identificar raíces y afijos.
Análisis sintáctico	Reconoce la estructura gramatical de las oraciones.
Análisis semántico	Interpreta el significado contextual, resolviendo ambigüedades léxicas.
Análisis pragmático	Considera el contexto para interpretar ironía, metáforas o intenciones.

Tabla 4. Procesamiento técnico en PLN

ETAPA	DESCRIPCIÓN BREVE
Tokenización	Divide el texto en unidades básicas: palabras, frases o subunidades léxicas.
Lematización / Stemming	Reduce las palabras a su forma base o raíz (por ejemplo, "corriendo" → "correr").
Etiquetado gramatical	Asigna a cada palabra su categoría gramatical (sustantivo, verbo, adjetivo...).
Análisis sintáctico	Identifica la estructura gramatical de las oraciones (sujeto, predicado, etc.).
Análisis semántico	Interpreta el significado contextual de las palabras y oraciones.

Tabla 5. Tipos de tareas del PLN

TAREA	EJEMPLO DE APLICACIÓN
Clasificación de texto	Filtrado automático de correos electrónicos como spam o no spam.
Análisis de sentimientos	Monitorizar opiniones de usuarios sobre productos en redes sociales.
Reconocimiento de entidades	Detectar nombres de empresas o ubicaciones en noticias financieras.
Resumen automático	Resumir artículos de prensa para plataformas de noticias.
Generación de texto	Redactar descripciones automáticas de productos en tiendas en línea.
Traducción automática	Traducir manuales técnicos entre diferentes idiomas.
Chatbots	Asistentes virtuales para atención al cliente en sitios web de e-commerce.

En resumen, el funcionamiento del PLN se basa en los siguientes pasos:

Preentrenamiento: Antes de ser utilizado en conversaciones en tiempo real, el modelo es entrenado en grandes cantidades de texto de diferentes fuentes, como libros, artículos y sitios web. Durante este proceso, el modelo aprende a entender el lenguaje y a predecir la siguiente palabra en una oración dada su comprensión del contexto.

Procesamiento del texto de entrada: Cuando proporcionas una consulta o una pregunta, el modelo analiza y procesa cada palabra y su relación con las palabras circundantes. Utiliza técnicas avanzadas de procesamiento del lenguaje natural para comprender la semántica y el contexto de la consulta.

Generación de respuesta: Después de comprender la entrada, el modelo utiliza su conocimiento previo para predecir y generar una respuesta coherente y relevante. La respuesta se forma en función de patrones y estructuras lingüísticas aprendidas durante el entrenamiento, y el modelo intenta generar una respuesta que sea apropiada y contextualmente relevante.

Optimización del texto de salida: Antes de proporcionar la respuesta final, el modelo verifica y ajusta la coherencia y la gramática de la respuesta generada. Esto implica asegurarse de que la respuesta sea lógica, coherente y esté bien redactada.

Entrega de la respuesta: Finalmente, el modelo proporciona la respuesta generada en función de la entrada original, intentando proporcionar una solución completa y comprensible.

2.2.2.3.2.2 Herramientas comerciales de PLN (julio 2025)

El ecosistema del PLN en julio de 2025 está dominado por herramientas comerciales avanzadas que integran capacidades multimodales, búsqueda inteligente y automatización de tareas (*Tabla 6*).

Tabla 6. Herramientas comerciales de PLN (julio 2025)

HERRAMIENTA	DESCRIPCIÓN BREVE
ChatGPT 5 / GPT-4o (OpenAI)	Asistente multimodal con razonamiento "Strawberry", navegación web autónoma ("Deep Research"), grabación y resumen de reuniones, integración de APIs y agentes ("Operator").
OpenAI Operator	Agente autónomo que completa formularios, pedidos online y gestiona citas.
OpenAI Deep Research (DeepSearch)	Agente de investigación que busca, lee y sintetiza múltiples fuentes online, entregando informes con citas.
Microsoft 365 Copilot / Copilot Vision	Integrado en Windows 11/365/Teams/Office; permite transcribir, generar contenido, interpretar pantallas ("Vision"), automatizar acciones web ("Copilot Actions") y personalizar agentes ("Copilot Tuning").
GitHub Copilot	Autocompletado y generación de código en IDEs, compatible con múltiples LLMs como GPT, Claude, Gemini y LLaMA.
Google Gemini	Asistente de búsqueda y codificación, incluido en "AI Mode" de Search; también ofrece capacidades de investigación profunda.
Perplexity AI / Perplexity Deep Research	Motor conversacional que procesa y sintetiza docenas de fuentes web en informes autónomos con citas.
Grok 3 (xAI)	Chatbot en X/Twitter con razonamiento avanzado ("Think", "Big Brain"), tono informal, y motor "DeepSearch" para investigación.
Anthropic Claude 4	Modelos "Opus 4" y "Sonnet 4" diseñados para diálogos extensos, con enfoque en razonamiento ético y uso empresarial.
Meta LLaMA 3/4	Modelos open-source utilizados en investigación, desarrollo y aplicaciones personalizadas.
IBM Deep Search	Plataforma empresarial para búsqueda semántica en grandes colecciones (PDFs, multimedia), que convierte documentos en JSON y crea entornos de búsqueda semántica.

2.2.2.3.2.3 Ejemplo de Aplicación de PLN: Detección de Testimonios Verdaderos o Falsos en declaraciones policiales

En el ámbito judicial, el procesamiento del lenguaje natural (PLN) se está utilizando como herramienta de apoyo para analizar declaraciones de testigos y acusados, con el fin de identificar posibles indicios de veracidad o falsedad. Durante un juicio por fraude financiero, los investigadores recopilan las transcripciones de los interrogatorios de varios implicados. Un sistema basado en PLN analiza estas declaraciones en busca de patrones lingüísticos que históricamente se han asociado con el engaño o la verdad.

1. Análisis lingüístico: El sistema analiza elementos como la longitud de las respuestas, el uso de evasivas, contradicciones gramaticales, cambios repentinos de tiempo verbal, exceso de detalles irrelevantes o el uso repetido de negaciones («yo no hice nada», «nunca supe nada»).
2. Modelos entrenados en patrones de engaño: Se utilizan modelos entrenados previamente con corpus de declaraciones clasificadas como verdaderas o falsas (por ejemplo, estudios psicológicos, bases de datos forenses). Estos modelos aprenden a reconocer señales sutiles en el lenguaje que podrían ser indicadores de mentira.
3. Análisis de sentimientos y emociones: El sistema también evalúa la carga emocional del discurso. Por ejemplo, un testigo que muestra emociones inconsistentes con la situación descrita (frialdad al relatar un crimen violento) puede despertar sospechas.
4. Detección de entidades y hechos clave: El modelo extrae nombres, fechas y lugares, y compara estos datos con otras evidencias del caso (como registros telefónicos o cámaras de seguridad), para detectar posibles incongruencias.

Un estudio reciente presenta un dataset específico para analizar declaraciones dadas durante entrevistas policiales. Utiliza un modelo basado en DistilBERT, entrenado para distinguir declaraciones verdaderas de falsas, logrando una precisión del 86 % [10]. El PLN no sustituye al juez ni al perito, pero entrega un informe con indicadores de posible engaño, lo que permite enfocar mejor las preguntas y cruzar los datos más críticos. Esto mejora la eficiencia y calidad del proceso judicial.

2.2.2.3.2.4 Ejemplo de aplicación del PLN en medicina de urgencias

En el contexto de la medicina de urgencias, el PLN tiene un potencial transformador al procesar grandes volúmenes de datos no estructurados, como notas clínicas, informes de triaje o registros de pacientes, para mejorar la toma de decisiones y optimizar los flujos de trabajo. Un ejemplo concreto es el uso del PLN para la clasificación automática de la gravedad en el triaje de urgencias.

Imaginemos un hospital que recibe a un paciente con dolor torácico. El médico registra una nota clínica inicial: "Paciente de 55 años, dolor torácico opresivo de inicio súbito, acompañado de disnea y sudoración". Un sistema basado en PLN, como los integrados en herramientas como Chat GPT, Microsoft 365 Copilot, Gemini, Grok 3…etc puede procesar esta nota en tiempo real mediante las siguientes etapas:

- Tokenización y lematización: El sistema descompone la nota en palabras clave como "dolor torácico", "opresivo", "súbito", "disnea" y "diaforesis".
- Etiquetado gramatical y análisis sintáctico: Identifica que "dolor torácico" es el sujeto principal y que términos como "opresivo" y "súbito" son descriptores clave.
- Análisis semántico y reconocimiento de entidades: Reconoce que "dolor torácico opresivo" y "disnea" son síntomas asociados con condiciones graves como el infarto de miocardio.
- Clasificación de texto: Utilizando modelos entrenados, el sistema clasifica la nota como de alta prioridad, sugiriendo un triaje de nivel 1 o 2 según escalas como el Sistema de Triaje de Emergencia (ETS).
- Generación de texto: El sistema puede generar una alerta automática para el equipo médico, como: "Paciente con posible evento cardiovascular agudo, requiere evaluación inmediata".

Este proceso, que combina varias tareas del PLN (clasificación de texto, reconocimiento de entidades y generación de texto), permite priorizar casos críticos en segundos, reduciendo

el tiempo de respuesta en un entorno de alta presión como las urgencias. Estudios han demostrado que el uso de PLN en triaje puede mejorar la precisión en la clasificación de pacientes hasta en un 20% en comparación con métodos manuales [11].

2.2.2.3.2.5 Aplicaciones potenciales en el día a día del uso de PLN en Medicina

El PLN tiene varias aplicaciones potenciales en el día a día de un médico, que pueden ayudar en la toma de decisiones clínicas, la educación de los pacientes y la gestión de la carga de trabajo. Algunos ejemplos de casos de uso de utilización son:

1. **Asistencia en la toma de decisiones clínicas**:
   - Diagnóstico diferencial: Un médico puede utilizar el chat GPT para generar una lista inicial de posibles diagnósticos en función de los síntomas y la historia clínica proporcionada por el paciente.
   - Revisión de literatura: El médico puede solicitar al chat GPT que resuma los últimos estudios médicos relevantes sobre un tema específico para estar al día con las últimas investigaciones.
     Ejemplo: «¿Cuáles son las últimas investigaciones sobre el tratamiento de la diabetes tipo 2?»
2. **Educación de pacientes:**
   - Explicación de condiciones médicas: El médico puede generar descripciones fáciles de entender sobre condiciones médicas, procedimientos o tratamientos para compartir con los pacientes.
     Ejemplo: «Explícame en términos sencillos qué es la hipertensión y cómo puedo controlarla.»
   - Consejos de salud: Proporcionar recomendaciones generales sobre la dieta, el ejercicio y el estilo de vida saludable.
     Ejemplo: «¿Cuáles son algunos consejos para mantener un corazón saludable?»
3. **Documentación médica y notas clínicas:**
   - Transcripción de notas clínicas: El chat GPT puede ayudar a los médicos a transcribir notas clínicas dictadas durante las consultas.
     Ejemplo: «Por favor, transcribe las notas de la consulta de hoy con el paciente X.»
4. **Resolución de dudas rápidas:**
   - Respuestas a preguntas frecuentes: Los médicos pueden utilizar el PLN para obtener respuestas rápidas a preguntas comunes sobre medicamentos, dosis recomendadas, interacciones medicamentosas, etc.
     Ejemplo: «¿Cuál es la dosis recomendada de ibuprofeno para un adulto?»
5. **Planificación de la atención al paciente:**
   - Generación de planes de tratamiento preliminares: Ayuda en la creación de planes de tratamiento iniciales antes de la consulta con el paciente.
     Ejemplo: «Crea un plan de tratamiento inicial para un paciente con diabetes tipo 1 recién diagnosticado.»
6. **Investigación clínica:**
   - Análisis de datos médicos: El PLN puede ayudar a analizar datos clínicos, identificar tendencias y generar informes preliminares [12]
     Ejemplo: «Analiza los datos de los pacientes en el último ensayo clínico y resalta las tendencias más relevantes».
7. **Gestión del tiempo:**
   - Gestión de citas y recordatorios: El chat GPT puede ayudar a programar citas, enviar recordatorios a pacientes y gestionar la agenda del médico.
     Ejemplo: «Programa una cita con el paciente Y para la próxima semana y envía un recordatorio.

2.2.2.3.3 Inteligencia artificial multimodal

Es un tipo de inteligencia artificial generativa capaz de procesar y combinar diferentes tipos de datos, como texto, imágenes, audio y video, para generar respuestas más completas y sofisticadas. A diferencia de los modelos tradicionales, que se enfocan en un solo tipo de entrada (por ejemplo, solo texto o solo imágenes), los modelos multimodales integran múltiples fuentes de información para mejorar su comprensión y generación de contenido (*Figura 22*).



Figura 22. IA generativa multimodal

Las ventajas de la IA multimodal son que puede interpretar imágenes y texto al mismo tiempo, y permite la comunicación con texto, voz e imágenes. La IA multimodal representa un gran avance en la inteligencia artificial, ya que permite una comprensión más parecida a la humana de la información. En la Tabla 6 pueden verse algunos ejemplos de IA multimodal.

Aplicaciones de la IA multimodal

Con la IA multimodal se abre un amplio abanico de posibilidades en sectores como el de la salud, la automoción, la educación o en cuestiones como la accesibilidad. A continuación, desgranamos algunas de sus aplicaciones en estos ámbitos:

- Asistencia sanitaria: Permitirá mejorar el diagnóstico y ajustar el tratamiento de cada paciente, a través de la combinación de diferentes datos como imágenes médicas, el historial del paciente o los proporcionados por sensores médicos portátiles (ritmo cardiaco, presión arterial, glucosa, etc.).
- Automoción: Potenciará la seguridad vial mediante la fusión de datos procedentes de cámaras o radares.
- Educación: Analizará textos, vídeos de impartición de clases y exámenes para adaptar los contenidos y hacerlos más atractivos para el alumnado, ofreciendo una experiencia pedagógica personalizada en las aulas.
- Accesibilidad: Permitirá tener una comunicación más natural con la tecnología a las personas con discapacidad, por ejemplo, mediante la traducción del lenguaje oral al escrito o la manipulación de imágenes y vídeos a través de instrucciones habladas, lo que supondrá un gran avance para este colectivo.

2.2.3 Ética y peligros de la utilización de PLN en Medicina

En general, el uso de PLN en Medicina ofrece muchas oportunidades emocionantes, pero también plantea importantes desafíos éticos y de seguridad [13]. Es importante abordar estos desafíos de manera proactiva para garantizar que el uso de ChatGPT en la atención médica sea seguro, justo y beneficioso para los pacientes.

Preguntando a ChatGPT3 [14] cuales son en su consideración esos peligros nos resume así:

1. Privacidad y seguridad de los datos: El uso de ChatGPT en Medicina puede involucrar el manejo de información médica sensible, como historiales médicos, registros de diagnóstico y otras formas de datos de salud privados. Es crucial garantizar que esta información esté protegida adecuadamente y que se cumplan los estándares de privacidad y seguridad de los datos.
2. Sesgo y discriminación: Como modelo entrenado en grandes cantidades de datos, ChatGPT puede reflejar y amplificar los prejuicios y estereotipos presentes en los datos de entrenamiento. Esto puede llevar a respuestas inexactas, incompletas o incluso perjudiciales para ciertos grupos de pacientes. Es importante garantizar que ChatGPT sea entrenado y utilizado de manera justa y equitativa, sin perpetuar o amplificar la discriminación existente.
3. Responsabilidad y responsabilidad legal: Cuando se usa ChatGPT en el diagnóstico o tratamiento de pacientes, es importante que los médicos y otros profesionales de la salud sean responsables de las decisiones y acciones que toman en función de la información proporcionada por el modelo. Esto puede plantear cuestiones legales y de responsabilidad en caso de que las decisiones médicas resulten en daño o perjuicio para los pacientes.
4. Confianza y comprensión: Los pacientes pueden confiar demasiado en las respuestas proporcionadas por ChatGPT, sin comprender completamente la base de las recomendaciones y el proceso de toma de decisiones detrás de ellas. Es importante garantizar que los pacientes comprendan adecuadamente la información proporcionada por ChatGPT y que se fomente una relación sólida y clara entre el paciente y el médico.
5. Falta de regulación y estándares claros también es una preocupación importante en relación con el uso de ChatGPT en medicina. En muchos casos, no hay pautas o regulaciones específicas que se apliquen al uso de modelos de lenguaje en la atención médica, lo que puede dar lugar a prácticas inconsistentes y potencialmente peligrosas.

La falta de regulación también puede dificultar la evaluación y comparación de diferentes modelos de lenguaje, lo que hace difícil determinar cuáles son los modelos más precisos, confiables y seguros para su uso en la atención médica. Además, los estándares y regulaciones claros también son importantes para garantizar que los modelos de lenguaje se desarrollen y utilicen de manera ética y responsable.
Por lo tanto, es importante que los reguladores y las autoridades de salud trabajen para establecer pautas claras y estándares de calidad para el uso de modelos de lenguaje en la atención médica. Esto puede incluir el establecimiento de estándares para la recopilación y uso de datos, la evaluación de la precisión y seguridad de los modelos de lenguaje, y la implementación de prácticas y políticas éticas para garantizar que los modelos se utilicen de manera justa y equitativa.

2.3 PLATAFORMAS Y WEBS ESPECIALIZADAS EN IA MÉDICA

En los últimos años, el escenario de la Inteligencia Artificial Médica ha crecido exponencialmente, abarcando desde el análisis de imágenes y la documentación clínica automatizada, hasta la investigación farmacéutica y la personalización de tratamientos. A continuación, se presenta una tabla con una selección de plataformas y webs especializadas en IA médica. Estas herramientas ilustran la diversidad de enfoques actuales —clínicos, operativos, de investigación y tecnológicos— que impulsan la transformación digital en la práctica sanitaria (Tabla 7).

Tabla 7. Algunas plataformas y webs especializadas en IA médica

PLATAFORMA / WEB	ÁREA PRINCIPAL	DESCRIPCIÓN	TIPO DE USUARIO	SITIO WEB
Aidoc	Radiología / Urgencias	Algoritmos de detección automática en TAC y RM para priorizar casos críticos.	Hospitales, radiólogos	https://www.aidoc.com
Viz.ai	Neurología / Cardiología	Identificación precoz de ictus y eventos cardiovasculares mediante IA.	Servicios de urgencias	https://www.viz.ai
Tempus	Oncología	Análisis multimodal de datos clínicos y genómicos para personalizar tratamientos.	Oncólogos, investigadores	https://www.tempus.com
PathAI	Anatomía patológica	Apoyo diagnóstico en histopatología digital mediante deep learning.	Patólogos, farmacéuticas	https://www.pathai.com
Arterys	Imagen médica	Plataforma cloud para análisis automatizado de imágenes cardíacas y pulmonares.	Radiólogos, hospitales	https://www.arterys.com
Nanox AI (ex Zebra)	Radiología poblacional	Cribado automatizado de enfermedades a partir de imágenes.	Sistemas sanitarios	https://www.nanox.vision
Merative (ex IBM Watson Health)	Gestión clínica / datos	Analítica clínica y soporte a la decisión basado en big data sanitario.	Gestores, clínicos	https://www.merative.com
DeepMind Health	Investigación clínica	Desarrollo de modelos predictivos para nefrología, oftalmología y UCI.	Investigadores, hospitales	https://deepmind.google/health

Referencias

1 De Francisco ALM. Artificial. La Nueva Inteligencia y su Aplicación en Nefrología. En Lorenzo V, López Gómez JM (Eds). Nefrología al Día. ISBN 978-84-127624-1-9.

2 De Francisco ALM Medicina Renal Inteligente. El futuro de la nefrología clínica con inteligencia artificial En Lorenzo V, López Gómez JM (Eds) Nefrología al Día ISBN 978-84-129769-3-9

3 Joyanes Aguilar L. *Fundamentos de programación: algoritmos, estructura de datos y objetos*. 4.ª ed. México: McGraw-Hill; 2016. Accesible en: https://combomix.net/wp-content/uploads/2017/03/Fundamentos-de-programaci%C3%B3n-4ta-Edici%C3%B3n-Luis-Joyanes-Aguilar-2.pdf

4 KeepCoding. 5 mejores IA para programar en Python que tienes que probar [Internet]. 2025 disponible en: https://keepcoding.io/blog/mejores-ia-para-programar-en-python/.

5 Szeliski R. *Computer Vision: Algorithms and Applications* [Internet]. 2nd ed. Cham: Springer; 2022 Disponible en: http://szeliski.org/Book

6 Goodfellow I, Bengio Y, Courville A. *Deep Learning* [Internet]. Cambridge, MA: MIT Press; 2016 [citado 2025 Jun 27]. Disponible en: https://www.deeplearningbook.org

7 Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, Thrun S. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017 Feb 2;542(7639):115-8. doi:10.1038/nature21056.

8 Rajpurkar P, Irvin J, Zhu K, Yang B, Mehta H, Duan T, et al. CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning. *arXiv* [preprint]. 2017 Disponible en: https://arxiv.org/abs/1711.05225

9 Chowdhury GG. Natural language processing. *Annu Rev Inf Sci Technol*. 2003;37(1):51-89. DOI:10.1002/aris.1440370103.

10 Spyridis Y, Younes JP, Deeb H, Argyriou V. Empowering prior to court legal analysis: A transparent and accessible dataset for defensive statement classification and interpretation. *arXiv* [Preprint]. 2024 May 17 [cited 2025 Aug 10]; Available from: arXiv:2405.10702

11 Levin S, Toerper M, Hamrock E, Hinson JS, Barnes S, Gardner H, et al. Machine-learning-based electronic triaje more accurately differentiates patients with respect to clinical outcomes compared with the emergency severity index. *Ann Emerg Med*. 2018;71(5):565-74. DOI:10.1016/j.annemergmed.2017.08.005.

12 Van Dis EAM, Bollen J, van Rooij R, Zuidema W, Bockting CL. ChatGPT: five priorities for research. *Nature*. 2023 Feb 9;614(7947):224-6. DOI:10.1038/d41586-023-00288-7.

13 Fernandes AC, Souto MEVC. Benefits, limits, and risks of GPT-4 as an AI chatbot for medicine. *N Engl J Med*. 2023 Jun 22;388(25):2399-400. DOI:10.1056/NEJMp2303819.

14 OpenAI. ChatGPT: desafíos éticos y de seguridad del ChatGPT-3 [Internet]. San Francisco (CA): OpenAI; [cited 2025 Aug 8]. Available from: https://chat.openai.com/

3.

OBJETIVOS GENERALES. IA EN MEDICINA DE URGENCIAS

Según datos globales, los servicios de urgencias hospitalarias atienden millones de pacientes anualmente (OCDE: ≈ 27 visitas/100 habitantes, con > 50 en España/Portugal) y solo en EE. UU. se registraron 155,4 millones de visitas en 2022 [1][2][3]. La presión sobre estos departamentos ha aumentado debido al envejecimiento de la población —reflejado en el uso creciente por parte de ancianos próximos al fallecimiento—, el incremento de enfermedades crónicas y multimorbilidad, especialmente en grupos vulnerables, así como por eventos como pandemias que han modificado tanto la frecuencia como el perfil de las visitas [4]. En este contexto, la IA puede ofrecer soluciones innovadoras para abordar tres desafíos clave: la priorización eficiente de pacientes, la mejora en la precisión diagnóstica y la optimización de recursos limitados.

La importancia de la IA radica en que puede procesar grandes volúmenes de datos en tiempo real, identificar patrones que podrían pasar desapercibidos al ojo humano y proporcionar recomendaciones basadas en evidencia. Por ejemplo, un sistema de IA puede analizar signos vitales, historiales clínicos y notas de ingreso en segundos, clasificando a los pacientes según su riesgo [5]. Un modelo de Deep Learning puede analizar una radiografía torácica y detectar signos de neumonía en menos de un minuto [6], mientras que un sistema de procesamiento de lenguaje natural (PLN) puede extraer información clave de las notas clínicas dictadas por un médico [7].

Esto no solo reduce el tiempo de espera para los casos críticos, sino que también alivia la carga administrativa sobre el personal médico, permitiéndoles enfocarse en la atención directa al paciente. En un entorno donde el error humano puede tener consecuencias fatales, la IA actúa como un soporte que complementa el juicio clínico, reduciendo la variabilidad interprofesional y las equivocaciones humanas. Además, la IA tiene un impacto directo en los resultados clínicos. Estudios recientes han demostrado que los sistemas de triaje asistido por IA pueden reducir los tiempos de atención en un 30-40% [8] Estos avances subrayan por qué la IA no es solo una moda tecnológica, sino una herramienta indispensable para transformar los servicios de urgencias en un entorno más eficaz y amable

La IA en urgencias no se limita a tareas técnicas; su diseño está orientado a integrarse en los flujos de trabajo clínicos existentes, desde el triaje inicial hasta la gestión de recursos en picos de demanda. Estas herramientas están entrenadas con grandes conjuntos de datos clínicos —como historias electrónicas, resultados de laboratorio y estudios de imagen— que les permiten «aprender» a identificar riesgos, priorizar pacientes y sugerir diagnósticos diferenciales. Sin embargo,

a diferencia de los sistemas automatizados tradicionales, la IA no sigue reglas predefinidas; su capacidad de aprendizaje continuo le permite adaptarse a nuevos datos y contextos, lo que la hace especialmente valiosa en un entorno dinámico como las urgencias [9].

3.1 URGENCIAS: UN ESCENARIO PERFECTO PARA LA IA

Los servicios de urgencias son un terreno fértil para la IA debido a tres características únicas: rapidez, complejidad y necesidad de precisión. En primer lugar, **la rapidez es crítica** en urgencias, donde un diagnóstico tardío puede ser fatal. La IA puede procesar datos en tiempo real, proporcionando alertas inmediatas sobre condiciones como sepsis o embolia pulmonar, lo que permite al equipo médico actuar antes de que la situación del paciente se deteriore. Por ejemplo, un estudio publicado en 2025 demostró que un algoritmo predictivo basado en Machine Learning redujo la incidencia de fallo multiorgánico en pacientes con sepsis en un 35% al identificar riesgos tempranos en urgencias [10].

En segundo lugar, **la complejidad de los casos** en urgencias —donde los pacientes presentan síntomas inespecíficos o múltiples comorbilidades— requiere un análisis multidimensional que la IA puede manejar con eficacia. Mientras que un médico podría tardar minutos en correlacionar signos vitales, antecedentes médicos y resultados de laboratorio, un sistema de IA puede integrar estas variables en segundos y sugerir diagnósticos probables con un alto grado de precisión [11]. Por ejemplo, un estudio prospectivo en Corea (marzo 2022–octubre 2023) confirmó que los sistemas de IA integrados con ECG pueden identificar infarto con rapidez y precisión, optimizando la atención inicial en urgencias [12].

Finalmente, la **necesidad de precisión** en urgencias es innegociable. Los errores diagnósticos, que representan hasta el 10% de los casos en urgencias según algunos estudios, pueden tener consecuencias devastadoras [13]. La IA reduce estos errores al complementar el razonamiento clínico con análisis basados en datos. Por ejemplo, las redes neuronales convolucionales utilizadas en el análisis de imágenes radiológicas han mostrado una sensibilidad del 86% en la detección de microhemorragias cerebrales, superando el 70% de los radiólogos junior en un metanálisis reciente [14]. Esta capacidad no solo mejora los resultados clínicos, sino que también aumenta la confianza del equipo médico en entornos de alta presión.

3.2 OBJETIVOS DE LA IA EN UN DEPARTAMENTO DE URGENCIAS

El presente libro tiene como propósito principal examinar la evolución desde la práctica clínica tradicional (intuición clínica y experiencia acumulada del profesional sanitario) hacia un modelo asistencial donde los algoritmos inteligentes se incorporan como aliados en la toma de decisiones médicas en los servicios de urgencias. A través de un recorrido estructurado que abarca conocimientos básicos de la IA, conceptos teóricos, ejemplos clínicos reales y reflexiones éticas, se busca proporcionar a los profesionales una guía útil para comprender, aplicar y liderar la transformación digital en su entorno asistencial.

No se pretende sustituir el juicio clínico humano, sino fortalecerlo, combinando la capacidad analítica de los sistemas de inteligencia artificial con la empatía, la intuición y la capacidad de discernimiento del médico. Este enfoque tiene como finalidad mejorar la calidad del cuidado, agilizar los procesos diagnósticos

y reducir los errores médicos, en un contexto donde el tiempo es un recurso crítico.
Asimismo, se abordan los principales obstáculos para una adopción efectiva de la IA, tales como la necesidad de disponer de datos fiables, la validación de modelos algorítmicos en escenarios reales, los desafíos relacionados con la transparencia de los sistemas (especialmente en los algoritmos de tipo «caja negra») y las cuestiones ético-legales derivadas de su uso. El libro ofrece recomendaciones para integrar la IA en los circuitos asistenciales sin comprometer la calidad del acto médico.
En la (Figura 1) pueden verse los objetivos de la IA en Urgencias y en las tablas 1-5 se reproducen más desarrollados.



Figura 1. Objetivos de la IA en Urgencias

Tabla de Objetivos de Aplicación de IA en Urgencias

Tabla 1. Objetivos Clínicos de la IA en Urgencias

OBJETIVO ESPECÍFICO	ACCIONES ASISTIDAS POR IA
Mejorar el triaje inicial	Clasificación automática de pacientes por gravedad mediante algoritmos. Priorización basada en signos vitales, historia clínica y motivos de consulta.
Asistencia en el diagnóstico	Identificación de patrones en síntomas, analíticas e imágenes. Detección temprana de condiciones críticas (infarto, sepsis, ACV, etc.).
Recomendaciones terapéuticas	Apoyo en la elección de tratamientos y dosis. Alertas sobre interacciones medicamentosas o alergias.
Seguimiento en tiempo real	Monitoreo continuo de parámetros vitales. Generación de alertas predictivas ante descompensaciones.

Tabla 2. Objetivos Operativos y Logísticos

OBJETIVO ESPECÍFICO	ACCIONES ASISTIDAS POR IA
Optimización del flujo de pacientes	Predicción de tiempos de espera. Gestión dinámica de camas y recursos.
Reducción del tiempo de atención	Automatización de tareas repetitivas (historia clínica, ingreso de datos). Asistencia en la generación de informes clínicos.
Asignación inteligente de personal	Análisis predictivo de picos de demanda. Planificación de turnos en función de la carga asistencial esperada.

Tabla 3. Objetivos de Gestión y Toma de Decisiones

OBJETIVO ESPECÍFICO	ACCIONES ASISTIDAS POR IA
Soporte en decisiones administrativas	Evaluación del rendimiento del servicio en tiempo real. Identificación de cuellos de botella y propuestas automáticas de mejora.
Análisis de datos para mejora continua	Detección de patrones de reingresos o errores clínicos. Informes periódicos sobre indicadores de calidad y seguridad.

Tabla 4. Objetivos de Seguridad del Paciente

OBJETIVO ESPECÍFICO	ACCIONES ASISTIDAS POR IA
Prevención de errores médicos	Verificación automatizada de procedimientos. Alertas ante discrepancias en el historial clínico.
Mejor control de infecciones	Identificación de brotes en tiempo real. Recomendaciones sobre aislamiento y tratamiento.

Tabla 5. Objetivos Educativos y Formativos

OBJETIVO ESPECÍFICO	ACCIONES ASISTIDAS POR IA
Apoyo al aprendizaje clínico	Simulación de casos clínicos reales mediante IA. Retroalimentación personalizada para residentes y estudiantes.
Evaluación continua del desempeño	Análisis de decisiones clínicas y su comparación con patrones óptimos. Recomendaciones de mejora basadas en IA.

En este sentido, el libro no se limita a ser una revisión técnica, sino que busca convertirse en una herramienta educativa y motivadora para los profesionales que desean participar activamente en el cambio. En un contexto donde la demanda asistencial crece, los recursos humanos escasean y los costes se elevan, la digitalización inteligente de los servicios de urgencias se presenta como una solución impostergable.

Por tanto, esta obra se ubica en la confluencia entre ciencia médica, tecnología avanzada y humanismo clínico. Su mensaje es firme: la IA no viene a desplazar al médico, sino a brindarle nuevas capacidades que permitan ofrecer una atención más rápida, personalizada y segura. Invitamos al lector a explorar este nuevo paradigma en el que el conocimiento clínico y la inteligencia artificial convergen en beneficio del paciente.

Referencias

1 OECD. Health at a Glance 2023: OECD Indicators. Paris: OECD Publishing; 2023. accesible en: https://www.oecd.org/en/publications/2023/11/health-at-a-glance-2023_e04f8239/full-report/hospital-activity_7a57d1e4.html

2 Informe anual del Sistema Nacional de Salud accesible en: https://www.sanidad.gob.es/estadEstudios/sanidadDatos/tablas/tabla27.htm

3 Centers for Disease Control and Prevention (CDC). Emergency Department Visits. National Center for Health Statistics; 2024. Available from: https://www.cdc.gov/nchs/fastats/emergency-department.htm]

4 Lim A, Benjasirisan C, Liu X, Ogungbe O, Himmelfarb CD, Davidson P, Koirala B. Social determinants of health and emergency department visits among older adults with multimorbidity: insight from 2010 to 2018 National Health Interview Survey. BMC Public Health. 2024 Apr 24;24(1):1153.

5 Choi A, Choi SY, Chung K, Chung HS, Song T, Choi B, et al. Development of a machine learning-based clinical decision support system to predict clinical deterioration in patients visiting the emergency department. Sci Rep. 2023; 13:8561. accesible en: https://www.nature.com/articles/s41598-023-35617-3].

6 Siddiqi R, Javaid S. Deep Learning for Pneumonia Detection in Chest X-ray Images: A Comprehensive Survey. J Imaging. 2024 Jul 23;10(8):176.

7 Adejumo P, Thangaraj PM, Dhingra LS, Aminorroaya A, Zhou X, Brandt C, Xu H, Krumholz HM, Khera R. Natural Language Processing of Clinical Documentation to Assess Functional Status in Patients With Heart Failure. JAMA Netw Open. 2024 Nov 4;7(11):e2443925. doi: 10.1001/jamanetwork].

8 Da'Costa A, Teke J, Origbo JE, Osonuga A, Egbon E, Olawade DB. AI-driven triaje in emergency departments: A review of benefits, challenges, and future directions. Int J Med Inform. 2025 May;197:105838.

9 Condés Moreno E, Bonis Sanz J, Beunza Nuin JJ, Puertas Sanz E, Rodríguez Vila B. Manual práctico de inteligencia artificial en entornos sanitarios. 2ª ed. Barcelona: Elsevier; 2023.

10 Heo S, Jeong D, Choi M,y cols ; Korean Shock Society. Scale to predict risk for refractory septic shock based on a hybrid approach using machine learning and regression modeling. Emergencias. 2025 Feb;37(1):15-22.

11 Sáenz-Abad D, Sachi Martínez-Mihara M, Lahoza-Pérez MC. La inteligencia artificial como herramienta de apoyo diagnóstico en urgencias. Emergencias. 2025;37:78-9].

12 Han J, Lee S, Kim H, et al. Rule-Out Acute Myocardial Infarction using Artificial intelligence-Enhanced Electrocardiogram analysis (ROMIAE): a multicentre prospective study. Eur Heart J. 2025;ehaf142.

13 Newman-Toker DE, Peterson SM, Badihian S, Hassoon A, et al. Diagnostic Errors in the Emer-

gency Department: A Systematic Review. AHRQ Comparative Effectiveness Review No. 258. Rockville, MD: Agency for Healthcare Research and Quality; 2022 (addendum agosto 2023).

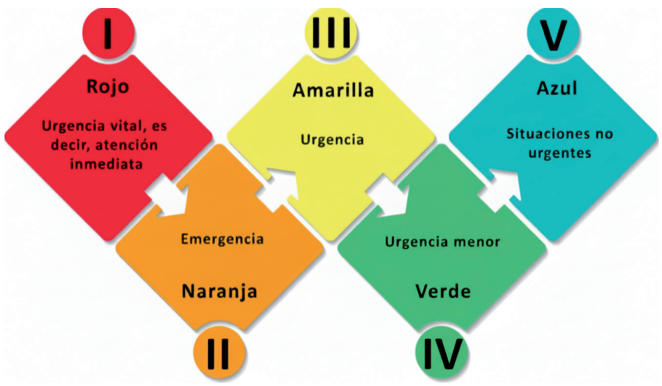
14 Jadoon MM, Torres Lopez V, Butt SA, Murthy SB y cols Automatic Detection and Classification of Cerebral Microbleeds Using 3D CNN. Journal of Image and Graphics, Vol. 13, No. 3, 2025.

4.

OBJETIVOS CLÍNICOS DE LA IA EN URGENCIAS

Objetivo Especifico		Acciones Asistidas por IA
	Mejorar el triaje inicial	Clasificación automática de pacientes por gravedad mediiante algoritmos Priorización basada en signos vitales, historia clinica y motivos de consulta
	Asistencia en el diagnóstico	Identificación de patrones en sintomas, analiticas e imagenes Detección temprana de condiciones criticas (infarto, sepsis, ACV, etc.)
	Recomendaciones terapéuticas	Apoyo en la elección de tratamientos y dosis Alertas sobre interacciones medicamentosas o alergias
	Seguimiento en tiempo real	Monitoreo continuo de parámetros vitales Generación de alertas predictivas

Imagen 1. Objetivos clínicos de la IA en urgencias



4.1 MEJORAR EL TRIAJE INICIAL

La aplicación de la IA en el triaje de urgencias representa una transformación radical en la atención médica. Con el objetivo de mejorar la clasificación y priorización de pacientes, los sistemas basados en IA emplean algoritmos avanzados que procesan grandes volúmenes de datos clínicos, reduciendo el tiempo de respuesta y mejorando la precisión diagnóstica **El triaje en urgencias** se define como el proceso de evaluación rápida y sistemática de los pacientes al momento de su llegada a un servicio de urgencias, con el objetivo de determinar la gravedad de su condición clínica, priorizar la atención médica según la urgencia del caso (no por orden de llegada) y asignar recursos adecuados en función del riesgo vital y la necesidad de intervención inmediata.

Teniendo en cuenta la presión y el estrés que experimentan los profesionales sanitarios al clasificar la gravedad en el servicio de urgencias, se han desarrollado y probado herramientas como el Manchester Triaje System (MTS) [1], el Emergency Severity Index (ESI) [2], la Canadian Triaje and Agudeza Scale (CTAS)[3], la Korean Triaje and Agudeza Scale (KTAS) [4] y la Swiss Emergency Triaje Scale (SETS) [5] para comprobar su fiabilidad y validez para su uso en la clasificación de la gravedad. El Sistema Español de Triaje – Modelo Andorrà (SETMAT) es un sistema estructurado y estandarizado de Triaje utilizado en servicios de urgencias hospitalarias y extrahospitalarias. Nació en Andorra en 2003 como una adaptación conceptual de la Canadian Triaje and Acuity Scale (CTAS), evolucionando para ser adoptado en España y otros países de habla hispana como estándar de triaje [6][7].

4.1.1 Características clave del triaje:

- Basado en criterios clínicos: como signos vitales, motivo de consulta, nivel de conciencia, entre otros.
- Clasificación por niveles: generalmente de 1 (emergencia vital) a 5 (no urgente), como en el Sistema Manchester o el sistema ESI (Emergency Severity Index) [1][2] (Tabla 1 comparativa).
- Dinámico: el estado del paciente puede cambiar, por lo que el nivel de triaje debe reevaluarse si es necesario.
- Realizado por personal capacitado: generalmente enfermeros/as entrenados en triaje.

4.1.2 El triaje en España y Europa

En España, la mayoría de los hospitales utilizan el modelo SET-MAT, seguido por el de Manchester. Sin embargo, existe un pequeño porcentaje de hospitales que no usan ningún tipo de triaje estructurado validado, como, por ejemplo, el Sistema Donostiarra de Triaje o el Sistema de Triaje en la Red Pública de Hospitales de Navarra [8].

Según un estudio realizado en 123 hospitales españoles, en más de tres cuartas partes de los hospitales el triaje lo realiza los profesionales de enfermería. Para poder realizarlo se realiza un curso de triaje, que es una formación específica y es necesario una experiencia mínima [9].

La mayoría de los países europeos utilizan el sistema de triaje creado en su país, como en Reino Unido, que utilizan su propio sistema de triaje de Manchester. En Europa depende del país utiliza cada sistema. Por ejemplo, Alemania ha realizado modificaciones del sistema de triaje Manchester. Así, utiliza diagramas de

presentación respaldados por 50 algoritmos, modificando así los diagramas de presentación y los indicadores. Se introducen también nuevos indicadores y complementos de tiempo para las categorías verde y azul. Mantiene los cinco niveles, pero en dos grupos: Grupo 1: Prioridad alta (color rojo y naranja) y Grupo 2: Prioridad baja (color amarillo, verde y azul) [10].

4.1.3 Comparación entre Sistemas de Triaje: ESI, Manchester y SET-MAT

Los sistemas de triaje ESI (Emergency Severity Index), Manchester (MTS) y SETMAT (Sistema Español de Triaje – Modelo Andorrà) son herramientas fundamentales para priorizar la atención de los pacientes en servicios de urgencias. Aunque comparten una estructura de cinco niveles, presentan diferencias clave en su origen, criterios y enfoque.

Cada sistema responde a las necesidades y contextos de sus países de origen, pero todos buscan garantizar una atención segura, rápida y equitativa en urgencias. La principal diferencia radica en el enfoque: ESI prioriza recursos, Manchester se basa en síntomas y algoritmos, y SETMAT combina criterios clínicos y tecnológicos para una clasificación integral y adaptada al entorno español (Tabla 1).

Tabla 1. Comparación de sistemas de triaje: ESI;MANCHESTER Y SET_MAT

CARACTERÍSTICA	ESI (EMERGENCY SEVERITY INDEX)	SISTEMA MANCHESTER (MTS)	SET-MAT (SISTEMA ESPAÑOL DE TRIAJE – MODELO ANDORRÀ)
Origen	Estados Unidos	Reino Unido	Andorra (Modelo Andorrà), adaptado en España como SET-MAT
Niveles de clasificación	5 niveles (ESI 1 - ESI 5)	5 niveles (Rojo, Naranja, Amarillo, Verde, Azul)	5 niveles (Nivel I a V)
Criterios de clasificación	Urgencia clínica + recursos necesarios	Algoritmos clínicos basados en síntomas guía	Discriminantes clínicos + categorías sintomáticas + algoritmos
Nivel 1 / Rojo	Atención inmediata (riesgo vital)	Atención inmediata (0 minutos)	Atención inmediata (Nivel I – 0 minutos)
Nivel 2 / Naranja	Alta prioridad sin paro cardíaco	Muy urgente (≤10 minutos)	Muy urgente (Nivel II – ≤10 minutos)
Nivel 3 / Amarillo	Estable, necesita múltiples recursos	Urgente (≤60 minutos)	Urgente (Nivel III – ≤60 minutos)
Nivel 4 / Verde	Estable, necesita 1 recurso	Menor urgencia (≤120 minutos)	Menor urgencia (Nivel IV – ≤120 minutos)
Nivel 5 / Azul	Estable, no requiere recursos	No urgente (≤240 minutos)	No urgente (Nivel V – ≤240 minutos)
Enfoque principal	Gravedad clínica + estimación de recursos	Basado en síntomas y algoritmos de presentación	Evaluación clínica guiada por protocolos y criterios estructurados
Uso principal	EE. UU., Latinoamérica, algunos países europeos	Reino Unido, Europa continental, hospitales españoles	España, Andorra, países de habla hispana

CARACTERÍSTICA	ESI (EMERGENCY SEVERITY INDEX)	SISTEMA MANCHESTER (MTS)	SET-MAT (SISTEMA ESPAÑOL DE TRIAJE – MODELO ANDORRÀ)
Requiere juicio clínico	Sí (especialmente en niveles 3–5)	Moderado (algoritmos rígidos, pero con excepciones)	Sí, pero con soporte algorítmico (***ePAT*** y tablas de ayuda)
Ventaja principal	Priorización eficiente de recursos	Homogeneidad y facilidad de aplicación	Precisión clínica, validación nacional, informatización

ePAT: herramienta rápida de valoración pediátrica en urgencias que evalúa apariencia, trabajo respiratorio y circulación a la piel para identificar la gravedad del niño y priorizar su atención.

4.1.4 Etapas del triaje IA

El **triaje de IA** se compone de varias etapas interconectadas que garantizan una evaluación rápida, precisa y explicable (Figura 1).

- Todo comienza con la **entrada de datos clínicos**, que incluye signos vitales como la frecuencia cardíaca, frecuencia respiratoria y temperatura; el motivo de consulta; datos demográficos como edad y sexo; y antecedentes relevantes como el tiempo de evolución de los síntomas y la presencia de comorbilidades. Esta información es fundamental para alimentar los modelos de inteligencia artificial.

- Una vez introducidos los datos, estos son procesados por los **modelos de IA**, que combinan un modelo de procesamiento de lenguaje natural (NLP de natural language processing) con un modelo de clasificación. El modelo NLP interpreta y estructura la información de texto (por ejemplo, el motivo de consulta escrito por el

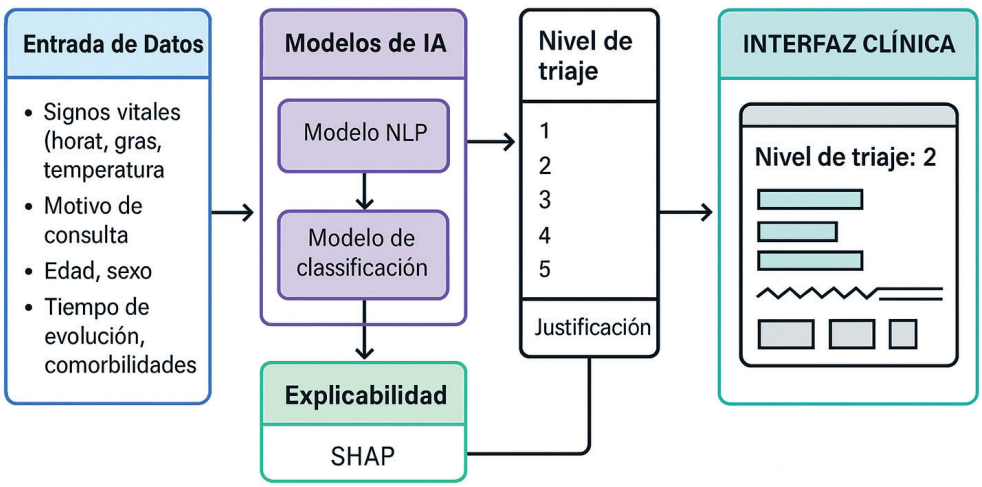


Imagen 2. Etapas interconectadas del Triaje de IA

paciente o el personal sanitario), mientras que el modelo de clasificación se encarga de asignar un nivel de gravedad o prioridad clínica, es decir, el **nivel de triaje.** Este nivel puede variar del 1 (más urgente) al 5 (menos urgente).

- Una característica clave de este sistema es su **explicabilidad**, lograda mediante el uso de técnicas como SHAP (SHapley Additive exPlanations). SHAP permite identificar qué variables influyeron más en la decisión del modelo, proporcionando una justificación transparente del nivel de triaje asignado. Esto es crucial para ganar la confianza de los profesionales sanitarios y asegurar la trazabilidad de las decisiones clínicas automatizadas.

Veamos un ejemplo de SHAP aplicado al triaje

Supongamos que un modelo predice Nivel II (muy urgente, ≤10 min) para un paciente. Con SHAP obtenemos algo así:

Frecuencia cardiaca = 140 lpm → +0.35 (empuja la predicción hacia mayor urgencia)

Saturación de O_2 = 86% → +0.40

Edad = 75 años → +0.20

Motivo de consulta: dolor torácico → +0.15

Temperatura normal → -0.05 (empuja hacia menor urgencia)

El modelo dice: "*Este paciente es Nivel II principalmente porque tiene hipoxemia + taquicardia + edad avanzada*".

- Finalmente, **el resultado se presenta en una interfaz clínica**, donde el personal médico puede visualizar el nivel de triaje asignado junto con una representación gráfica de los factores que contribuyeron a dicha decisión. Esta interfaz facilita la integración del sistema de IA en el flujo de trabajo clínico, permitiendo decisiones más informadas, ágiles y basadas en evidencia.

En resumen, el triaje de IA combina datos clínicos, modelos de procesamiento automático y explicabilidad para apoyar de forma segura y eficiente la toma de decisiones en situaciones de urgencia médica.

4.1.5 Análisis comparativo: Triaje tradicional vs. Triaje con IA

La siguiente tabla resume las principales diferencias entre el triaje tradicional y el asistido por IA, revelando mejoras sustanciales en eficiencia, precisión y adaptabilidad. A continuación, se presenta un análisis explicativo de cada punto comparado (Tabla 2):

Tabla 2. Comparación entre triaje tradicional e IA [11-14]

CARACTERÍSTICA	TRIAJE TRADICIONAL	TRIAJE CON IA
Tiempo medio de clasificación	3-10 min	30 s – 2 min
Precisión en casos graves	80-86%	88-94%
Variabilidad profesional	Alta	Baja
Adaptabilidad	Limitada	Alta (en tiempo real)
Capacidad de aprendizaje	No	Sí

1. Tiempo medio de clasificación: El triaje tradicional puede requerir entre 3 y 10 minutos, dependiendo de la experiencia del profesional y la complejidad del caso. En contraste, los sistemas con IA son capaces de realizar la clasificación en tan solo 30 segundos a 2 minutos gracias al análisis automático y simultáneo de signos vitales y datos clínicos [11].
2. Precisión en casos graves: La precisión del triaje convencional oscila entre 80% y 86%, mientras que los modelos de IA pueden alcanzar cifras entre 88% y 94% [12] Esto representa una mejora significativa, especialmente en la detección de pacientes en estado crítico, lo que puede tener un impacto directo en la supervivencia y calidad del cuidado.
3. Variabilidad profesional: En los métodos tradicionales, la clasificación puede variar significativamente entre distintos profesionales debido a diferencias en juicio clínico, experiencia o incluso carga laboral. La IA minimiza esta variabilidad al aplicar algoritmos estandarizados, ofreciendo decisiones más consistentes y homogéneas [11].
4. Adaptabilidad: El triaje convencional no está diseñado para ajustarse dinámicamente a cambios bruscos en la demanda o la disponibilidad de recursos. Por el contrario, los sistemas con IA pueden adaptarse en tiempo real, redirigiendo circuitos y ajustando prioridades en función de nuevas entradas de datos [13].
5. Capacidad de aprendizaje: A diferencia del sistema tradicional, que depende exclusivamente de la experiencia del personal, los algoritmos de IA pueden ser reentrenados con nuevos datos, aprendiendo y mejorando su rendimiento de forma continua mediante técnicas de Machine Learning [14].

4.1.6 Principales estudios internacionales y nacionales recientes sobre el uso de IA en el triaje (Tabla 3)

Los estudios internacionales y nacionales destacan el potencial de la IA para transformar el triaje en urgencias, mejorando la precisión, eficiencia y personalización de la atención. Sin embargo, desafíos como la calidad de los datos, la ética y la necesidad de infraestructura tecnológica persisten. La integración de IA en el triaje requiere un enfoque interdisciplinario y regulaciones claras para garantizar su uso seguro y equitativo. Algunos de estos estudios son:

Estudios Internacionales

1. Universidad de California, San Francisco (EE.UU.). Un estudio evaluó un sistema de triaje basado en IA para clasificar pacientes en urgencias. Los resultados mostraron que la IA puede predecir con alta precisión la gravedad de los casos, reduciendo los tiempos de espera y mejorando la asignación de recursos en comparación con los sistemas tradicionales. Este sistema utiliza algoritmos de aprendizaje automático para analizar datos clínicos en tiempo real, logrando una precisión superior al 80% en la identificación de casos críticos [15].
2. Investigaciones han explorado el uso de modelos de aprendizaje automático y redes neuronales profundas en el triaje. Estos estudios destacan la capacidad de la IA para analizar datos multimodales, como imágenes médicas y registros clínicos, para priorizar pacientes con enfermedades críticas. Por ejemplo, un modelo de IA predijo complicaciones en pacientes con enfermedades cardiovasculares con una precisión superior al 80%, permitiendo intervenciones tempranas [16][17].
3. Un estudio de la Mayo Clinic aborda el uso de algoritmos de inteligencia artificial

Tabla 3. Resumen de Estudios sobre IA y Triaje

ESTUDIO	PAÍS	AÑO	METODOLOGÍA	HALLAZGOS PRINCIPALES	REFERENCIA
Universidad de California, San Francisco	EE.UU.	2024	Algoritmos de aprendizaje automático	Precisión >80% en triaje de casos críticos, reduce tiempos de espera	[15]
Nature y The Lancet Digital Health	Internacional	2023-2024	Modelos de aprendizaje automático y redes neuronales	Predicción de complicaciones cardiovasculares con >80% de precisión	[16,17]
Mayo Clinic	EE.UU.	2024	CDSS basado en IA	Predicción de eventos cardíacos con >80% de precisión	[18]
Naved & Luo (Medicina Digital)	EE.UU.	2024	Triaje virtual con reglas y ML	Precisión de hasta 90% en casos críticos	[19]
Hospital Mancha Centro	España	2023	IA con simulación de escenarios clínicos	Reduce tiempos y automatiza procesos con enfoque humanizado	[20]
Proyecto trIAje	España	2025	ML y NLP en triaje telefónico	Mejora detección de patologías críticas y asignación de recursos	[21]
Triaje Smart Decision (ITCL)	España	2021	PNL y aprendizaje profundo	Automatiza triaje, reduce contacto físico, inclusivo y multilingüe	[22]

para predecir disfunciones cardíacas, como eventos adversos, utilizando electrocardiogramas (ECG) habilitados por IA. El estudio reporta una alta precisión en la detección de condiciones críticas, lo que apoya su aplicación en sistemas de apoyo a la toma de decisiones clínicas (CDSS) para triaje en emergencias [18].

4. Naved y cols. analizan sistemas de triaje virtual basados en IA que emplean reglas empíricas y aprendizaje automático: Los resultados indican que los sistemas de IA superan a los basados únicamente en reglas en escenarios de emergencia, con una precisión de triaje de hasta el 90% en casos críticos, aunque la precisión disminuye en casos de menor urgencia [19].

Estudios Nacionales

1. La herramienta, basada en IA, implantada en el Servicio de Urgencias del Hospital General la Mancha Centro, mejora el sistema de triaje tradicional ya que permite simular situaciones clínicas y realizar previsiones en un entorno virtual, creando así una réplica digital del proceso físico. Todo ello gracias a la generación de "Gemelos Clínicos Digitales Anonimizados" (modelo virtual de un paciente o de un proceso asistencial que reproduce su comportamiento clínico). Concretamente, este sistema permite que cada profesional se enfrente a más de 300 casos de situaciones clínicas totalmente diferentes. Además, facilita la asignación de niveles de prioridad, identificando por colores en las zonas de asistencia

y/o circuitos previamente establecidos donde se encuentren los pacientes triados [20].

2. El Centro de Emergencias Sanitarias 061 de Andalucía y la Fundación Progreso y Salud (FPS) han comenzado a investigar sobre la aplicación de la IA en el servicio de emergencias, a través del proyecto "*trIAje' Innovando en el Triaje Telefónico de los Centros de Emergencias Sanitarias en Andalucía*" con Inteligencia Artificial. La iniciativa propone el uso de tecnologías de aprendizaje automático (ML) y procesamiento de lenguaje natural (NLP) para desarrollar y validar algoritmos, que aumenten la eficiencia y precisión del sistema de triaje telefónico del 061. Con ello se pretende mejorar la asignación de recursos de emergencia y una reducción significativa en los tiempos de respuesta, aspectos claves para mejorar los resultados en salud en situaciones críticas [21].
3. El proyecto *Triaje Smart Decision*, desarrollado por el Instituto Tecnológico de Castilla y León (ITCL), utiliza procesamiento de lenguaje natural y aprendizaje profundo para automatizar el triaje en urgencias. Este sistema, implementado en 2021, permite un cribado inicial de pacientes, diferenciando casos COVID-19 de no COVID-19, reduciendo el contacto físico y mejorando la eficiencia hospitalaria. El sistema es multilingüe e inclusivo, adaptándose a diversas casuísticas mediante autoaprendizaje [22].

4.1.7 Algoritmos utilizados en el triaje con IA (Tabla 4)

Los algoritmos aplicados en el triaje con inteligencia artificial se seleccionan en función del tipo de datos disponibles, los objetivos clínicos del sistema y el entorno operativo. La siguiente tabla resume los principales enfoques algorítmicos empleados, junto con su aplicación y ventaja destacada. A continuación, se analiza el papel de cada uno:

- 1. Redes neuronales profundas (DNN): Estos modelos, que incluyen arquitecturas como CNN (Convolutional Neural Network) y RNN(Recurrent Neural Network), son especialmente eficaces en la detección de patrones complejos no lineales. Se utilizan ampliamente para predecir signos vitales, categorizar la gravedad de los pacientes y anticipar ingresos a unidades críticas. Su capacidad para manejar grandes volúmenes de datos y aprender de ellos los convierte en una herramienta de alto rendimiento clínico.
- 2. Modelos de lenguaje natural (LLM): Algoritmos como ChatGPT o BERT-clinical (Bidirectional Encoder Representations from Transformers) permiten interpretar y estructurar información contenida en textos libres, como notas de ingreso, síntomas descritos por pacientes o informes de triaje. Esto facilita una integración fluida con los sistemas de historia clínica electrónica y mejora la extracción automática de datos clínicamente relevantes.
- 3. Aprendizaje por refuerzo: como vimos en el capítulo 2 es una técnica de inteligencia artificial donde un "agente" aprende tomando decisiones y recibiendo recompensas o castigos según sus acciones. En el contexto de un gemelo digital (una simulación de un hospital, por ejemplo), este método permite que el sistema pruebe distintas estrategias para mejorar el flujo de pacientes, aprendiendo de la experiencia. Su gran ventaja es que se adapta automáticamente a los cambios, como la falta de camas o un aumento repentino en la demanda, buscando siempre la mejor forma de actuar según la situación.
- 4. Random Forest y XGBoost: son algoritmos de inteligencia artificial que combinan muchos "árboles de decisión" para hacer predicciones más precisas. Son buenos porque manejan bien datos variados o incompletos

Tabla 4. Algoritmos utilizados en el triaje con IA

ALGORITMO	APLICACIÓN	VENTAJA PRINCIPAL
Redes neuronales profundas (DNN)	Predicción de signos y clasificación	Alta precisión en escenarios complejos
Modelos de lenguaje (LLM)	Análisis de notas clínicas	Capacidad de interpretar lenguaje natural
Aprendizaje por refuerzo	Optimización del flujo	Adaptabilidad en simulaciones
Random Forest / XGBoost	Clasificación multivariable	Reducción del over-triaje

y pueden clasificar pacientes considerando muchas variables clínicas a la vez. Gracias a esto, ayudan a mejorar el triaje, reduciendo los casos en los que se clasifica a un paciente como más grave de lo que es, sin aumentar los errores en los casos graves reales.En conjunto, estos algoritmos ofrecen soluciones complementarias que, integradas, fortalecen la fiabilidad y eficiencia del triaje asistido por IA.

4.1.8 Caso práctico: Sistema de IA para triaje en el Servicio de Urgencias Hospitalarias

Presentamos un esquema conceptual para el desarrollo e implementación de un Sistema de IA para Triaje en Urgencias Hospitalarias, que integra modelos de aprendizaje automático con procesamiento del lenguaje natural (NLP) para asistir al personal sanitario en la clasificación inicial de pacientes [23]. A continuación, se describe en forma de tabla cada uno de los componentes clave del sistema, desde el diseño técnico hasta los resultados esperados en una fase piloto.

Resumimos cuales son los componentes del sistema, aunque somos conscientes que ello requiere un conocimiento elevado para el lector de esta publicación básica Estos son los componentes:

1. Objetivo. El propósito fundamental del sistema es clasificar automáticamente a los pacientes en uno de los cinco niveles de prioridad establecidos en sistemas reconocidos como el *Manchester Triaje System*. Esta clasificación se basa en los datos clínicos recogidos al ingreso del paciente, incluyendo signos vitales, motivo de consulta y otras variables relevantes.
2. Diseño del sistema. El diseño técnico contempla la captura de datos de entrada como signos vitales, edad, motivo de consulta y comorbilidades. La IA utiliza modelos supervisados, como XGBoost o redes neuronales, junto con técnicas de NLP para analizar textos clínicos. El sistema produce como salida un nivel de triaje (1 a 5), acompañado de una justificación basada en los factores clínicos detectados.
3. Desarrollo técnico. El entrenamiento del sistema se apoya en bases de datos reales de pacientes, estructuradas y no estructuradas (notas clínicas en texto libre). El preprocesamiento incluye técnicas como imputación por k-vecinos más cercanos (kNN) y normalización de variables. Se utiliza un conjunto de entrenamiento/prueba de 80/20 y métricas como F1-score y recall

Tabla 5. Ejemplo de Sistema de IA para Triaje en Urgencias Hospitalarias

COMPONENTE	DESCRIPCIÓN
Objetivo	Clasificar automáticamente a los pacientes en 5 niveles de prioridad (p. ej., Manchester Triaje System) según datos clínicos iniciales.
1. Diseño del sistema	a. Entrada de datos: signos vitales, motivo de consulta, nivel de consciencia, edad, sexo, evolución, comorbilidades. b. Modelos de IA: NLP + Clasificador supervisado (XGBoost, Red Neuronal). c. Salida: Nivel de triaje (1–5) + justificación.
2. Desarrollo técnico	a. Dataset: visitas previas, datos estructurados y texto libre, etiquetas por expertos. b. Preprocesamiento: limpieza de texto, imputación (kNN), normalización. c. Entrenamiento: set 80/20, métricas por clase (F1, recall), validación cruzada. d. Explicabilidad: SHAP para justificar predicciones.
3. Interfaz clínica	Panel web o tablet para el personal. Visualización clara de nivel y variables clave. Interacción humana: aceptar/modificar/rechazar propuesta IA.
4. Ética y legalidad	Cumplimiento GDPR/LOPD. Validación clínica antes de uso. Supervisión continua del rendimiento.
5. Resultados esperados (piloto)	- Reducción del tiempo de triaje: 12 min → 5 min. - Mejora en precisión niveles 1-2: +8%. - Satisfacción clínica: >85%. - Identificación precoz de críticos ocultos: +15%.

kNN (k-Nearest Neighbors): método que usa los datos más parecidos para estimar valores o categorías faltantes. F1 (F1-score): medida que combina precisión y sensibilidad, indicando el equilibrio general del modelo. Recall (Sensibilidad): mide cuántos casos verdaderos de una clase (por ejemplo, pacientes graves) el modelo logra identificar correctamente.SHAP (SHapley Additive exPlanations): método que explica qué variables influyeron más en cada decisión del modelo.

por clase, con validación cruzada. Se aplica SHAP para explicar de manera transparente las decisiones del modelo.

4. Interfaz clínica. El sistema está diseñado para ser utilizado a través de un panel en web o tablet accesible al personal de triaje. La interfaz ofrece una visualización clara del nivel propuesto por la IA, los factores determinantes y la posibilidad de que el profesional acepte, modifique o rechace la recomendación, manteniendo el control humano en la decisión final.
5. Ética y legalidad. Se garantiza el cumplimiento de las normativas de protección de datos GDPR (Reglamento General de Protección de Datos de la Unión Europea). y LOPD(adaptación española del GDPR.), junto con una validación clínica rigurosa antes de la implementación. Se establece un sistema de supervisión continua para evaluar el rendimiento del modelo en la práctica real y corregir desviaciones.
6. Resultados esperados (piloto). En una fase piloto, se prevé una reducción significativa del tiempo medio de triaje (de 12 a 5 minutos), una mejora del 8% en la precisión de clasificación en los niveles críticos (1 y 2), una satisfacción clínica superior al 85%, y un aumento del 15% en la identificación temprana de pacientes graves que no se reconocieron inicialmente.

4.1.9 Limitaciones Éticas y Técnicas de la IA en el Triaje de Urgencias

La incorporación de la IA en el triaje de urgencias plantea importantes desafíos éticos y técnicos que deben ser cuidadosamente valorados para evitar riesgos en la equidad, la seguridad y la confianza en el sistema sanitario.

1. Sesgos en los Datos. Uno de los principales riesgos éticos de la IA en el triaje es la reproducción o amplificación de sesgos existentes en los datos de entrenamiento. Si los conjuntos de datos utilizados para entrenar los algoritmos no representan adecuadamente a todos los grupos poblacionales, la IA puede perpetuar desigualdades en el acceso o la calidad del cuidado. Por ejemplo, se han documentado casos en los que algoritmos entrenados mayoritariamente con datos de pacientes de un grupo étnico presentan menor precisión para otros grupos, lo que puede derivar en decisiones clínicas injustas o inadecuadas. La falta de diversidad en los datos puede afectar negativamente a minorías étnicas, mujeres o personas con condiciones menos prevalentes, incrementando el riesgo de errores diagnósticos o de priorización [24][25].
2. Caja Negra Algorítmica y Falta de Explicabilidad. Muchos modelos de IA, especialmente aquellos basados en Deep Learning, funcionan como una "caja negra", es decir, producen resultados sin que sea posible comprender fácilmente el razonamiento detrás de sus decisiones. Esta falta de explicabilidad dificulta la interpretación clínica, reduce la confianza de los profesionales sanitarios y puede limitar la aceptación de estas herramientas en entornos críticos como las urgencias. La transparencia y la capacidad de auditar las decisiones algorítmicas son fundamentales para garantizar la seguridad del paciente y permitir la supervisión humana en situaciones complejas.
3. Privacidad y Protección de Datos. El uso de IA en el triaje de urgencias implica el procesamiento de grandes volúmenes de datos personales y clínicos, lo que exige cumplir rigurosamente con normativas de privacidad y protección de datos como el Reglamento General de Protección de Datos (GDPR) en Europa o la Ley de Portabilidad y Responsabilidad del Seguro Médico (HIPAA) en Estados Unidos [26][27][28]. Estas regulaciones establecen obligaciones estrictas sobre el consentimiento informado, la minimización de datos, la anonimización y la seguridad de la información, con el objetivo de proteger la confidencialidad y los derechos de los pacientes. El incumplimiento puede acarrear sanciones legales y dañar la confianza pública en el uso de IA en salud.
4. Responsabilidad Médica. La introducción de IA en la toma de decisiones clínicas plantea interrogantes sobre la asignación de responsabilidades en caso de errores o daños al paciente. Actualmente, en muchos sistemas sanitarios, la responsabilidad recae principalmente en el profesional médico, incluso cuando la decisión se ha basado en una recomendación algorítmica. Esta situación genera incertidumbre y puede desincentivar el uso de la IA, especialmente si los algoritmos son opacos o no han sido validados exhaustivamente. Es necesario establecer marcos legales y éticos claros que definan la responsabilidad compartida entre desarrolladores, instituciones y profesionales sanitarios.

Por tanto, aunque la IA tiene el potencial de transformar el triaje de urgencias, su implementación debe acompañarse de estrategias para mitigar los sesgos, garantizar la transparencia y la protección de datos, y clarificar la

responsabilidad profesional, asegurando así una atención ética, segura y equitativa para todos los pacientes.

4.1.10 Proyección Futura de la IA en Urgencias

En el futuro la evolución de la IA permitirá que los sistemas analicen grandes volúmenes de datos provenientes de historias clínicas, dispositivos portátiles y monitores en tiempo real, ajustando las recomendaciones terapéuticas y de triaje a las características individuales de cada paciente. Esta personalización dinámica contribuirá a mejorar los resultados clínicos y optimizar los recursos disponibles, especialmente en situaciones de alta demanda o sobrecarga del sistema.

1. Gemelos Digitales y Simulaciones Clínicas
El desarrollo de gemelos digitales —réplicas virtuales de pacientes, unidades de urgencias o incluso hospitales completos— está revolucionando la formación del personal sanitario y la gestión operativa. Estas herramientas permiten simular escenarios clínicos complejos, anticipar picos de demanda y ajustar dinámicamente la asignación de recursos, mejorando la capacidad de respuesta ante emergencias y eventos extraordinarios. Además, los gemelos digitales facilitan la identificación temprana de riesgos y la intervención preventiva, lo que puede traducirse en una reducción de complicaciones y una mayor eficiencia asistencial [29].
2. Predicción de Flujos y Asignación de Recursos. A largo plazo, la IA no solo optimizará el triaje, sino que también será fundamental en la predicción de flujos de pacientes, la asignación de camas y la toma de decisiones terapéuticas inmediatas. Algoritmos avanzados podrán anticipar la llegada de pacientes, prever la ocupación de camas y recomendar estrategias de redistribución de recursos en tiempo real, siempre bajo la supervisión y validación de los profesionales sanitarios [30]. Esta integración permitirá reducir los tiempos de espera, evitar el colapso de los servicios y mejorar la calidad global de la atención en urgencias.
3. Supervisión Humana y Retos Éticos. A pesar de los avances tecnológicos, la supervisión humana seguirá siendo imprescindible para validar las recomendaciones de la IA, garantizar la seguridad del paciente y abordar los retos éticos asociados, como la equidad en el acceso y la protección de



Imagen 3

datos personales [31]. El futuro de la IA en urgencias se perfila como una colaboración estrecha entre tecnología y profesionales, orientada a una atención más eficiente, segura y personalizada.



Imagen 4

4.2 ASISTENCIA EN EL DIAGNÓSTICO MÉDICO

La inteligencia artificial (IA) está revolucionando la asistencia diagnóstica en los servicios de urgencias, permitiendo una evaluación más rápida y precisa de los pacientes. Su capacidad para analizar grandes volúmenes de datos clínicos, imágenes y resultados analíticos contribuye a mejorar la toma de decisiones y a reducir los errores diagnósticos en situaciones críticas [32].

4.2.1. Identificación de patrones en síntomas, analíticas e imágenes

4.2.1.1 Algoritmos de procesamiento de lenguaje natural y datos clínicos

Como ya hemos visto la inteligencia artificial (IA) está transformando la medicina mediante el uso de algoritmos avanzados de procesamiento de datos clínicos. Estos algoritmos, basados en el aprendizaje automático (machine learning) y el procesamiento de lenguaje natural (PLN), permiten analizar grandes volúmenes de información médica, extraer patrones relevantes y asistir en la toma de decisiones clínicas. Estos sistemas no solo mejoran la precisión y eficiencia del diagnóstico, sino que también permiten priorizar la atención de pacientes críticos, demostrando resultados superiores en estudios recientes frente a métodos tradicionales [33].

Ya hemos visto en el capítulo 2 cómo funciona la IA. El aprendizaje automático permite procesar y analizar datos clínicos estructurados y no estructurados, como historias médicas electrónicas, imágenes diagnósticas y datos genéticos. Los sistemas de IA pueden generar listas ordenadas de posibles diagnósticos con estimaciones de probabilidad, facilitando el diagnóstico diferencial y la priorización de casos complejos. Veamos algunos ejemplos:

Ejemplo 1: La **enfermedad cardiovascular** es la principal causa de muerte en pacientes con enfermedad renal crónica. Zhu y cols desarrollaron un modelo de predicción de riesgo cardiovascular usando aprendizaje automático y datos clínicos de casi 9.000 pacientes. El modelo identificó ocho factores clave y, utilizando Extreme Gradient Boosting, logró una alta precisión (AUC

0.89) para predecir eventos cardiovasculares. Esos factores fueron edad, antecedentes de hipertensión, sexo, uso de antiagregantes plaquetarios, niveles de colesterol HDL, concentración de sodio en sangre, proteinuria en 24 horas y tasa de filtración glomerular estimada (eGFR) [34].

Ejemplo 2: Un estudio utilizó seis algoritmos de aprendizaje automático para mejorar el diagnóstico de **enfermedades de la piel** a partir de muestras de biopsia. El clasificador Stochastic Gradient Descent (SGD) fue el más preciso, con una exactitud del 99,09%. La selección de características clave, como el fenómeno de Koebner (aparición de lesiones nuevas en áreas de piel sana tras un trauma o irritación, en personas con enfermedades cutáneas como psoriasis o vitiligo.), el eritema y el prurito, mejoró la eficacia y comprensión del modelo. Los resultados muestran el potencial del aprendizaje automático para crear herramientas diagnósticas automáticas y confiables en dermatología[35].

Ejemplo 3: Veamos ahora la aplicación de algoritmos de aprendizaje automático en el ámbito de la **medicina de urgencias**. Como hemos visto los algoritmos de procesamiento de datos clínicos tienen un impacto significativo en la mejora del triaje, la priorización y la toma de decisiones bajo presión. Un ejemplo reciente es el desarrollo de modelos de aprendizaje profundo (deep learning) integrados en sistemas avanzados de apoyo a la decisión clínica (CDSS) en servicios de urgencias. En un estudio retrospectivo que incluyó más de 237.000 visitas a urgencias en un hospital terciario, se implementó un algoritmo de deep learning capaz de integrar datos multimodales (constantes vitales, resultados de laboratorio e imágenes diagnósticas) desde la historia clínica electrónica. Este sistema demostró una alta precisión en la predicción en tiempo real del deterioro clínico, incluyendo paros cardíacos intrahospitalarios, necesidad de soporte circulatorio intensivo y admisión en UCI, superando a los modelos estadísticos tradicionales. Además, la precisión de las predicciones aumentó al incorporar datos clínicos actualizados a intervalos más cortos, lo que permitió intervenciones más tempranas y una optimización de recursos críticos en urgencias[36].

4.2.1.2 Algoritmos de procesamiento de Interpretación de analíticas y biomarcadores

Los sistemas de IA pueden analizar resultados de laboratorio y biomarcadores para detectar alteraciones compatibles con patologías críticas. Por ejemplo, algoritmos específicos alertan sobre la presencia de anemia grave, infecciones o alteraciones metabólicas, facilitando la intervención precoz [37].

Ejemplo 1: Un hospital donde los resultados de laboratorio de todos los pacientes ingresan automáticamente a un sistema de inteligencia artificial. Un paciente llega a urgencias con síntomas inespecíficos y se le realiza un análisis de sangre. El sistema de IA revisa los valores de hemoglobina, leucocitos, electrolitos y otros biomarcadores en tiempo real. Puede detectar anemia grave y el algoritmo identifica que la hemoglobina está peligrosamente baja y genera una alerta inmediata al equipo médico, permitiendo iniciar una transfusión sin demora. Lo mismo identifica una infección por aumento significativo de leucocitos y neutrófilos, sugiriendo una posible infección bacteriana grave o alteraciones metabólicas como hiponatremia severa y la IA señala el riesgo de convulsiones o coma, priorizando la atención y

guiando el tratamiento urgente. Estos sistemas no solo agilizan la interpretación de grandes volúmenes de datos, sino que también ayudan a reducir errores y a intervenir precozmente en situaciones críticas, mejorando los resultados clínicos[38].

4.2.1.3 Algoritmos de procesamiento de análisis de imágenes médicas

La IA ha mostrado una gran eficacia en el análisis automático de radiografías, tomografías computarizadas y resonancias magnéticas. Los algoritmos pueden detectar anomalías como neumonías, hemorragias intracraneales o lesiones óseas con una precisión comparable o superior a la de los radiólogos humanos. En el caso del electrocardiograma (ECG), la IA es capaz de identificar alteraciones isquémicas o arritmias de manera automatizada y en tiempo real.

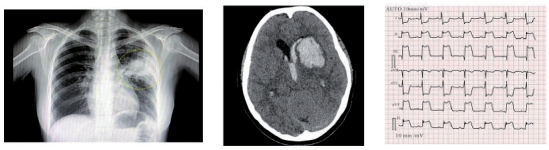


Imagen 5

Ejemplo 1: Un estudio realizado por Stanford University desarrolló el algoritmo CheXNet, una red neuronal entrenada con más de 100,000 radiografías de tórax. Este sistema ha demostrado una precisión superior a la de los radiólogos en la detección de **neumonía**, permitiendo una identificación temprana y mejorando significativamente las tasas de tratamiento oportuno [39].

Ejemplo 2: La utilización de sistemas de inteligencia artificial para la detección automática de **hemorragias intracraneales** en tomografías computarizadas ha mostrado una precisión comparable a la de los radiólogos expertos, agilizando el diagnóstico y priorización de pacientes en situaciones de urgencia. Los investigadores introdujeron 904 tomografías computarizadas de craneo, cada una de las cuales contaba con alrededor de 40 imágenes individuales. Todas ellas fueron etiquetadas por un equipo de cinco neurorradiólogos en relación a si mostraban uno de los cinco subtipos de hemorragia, según la ubicación dentro del cerebro, o no tenían hemorragia. Una vez que se creó el sistema modelo, los investigadores lo probaron en dos conjuntos separados de tomografías computarizadas: un conjunto retrospectivo tomado antes del desarrollo del sistema, que constaba de 100 exploraciones con o sin hemorragia intracraneal, y una serie prospectiva, tomada después de la creación del modelo, de 79 exploraciones con o sin hemorragia. En su análisis del conjunto retrospectivo, el sistema modelo fue tan preciso en la detección y clasificación de las hemorragias intracraneales como lo habían sido los radiólogos que habían revisado las exploraciones. Además, en el análisis del conjunto demostró ser mejor que los profesionales no expertos [40].

4.2.2 Detección temprana de condiciones críticas

4.2.2.1 Infarto agudo de miocardio

La IA ha sido aplicada con éxito en la identificación de infartos mediante el análisis automatizado de ECG y datos clínicos. Algoritmos entrenados con grandes bases de datos pueden reconocer patrones de isquemia y alertar al equipo médico, reduciendo el tiempo hasta el diagnóstico y mejorando el pronóstico del paciente [41]. Diversos estudios recientes han evidenciado el valor clínico de la inteligencia artificial en el análisis automatizado de electrocardiogramas para mejorar el diagnóstico

del infarto agudo de miocardio. Bellfield y cols [42] demostraron que el formato de los datos de ECG influye significativamente en el rendimiento de los modelos predictivos, subrayando la importancia de una estandarización adecuada. Ricci y cols [43] profundizaron en los patrones ECG específicos del infarto por oclusión (OMI), facilitando su identificación temprana. Kim y cols [44] propusieron un enfoque integrativo que combina IA con guías clínicas para clasificar con mayor precisión los tipos de infarto con elevación del ST. Por su parte, Naghashyar [45] mostró que el preentrenamiento de algoritmos con ECG sintéticos (generados artificialmente simulados por computadora en lugar de usar solo registros reales.) mejora notablemente la detección del infarto, incluso en entornos con datos limitados. En conjunto, estos estudios respaldan el uso de IA como una herramienta complementaria eficaz en el diagnóstico temprano y la estratificación del riesgo cardíaco.

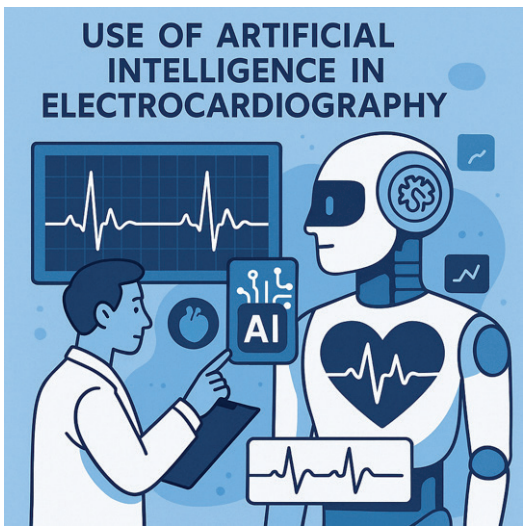


Imagen 6

Ejemplo en urgencias: Un ejemplo se basa en que el número de pacientes con IOM (Occlusive Myocardial Infarction) sin elevación del segmento ST en el electrocardiograma (ECG) de presentación es cada vez mayor. Estos pacientes tienen un mal pronóstico y se beneficiarían de una terapia de reperfusión inmediata, pero, en la actualidad, no existen herramientas precisas para identificarlos durante el triaje inicial. Al Zaiti y cols [46]publicaron un estudio observacional de cohortes que desarrolla modelos de aprendizaje automático para el diagnóstico ECG de IOM. Utilizando 7.313 pacientes consecutivos de múltiples centros clínicos, derivaron y validaron externamente un modelo inteligente que superó a los clínicos en ejercicio, aumentando sustancialmente tanto la precisión como la sensibilidad. La puntuación de riesgo de IOM derivada proporcionó una mayor precisión de inclusión y exclusión en la atención rutinaria y, cuando se combinó con el juicio clínico de personal de urgencias entrenado, ayudó a reclasificar correctamente a uno de cada tres pacientes con dolor torácico. Las características del ECG que guiaron los modelos fueron validadas por expertos clínicos, proporcionando vínculos mecánicos plausibles con la lesión miocárdica.

Los estudios sobre IA y ECG son numerosísimos y lógicamente incluyen infarto agudo de miocardio, arritmias, predicción de paro cardiaco, etc. Un estudio interesante es el realizado por Attia y cols [47]. La disfunción ventricular izquierda asintomática (ALVD) afecta al 3-6% de la población general, se asocia con una menor calidad de vida y esperanza de vida, y es tratable si se detecta a tiempo. Actualmente, no existe una herramienta de cribado económica y no invasiva disponible en la consulta médica para su detección. Se planteó la hipótesis de que la inteligencia artificial (IA) aplicada al electrocardiograma (ECG) —una prueba

rutinaria y de bajo coste— podría identificar la ALVD. Para ello, se usaron datos emparejados de ECG de 12 derivaciones y ecocardiogramas, incluyendo la fracción de eyección del ventrículo izquierdo (indicador de la función contráctil), de 44.959 pacientes del Mayo Clinic. Se entrenó una red neuronal convolucional para detectar disfunción ventricular (definida como fracción de eyección ≤35%) a partir únicamente de los datos del ECG. Al evaluarse en un conjunto independiente de 52.870 pacientes, el modelo de IA alcanzó un área bajo la curva (AUC) de 0.93 Además, en pacientes sin disfunción ventricular al inicio, aquellos con un cribado positivo por IA tuvieron un riesgo 4 veces mayor de desarrollar disfunción en el futuro (razón de riesgo: 4.1; IC 95%: 3.3–5.0) en comparación con los de cribado negativo.

4.2.2.2 Sepsis

La sepsis representa una de las principales causas de morbimortalidad a nivel mundial, con millones de muertes cada año[48]. Su detección precoz en los servicios de urgencias es fundamental, ya que la mayoría de los pacientes con sepsis ingresan por esta vía, presentando altas tasas de hospitalización y mortalidad. El retraso en el diagnóstico y tratamiento se asocia a un peor pronóstico, por lo que la intervención rápida es clave. La Campaña Sobrevivir a la Sepsis [49] propone un paquete de medidas basadas en evidencia que deben aplicarse en las primeras horas desde el reconocimiento, como la administración precoz de antibióticos y líquidos intravenosos, y la medición de lactato. Sin embargo, debido a la sobrecarga asistencial en urgencias, identificar rápidamente la sepsis sigue siendo un reto. En este contexto, los sistemas de alerta automatizados han surgido como herramientas útiles para facilitar el diagnóstico temprano. Aunque han demostrado buena sensibilidad en la detección, su impacto directo en la mortalidad y en la mejora de los tiempos de intervención aún requiere mayor evidencia. Aun así, integrar estos sistemas puede ser crucial para optimizar el manejo de la sepsis en un entorno tan crítico como urgencias.

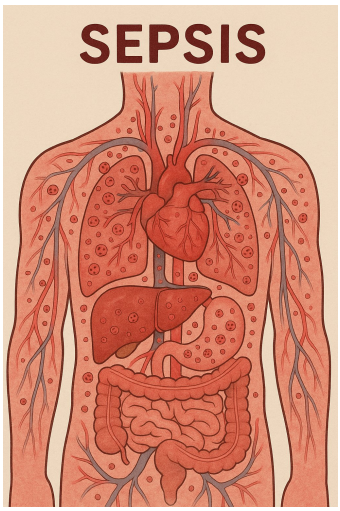


Imagen 7

En un metanalisis, Kim y cols [50] incluyeron 22 estudios que cumplieron los criterios de inclusión, abarcando a 19.580 pacientes. Los sistemas de alerta de sepsis se asociaron con una reducción del riesgo de mortalidad (RR, 0,78; IC del 95%, 0,67 a 0,92) y de la duración de la estancia hospitalaria. Estos sistemas también se asociaron con una mejor adherencia a los elementos del paquete de medidas de sepsis, especialmente en términos de menor tiempo hasta la administración de líquidos, hemocultivo, administración de antibióticos y medición de lactato.

Existe un elevado número de estudios sobre la IA en sepsis [51]. En la tabla 6 se incluyen algunos seleccionados con multiples modelos de IA, , tan solo para orientación del lector.

Tabla 6. Algunos estudios sobre IA y Sepsis

ESTUDIO	AÑO	MODELO DE IA	PROPÓSITO PRINCIPAL
Boussina et al.[52]	2024	Deep Learning (COMPOSER)	Evaluar impacto real en supervivencia y calidad de atención
Pappada et al.[53]	2024	MLP (red neuronal)	Detección y predicción de riesgo en pacientes UCI
Bhargava et al.[54]	2024	Random Forest calibrado	Predecir sepsis dentro de 24 h; estratificación de riesgo
Kijpaisalratana et al.[55]	2024	Random Forest	Mejorar diagnóstico y tiempo de antibióticos en urgencias
Park SW et al.[56]	2024	CatBoost, XGBoost, LightGBM	Predecir mortalidad en urgencias con ML interpretable
Zhang et al.[57]	2024	XGBoost	Predecir mortalidad con biomarcadores inflamatorios
Wang L et al.[58]	2024	ANN	Predecir mortalidad en niños con sepsis en UCI pediátrica
Ates et al.[59]	2024	MLMs diversos	Evaluar impacto del monitoreo terapéutico de fármacos
Valik et al.[60]	2023	SepsisFinder (red probabilística)	Reconocer sepsis antes que NEWS2 usando EHR
Jiang et al. [61]	2023	LR, GBDT (XGBoost)	Análisis en tiempo real de factores de riesgo y fenotipos
Aguirre y Urrechaga[62]	2022	NB, KNN, SVM, RF, MLP, XGBoost	Comparar modelos para diagnóstico de sepsis en urgencias
Park YJ et al.[63]	2022	LASSO, RF, XGBoost, DNN, Super Learner	Predecir mortalidad hospitalaria en pacientes con sepsis
Adams et al.[64]	2022	TREWS (sistema de alerta en tiempo real)	Evaluar resultados tras implementación del sistema
Henry et al.[65]	2022	TREWS	Estudiar adopción por parte de los profesionales y tiempos de respuesta
Shashikumar et al.[66]	2021	DeepAISE (RNN + Cox)	Predicción interpretativa de sepsis hasta 12 h antes
Persson et al.[67]	2021	CNN (NAVOY Sepsis)	Modelo aplicable a UCIs europeas para predicción temprana
Taneja et al.[68]	2021	Random Forest	Diagnóstico y pronóstico usando biomarcadores y EHR
Wang D. et al.[69]	2021	Random Forest	Diagnóstico precoz en pacientes de UCI
Rodríguez et al.[70]	2021	Árbol C4.5, RF, ANN, SVM	Comparar modelos para clasificar y predecir mortalidad
Li et al.[71]	2021	GBDT, LR, KNN, RF, SVM	Comparar modelos para predecir mortalidad en UCI
Bataille et al.[72]	2021	CART, PLS, NNET, LDA	Predecir respuesta a fluidos en sepsis grave o shock séptico
Song et al.[73]	2021	Gradient Boosting Machine	Identificar factores clínicos que predicen tratamiento rápido
Yang et al.[74]	2020	XGBoost	Predicción en tiempo real con explicaciones clínicas
Lauritsen et al.[75]	2020	CNN-LSTM	Detección temprana con datos secuenciales de EHR
Burdick et al.[76]	2020	XGBoost	Reducir mortalidad, estancia hospitalaria y reingresos
Zheng et al.[77]	2020	XGBoost + selección de variables	Diagnóstico y diferenciación de infecciones con biomarcadores
Giannini et al.[78]	2019	Random Forest	Predecir sepsis severa y shock séptico; evaluar impacto clínico
Barton et al.[79]	2019	XGBoost	Predecir aparición de sepsis hasta 48 h antes

Aplicación de inteligencia artificial en el diagnóstico precoz de sepsis BI Alert

El sistema **BI Alert** (Business Intelligence Alert) [80] nace de la colaboración del IIC (Instituto de Ingeniería del Conocimiento) con el Hospital Universitario Son Llátzer y la Fundación Instituto de Investigación Sanitaria Illes Balears. Es una plataforma de inteligencia artificial diseñada para el entorno hospitalario, que integra conocimientos médicos y algoritmos de análisis avanzado de datos clínicos para la detección precoz de condiciones críticas, con especial relevancia en sepsis y deterioro agudo del paciente. BI Alert combina la experiencia clínica con técnicas de inteligencia artificial (como el aprendizaje automático) para analizar, en tiempo real, grandes volúmenes de datos provenientes de historias clínicas electrónicas. El fundamento metodológico se basa en el análisis de hasta 200 variables clínicas relevantes —hemogramas, constantes vitales, marcadores bioquímicos, resultados de laboratorio y parámetros fisiopatológicos—, identificando correlaciones complejas que pueden escapar al reconocimiento humano clásico. El sistema se conecta periódicamente (cada 30 minutos) a los registros clínicos de todos los pacientes hospitalizados, sin requerir intervención manual adicional del personal sanitario, y emite alertas automáticas cuando detecta cambios sugestivos de un evento crítico como sepsis o shock. La plataforma busca superar las limitaciones de los algoritmos basados únicamente en reglas fijas, logrando reducir la tasa de falsos positivos y falsos negativos gracias a la inferencia en base a patrones extraídos de datos históricos reales. Sistemas como BI Alert han demostrado una capacidad predictiva del 96% para anticipar la aparición de sepsis hasta 24 horas antes que los protocolos tradicionales, emitiendo alertas en tiempo real al personal sanitario. Esto ha permitido reducir la mortalidad y los falsos positivos en el diagnóstico de sepsis.

Sus principales ventajas se encuentran en la siguiente tabla 7.

Tabla 7. Ventajas del sistema BI Alert en el manejo de la sepsis

CATEGORÍA	VENTAJA	DESCRIPCIÓN
Funcional	Capacidad predictiva del 96%	Detecta pacientes en riesgo mediante algoritmos entrenados con grandes volúmenes de datos clínicos.
Funcional	Alertas en tiempo real	Notifica de inmediato a los profesionales sanitarios, permitiendo intervenciones precoces.
Funcional	Reducción de la mortalidad	Mejora la supervivencia al facilitar una actuación temprana ante los primeros signos de sepsis.
Funcional	Disminución de falsos positivos	Mejora la especificidad de las alertas, reduciendo tratamientos innecesarios y optimizando recursos.
Impacto clínico	Diagnósticos más rápidos y precisos	Acelera la identificación de sepsis con mayor exactitud, especialmente en urgencias y UCI.
Impacto clínico	Mejora en la eficiencia del flujo de trabajo clínico	Reduce demoras en la atención y facilita la priorización de casos críticos.
Impacto clínico	Mejor pronóstico y sobrevida de los pacientes	La detección y tratamiento tempranos se traducen en mejores resultados clínicos para los pacientes.

En las últimas décadas, el Machine Learning y otras herramientas de IA han explorado también ampliamente la sepsis, con modelos desarrollados para la detección temprana, el diagnóstico, el pronóstico e incluso la gestión en tiempo real de las estrategias de tratamiento. Bignami y cols analizan las diferentes publicaciones con el objetivo de proporcionar una descripción general de la aplicación de la IA en el manejo de la sepsis, revisando los principales estudios y metodologías utilizadas para evaluar su efectividad, limitaciones y potencial futuro [81].

4.2.2.3 Accidente cerebrovascular (ACV)

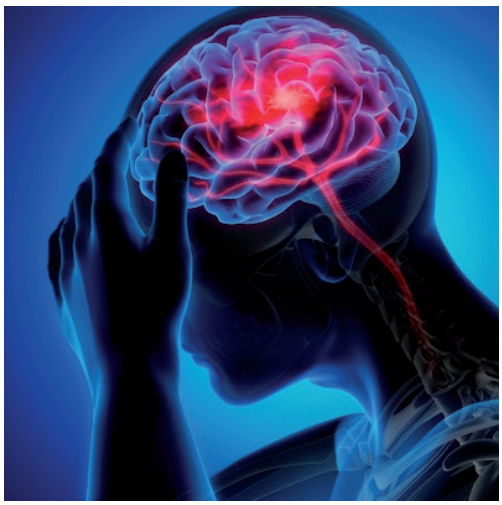


Imagen 8

La introducción de la inteligencia artificial (IA) en el manejo del ictus ha transformado de manera significativa tanto el diagnóstico precoz como la toma de decisiones terapéuticas, aportando rapidez y precisión en escenarios donde cada minuto es crucial para el pronóstico neurológico del paciente. Su impacto abarca distintas etapas de la atención, desde la identificación automática de oclusiones arteriales hasta la evaluación del grado de circulación colateral, optimizando la selección de pacientes para tratamientos de reperfusión.

4.2.2.3.1 Identificación Automatizada de Oclusiones Arteriales

La IA permite la detección rápida y precisa de oclusiones de grandes vasos cerebrales mediante algoritmos entrenados con imágenes de tomografía computarizada (TC) y resonancia magnética (RM). Por ejemplo, el software Methinks LVO ha demostrado detectar oclusiones en los vasos cerebrales en menos de dos minutos y con una tasa de detección superior al análisis convencional de neuroradiólogos expertos [82]. Además, la IA puede procesar imágenes de TC sin contraste, facilitando el diagnóstico en centros con tecnología limitada y evitando traslados innecesarios que retrasan el inicio del tratamiento.

Esta automatización es especialmente valiosa en los hospitales de menor tamaño, donde la interpretación de imágenes por personal experimentado puede no estar disponible durante todo el día, y ayudar a ganar hasta dos horas en la administración del tratamiento endovascular en comparación con los flujos tradicionales.

4.2.2.3.2 Evaluación del Grado de Circulación Colateral

La determinación del estado de la circulación colateral cerebral —es decir, la capacidad de los vasos secundarios para suplir el territorio cerebral afectado— es un factor pronóstico fundamental en el ictus isquémico. Las herramientas de IA permiten una evaluación rápida y objetiva del grado de circulación colateral a partir de imágenes de TC perfusión o angio-TC, superando la variabilidad observador-dependiente de la valoración humana y facilitando la implementación de escalas pronósticas avanzadas en la práctica clínica [83]. La valoración precisa de la circulación colateral es esencial, dado que un

buen estado colateral se asocia a una mayor cantidad de tejido cerebral salvable y mejores resultados funcionales tras la reperfusión, particularmente en pacientes tratados mediante trombectomía mecánica.

4.2.2.3.3 Optimización de la Selección de Pacientes para Tratamientos de Reperfusión

El uso de IA en la interpretación de neuroimágenes permite identificar con mayor rapidez y fiabilidad a los pacientes candidatos a terapia de reperfusión (trombólisis o trombectomía), eliminando dudas sobre la extensión de la lesión isquémica y la viabilidad del tejido cerebral. Softwares como RapidAI [84] y MethinksLVO [85]ofrecen mapas de perfusión cerebral y cuantifican el volumen de tejido infartado y en riesgo, orientando la selección del paciente incluso más allá de la tradicional "ventana terapéutica" de 6 horas.

La IA también ha comenzado a integrarse en el **triaje prehospitalario**. Algoritmos aplicados en ambulancias pueden, según estudios recientes, aumentar en un 20% el acceso a terapia endovascular y adelantarse hasta en 2 horas en la administración del tratamiento, incrementando significativamente las posibilidades de recuperación neuronal [86].

4.2.2.3.4 Reducción de los Tiempos de Actuación

La rapidez contribuye de forma decisiva al pronóstico neurológico del paciente con ictus. El uso de IA permite acortar los tiempos desde el diagnóstico a la intervención. En grandes hospitales, la integración de software de IA ha permitido acelerar el proceso diagnóstico en torno a 15 minutos; en hospitales comarcales o zonas rurales, esto puede suponer hasta dos horas de adelanto en la administración del tratamiento, repercutiendo positivamente en la equidad de acceso a terapias avanzadas para la población rural o de difícil acceso[87]. La reducción del tiempo entre llegada al hospital e inicio del tratamiento ha sido un objetivo clave en los últimos años, y la IA es una herramienta central para acortar estos lapsos y mejorar el pronóstico global del ictus.

4.2.2.3.5 Perspectivas Futuras y Limitaciones

A pesar de los avances, la sensibilidad de los algoritmos de IA aún debe mejorar para la detección de oclusiones más distales y en circulación posterior, áreas donde la experiencia del radiólogo sigue siendo imprescindible. Además, es importante que avancemos en la integración ética, la validación multicéntrica y la supervisión médica que siguen siendo elementos insustituibles en la cadena asistencial.

4.3 RECOMENDACIONES TERAPEUTICAS



Imagen 9

La integración de la inteligencia artificial (IA) en los servicios de urgencias persigue varios objetivos clave que mejoran la atención médica, la eficiencia del sistema y la seguridad del paciente. Entre estos objetivos, los sistemas de apoyo en la toma de decisiones terapéuticas y la prevención de errores relacionados con medicamentos son especialmente relevantes.

4.3.1 Optimización de la Toma de Decisiones Terapéuticas

La IA facilita la evaluación automatizada de la información clínica del paciente —incluyendo historial médico, resultados de pruebas y parámetros fisiológicos— para sugerir tratamientos personalizados. Los algoritmos pueden analizar grandes volúmenes de datos y proponer el tratamiento más adecuado según guías clínicas y evidencia científica actualizada, ayudando a seleccionar tanto los fármacos como las dosis óptimas para cada caso individual [88].

Recomendación de tratamientos personalizados:
Mediante el análisis de bases de datos clínicas y evidencia científica, los sistemas de IA pueden identificar cuál es el tratamiento más eficaz para un paciente concreto, considerando comorbilidades, alergias y posibles contraindicaciones. Los métodos de medicina de precisión identifican fenotipos de pacientes con respuestas menos frecuentes al tratamiento o con necesidades de atención médica únicas. La IA genera información, permite que el sistema razone y aprenda, y potencia la toma de decisiones clínicas mediante inteligencia aumentada. La literatura reciente sugiere que la investigación traslacional que explora esta convergencia ayudará a resolver los desafíos más complejos que enfrenta la medicina de precisión, especialmente aquellos en los que los determinantes genómicos y no genómicos, combinados con la información de los síntomas, el historial clínico y el estilo de vida del paciente, facilitarán el diagnóstico y el pronóstico personalizados [89].

- Apoyo en el ajuste de dosis**:** Especialmente útil en pacientes pediátricos, ancianos o con insuficiencia renal/hepática, donde el cálculo correcto de la dosis es vital para evitar efectos adversos. La farmacología intervencionista es una de las armas más potentes de la medicina contra las enfermedades. Sin embargo, estos fármacos pueden provocar efectos secundarios perjudiciales y deben monitorizarse estrechamente. La farmacovigilancia es el campo científico que monitoriza, detecta y previene las reacciones adversas a medicamentos (RAM). Las iniciativas de seguridad comienzan durante el proceso de desarrollo, mediante estudios in vivo e in vitro, continúan durante los ensayos clínicos y se extienden a la vigilancia poscomercialización en poblaciones reales. Los futuros desafíos en materia de toxicidad y seguridad, como el aumento de la polifarmacia y la diversidad de pacientes, ponen en evidencia los límites de estas herramientas tradicionales. La enorme cantidad de datos recientemente disponibles presenta una oportunidad para utilizar la inteligencia artificial y el aprendizaje automático para mejorar la ciencia de la seguridad de los medicamentos. La farmacovigilancia poscomercialización se basa en diversas fuentes de datos, como bases de datos moleculares, quimioinformáticas y clínicas, así como redes sociales y literatura biomédica.Los métodos de procesamiento del lenguaje natural (PLN) impulsados por aprendizaje profundo, que incluyen incrustaciones de palabras y mecanismos de atención, son las técnicas elegidas para extraer relaciones entre medicamentos y eventos adversos (EA) en datos de texto [90].

- Segunda opinión clínica automática: Herramientas como **Drug-GPT** pueden presentar distintas alternativas terapéuticas y la justificación de cada una, facilitando la toma de decisiones en escenarios bajo presión y alta rotación de cuadros clínicos. Drug-GPT es un modelo de lenguaje basado en inteligencia artificial diseñado específicamente para tareas relacionadas con farmacología, interacciones medicamentosas, y recomendaciones terapéuticas. Es una aplicación especializada de la arquitectura GPT (como ChatGPT), entrenada o afinada con grandes cantidades de información biomédica y farmacológica. Las características principales de Drug-GPT son:
  - Identificación de medicamentos: Reconoce principios activos, nombres comerciales y genéricos.
  - Recomendaciones clínicas: Ofrece sugerencias sobre dosis, vías de administración, y ajustes por edad o función renal/hepática.
  - Detección de interacciones: Informa posibles interacciones medicamentosas o contraindicaciones.
  - Apoyo a la toma de decisiones clínicas: Puede actuar como sistema de soporte para médicos, especialmente en entornos de urgencias o cuidados intensivos.
  - Consulta de guías y literatura biomédica: Se entrena con fuentes como PubMed, DrugBank, FDA, y guías clínicas actualizadas.

Hemos preguntado a Chat GPT la comparación entre los diversos modelos de IA médicas (Tabla 8):

Tabla 8. Comparativa de Modelos de IA Médica

MODELO	ENFOQUE PRINCIPAL	FUENTE DE ENTRENAMIENTO	CASOS DE USO	LIMITACIONES
Drug-GPT	IA enfocada en farmacología clínica e interacciones medicamentosas	Literatura biomédica, DrugBank, guías clínicas, fichas técnicas de medicamentos	Apoyo en prescripción médica, revisión farmacológica, alertas de interacciones	Puede carecer de contexto clínico completo; requiere supervisión médica
Med-PaLM	IA médica generalista con enfoque en comprensión de preguntas clínicas complejas	Preguntas médicas reales, literatura médica revisada por pares (como UMLS, MedQA)	Respuestas a preguntas médicas, educación médica, soporte clínico general	No especializado en farmacología profunda; riesgo de alucinaciones médicas
BioGPT	IA biomédica especializada en procesamiento de lenguaje natural científico	Artículos biomédicos de PubMed (abstracts científicos)	Extracción de información científica, clasificación de textos biomédicos	No diseñado para aplicaciones clínicas directas; más orientado a investigación

4.3.2 Alerta de Interacciones Medicamentosas y Alergias

Uno de los mayores riesgos en el ámbito de urgencias es la polimedicación, y el escaso tiempo para revisar el historial farmacológico del paciente. La IA aporta soluciones para la detección temprana de posibles interacciones negativas y alergias [91].

- Identificación de interacciones farmacológicas: Algoritmos avanzados exploran al instante las combinaciones de medicamentos prescritos, advirtiendo al equipo

médico sobre posibles interacciones adversas, incompatibilidades o duplicidades.
- Detección de alergias y reacciones cruzadas**:** Los sistemas de IA consultan automáticamente el historial médico en busca de alergias documentadas o patrones de riesgo, contribuyendo así a evitar errores de prescripción potencialmente críticos.
- Alertas automáticas integradas en sistemas informáticos hospitalarios**:** Bases de datos como Merative Micromedex ISI®[92] o plataformas de farmacia clínica permiten generar alertas visuales en tiempo real ante posibles problemas con la medicación, considerando variables como edad, sexo, comorbilidades y antecedentes alérgicos.

4.3.3 Seguridad y Reducción de Errores

La aplicación de IA en urgencias no solo acelera los procesos, sino que minimiza fallos asociados al cansancio, presiones asistenciales y sesgos cognitivos. Los estudios recientes indican:
- Detección precoz de errores de administración o dosificación**:** Modelos predictivos identifican recetas inusuales, dosis fuera de rango o incompatibles con el perfil del paciente.
- Prevención de reacciones adversas**:** Herramientas predictivas permiten anticipar eventos adversos y tomar medidas antes de que se produzcan, especialmente en pacientes polimedicados [93].

4.3.4 Aplicaciones Clínicas en la farmacovigilancia

La integración de IA ha demostrado reducir los tiempos de respuesta, aumentar la precisión en la selección de tratamientos y disminuir la incidencia de errores médicos en escenarios de alta presión asistencial. La tabla 9 incluida resume algunas de las aplicaciones más representativas actualmente en uso o en evaluación avanzada:

Drug-GPT, desarrollado por la Universidad de Oxford, actúa como un asistente de prescripción médica, ayudando a los profesionales a seleccionar dosis adecuadas y detectar posibles interacciones. Ya ha sido probado en hospitales del NHS británico con resultados prometedores.
PharmacyGPT representa una innovación enfocada en entornos críticos como las unidades de cuidados intensivos. Este modelo permite evaluar combinaciones terapéuticas y anticipar efectos adversos, utilizando datos clínicos reales para reforzar la toma de decisiones.
HELIOT es un sistema especializado en la detección de alergias medicamentosas a través de modelos lingüísticos. Ha demostrado una precisión excepcional en entornos simulados, siendo una solución útil para evitar errores potencialmente graves.
TxAgent, por su parte, incorpora inteligencia artificial avanzada para recomendar tratamientos personalizados. Integra múltiples fuentes de datos (farmacocinética, guías clínicas, moléculas) y ha superado pruebas comparativas frente a otros modelos de lenguaje.

Los **sistemas de soporte clínico (CDSS)** ya forman parte de las farmacias hospitalarias en muchos centros europeos. Estos algoritmos monitorean constantemente perfiles farmacológicos, antecedentes clínicos y parámetros analíticos, generando alertas sobre interacciones o ajustes posológicos necesarios.
En un ámbito más regulador, agencias como la EMA y la FDA están utilizando IA para tareas de farmacovigilancia activa, como la detección precoz de señales de seguridad a partir de datos del mundo real. Un hito en este campo es **cderGPT**, proyecto conjunto con OpenAI, que ha completado recientemente la primera

revisión automatizada de documentación para evaluación de medicamentos.
En conjunto, estas herramientas reflejan un avance significativo en la seguridad farmacológica y en la eficiencia del acto terapéutico, demostrando que la IA no solo mejora procesos clínicos, sino que contribuye directamente a la calidad asistencial y a la prevención de eventos adversos.

Tabla 9. Ejemplos de Aplicaciones Clínicas de IA en Farmacovigilancia [94-100]

APLICACIÓN / PROYECTO	FUNCIONALIDAD PRINCIPAL	ESTADO DE IMPLEMENTACIÓN	ORGANIZACIÓN / FUENTE
Drug-GPT	Asistencia en la prescripción, alertas de interacciones	Piloto en hospitales del NHS (UK)	Universidad de Oxford
PharmacyGPT	Evaluación de combinaciones fármaco-paciente crítico	Validación en entorno UCI	UNC Chapel Hill
HELIOT	Detección de alergias a medicamentos mediante IA	Validación sintética y académica	Investigadores independientes (arXiv)
TxAgent	Recomendaciones terapéuticas personalizadas con IA	Modelo validado con benchmarks clínicos	TxA Foundation (arXiv)
CDSS hospitalarios	Análisis de interacciones y ajustes posológicos	Uso activo en hospitales europeos	Implementación hospitalaria
Farmacovigilancia por IA	Detección de señales de seguridad en tiempo real	Aplicación regulatoria en curso	EMA / FDA / UE
cderGPT	Revisión asistida por IA para evaluación de fármacos	Primera revisión completada	FDA y OpenAI

4.4 SEGUIMIENTO EN TIEMPO REAL

Entre los objetivos principales de la implementación de la inteligencia artificial (IA) en los servicios de urgencias hospitalarias destacan el seguimiento en tiempo real y el desarrollo de sistemas de alerta para predecir descompensaciones agudas en pacientes.

4.4.1 Seguimiento en tiempo real y monitorización continua de parámetros vitales

La capacidad de la IA para monitorizar de manera continua los parámetros vitales de los pacientes en entornos de urgencias permite una detección precoz de alteraciones críticas. Esta monitorización se realiza gracias al uso de



Imagen 10

sensores portátiles y algoritmos avanzados que analizan datos como la frecuencia cardíaca, la presión arterial, la saturación de oxígeno y la temperatura corporal en tiempo real.
Entre las ventajas de la monitorización continua mediante IA destacan:

- Detección temprana de desviaciones en los signos vitales, incluso antes de que se manifiesten clínicamente.
- Reducción de los tiempos de intervención médica ante eventos agudos.
- Seguimiento integral del estado de salud, útil en pacientes críticos, crónicos o con patologías inestables.
- Transmisión remota y almacenamiento de datos para el acceso inmediato por parte del equipo sanitario, mejorando la coordinación y la toma de decisiones.
- Gestión y ubicación precisa de los pacientes en tiempo real a través de tecnología portable y sistemas de posicionamiento.

En las tablas siguientes(Tablas 10-16) podemos ver diferentes dispositivos portátiles de salud que pueden aplicarse a diferentes partes del cuerpo, para detectar una amplia gama de signos vitales lo que facilitará el triaje prehospitalario (traslado) y en su llegada a urgencias [101].

Tabla 10. Dispositivos de Salud Portátiles de Electroencefalograma (EEG)

POTENCIAL EN EL ENTORNO PREHOSPITALARIO	APLICACIONES DE APOYO A LA DECISIÓN CLÍNICA	LIMITACIONES ACTUALES
• Detección de lesiones cerebrales traumáticas en el lugar del accidente	• Diagnóstico de enfermedades cerebrales • Evaluación de la función cognitiva • Detección y manejo del estrés	• Requiere contacto adecuado y fiable de los electrodos con el cuero cabelludo • Menor número de electrodos que los estándares internacionales • Alta susceptibilidad al ruido de señal y artefactos

Tabla 11. Dispositivos Portátiles de Fotopletismografía (PPG)

POTENCIAL EN EL ENTORNO PREHOSPITALARIO	APLICACIONES DE APOYO A LA DECISIÓN CLÍNICA	LIMITACIONES ACTUALES
• Predicción de arritmias ventriculares inminentes • Predicción de descompensación antes del shock hemorrágico • Predicción no invasiva de la presión arterial • Monitorización respiratoria	• Mejora del diagnóstico de preeclampsia • Predicción del estado de sueño para clasificar la gravedad de la apnea del sueño • Evaluación del grado de estenosis vascular	• Susceptible a artefactos por movimiento • Susceptible a factores ambientales • Requiere colocación en ubicaciones específicas para mayor precisión

Tabla 12. Dispositivos de Imagen Médica Portátiles

POTENCIAL EN EL ENTORNO PREHOSPITALARIO	APLICACIONES DE APOYO A LA DECISIÓN CLÍNICA	LIMITACIONES ACTUALES
• Imagen continua de órganos internos para evaluación de hemorragias o perfusión • Evaluación de la velocidad del flujo sanguíneo mediante tecnología Doppler	• Diagnóstico automatizado de hemorragia abdominal, neumotórax, y muchas otras lesiones internas	• Menor resolución que los sistemas clínicos de ultrasonido • Problemas de artefactos en la imagen, especialmente durante el movimiento • El sensor debe colocarse adecuadamente para proporcionar información médica relevante

Tabla 13. Dispositivos Químicos Portátiles

POTENCIAL EN EL ENTORNO PREHOSPITALARIO	APLICACIONES DE APOYO A LA DECISIÓN CLÍNICA	LIMITACIONES ACTUALES
• Monitorización en tiempo real de biomarcadores para obtener datos diagnósticos inmediatos. • Reducción de la dependencia de pruebas de laboratorio que no están disponibles en el entorno prehospitalario.	• Evaluación automatizada del shock hemorrágico mediante monitorización de lactato. • Impulso de planes médicos personalizados y dinámicos utilizando biomarcadores.	• Especificidad y sensibilidad limitadas para ciertos biomarcadores. • Limitaciones de tamaño para algunos procesos químicos. • Desafíos para mantener la calibración durante el uso prolongado.

Tabla 14. Dispositivos Portátiles de Electrocardiograma (ECG)

POTENCIAL EN EL ENTORNO PREHOSPITALARIO	APLICACIONES DE APOYO A LA DECISIÓN CLÍNICA	LIMITACIONES ACTUALES
• Detección de problemas cardíacos que pueden causar paro cardíaco y muerte súbita.	• Predicción de múltiples tipos de arritmias. • Diagnóstico mejorado de la fibrilación auricular. • Predicción del riesgo de hospitalización por insuficiencia cardíaca.	• Dependencia de una colocación adecuada para una lectura precisa del ECG. • El sitio de colocación puede causar irritación en la piel.

Tabla 15. Dispositivos Portátiles de Sismocardiograma (SCG)

POTENCIAL EN EL ENTORNO PREHOSPITALARIO	APLICACIONES DE APOYO A LA DECISIÓN CLÍNICA	LIMITACIONES ACTUALES
• Mediciones cardíacas en tiempo real que no se pueden obtener fácilmente con otras tecnologías, como los tiempos de eyección sanguínea y la función de las válvulas cardíacas.	• Evaluación de fibrilación auricular, condiciones cardíacas irregulares e isquemia. • Evaluación de afecciones cardíacas crónicas no traumáticas.	• Los artefactos por movimiento del paciente pueden afectar las señales del acelerómetro. • El filtrado de artefactos de ruido en la biosenal requiere amplios recursos computacionales.

Tabla 16. Dispositivos Portátiles de Temperatura

POTENCIAL EN EL ENTORNO PREHOSPITALARIO	APLICACIONES DE APOYO A LA DECISIÓN CLÍNICA	LIMITACIONES ACTUALES
• Detección de enfermedades relacionadas con el calor, sepsis e infecciones. • Puede permitir una administración más temprana de líquidos, antibióticos y otros tratamientos.	• Estimación de la temperatura corporal central a partir de la temperatura superficial. • Predicción de fiebre e inflamación mediante monitoreo continuo de la temperatura.	• Precisión reducida en temperaturas extremas. • Susceptible al ruido causado por el sudor y el movimiento. • Dependencia de una colocación adecuada para una lectura precisa de la temperatura.

4.4.2 Generación de alertas predictivas ante descompensaciones

Los sistemas de alerta temprana basados en IA están revolucionando la atención sanitaria al permitir a los profesionales de la salud anticiparse a eventos graves como paradas cardiorrespiratorias o ingresos no planificados en la UCI y tomar medidas preventivas con

alta precisión. Estos sistemas integran datos clínicos, imágenes médicas, registros electrónicos y patrones epidemiológicos para generar alertas oportunas, mejorando los resultados de los pacientes Emplean algoritmos que procesan grandes volúmenes de datos clínicos y fisiológicos para anticipar episodios de descompensación [88].

4.2.2.1 Aportaciones de las alertas predictivas

- Predicción de eventos críticos con antelación (hasta 1 mes en algunos algoritmos).
- Reducción de falsos positivos mediante el uso combinado de diversos parámetros vitales y de actividad física.
- Intervención preventiva y personalizada acorde con la evolución y el riesgo individual del paciente.
- Optimización de los recursos hospitalarios al priorizar la atención de quienes presentan mayor riesgo de descompensación.
- Documentación y registro automatizado de alertas y variables clínicas para futuras acciones y análisis estadístico.

4.2.2.2 Ejemplos de sistemas de alerta predictiva (Tabla 17)

El sistema **HeartLogic** analiza parámetros como el tono cardíaco, la impedancia torácica, la función respiratoria, la actividad física y la frecuencia cardíaca para predecir episodios de insuficiencia cardíaca con una antelación de hasta un mes. Este sistema es particularmente útil para el monitoreo de pacientes con insuficiencia cardíaca, ya que permite intervenir antes de que ocurran complicaciones graves [102].

Por su parte, el **Early Warning Score (EWS)** utiliza un enfoque multiparamétrico que incluye diversos signos vitales, la edad del paciente y sus comorbilidades. Este sistema puede prever deterioros clínicos con una antelación superior a las 8 horas, lo que lo hace especialmente valioso para identificar pacientes en riesgo de requerir traslados no planificados a la unidad de cuidados intensivos (UCI) [103].

El sistema **SepsisWatch** monitorea signos vitales, como la frecuencia cardíaca y la presión arterial, junto con análisis de sangre y registros electrónicos de salud para predecir la sepsis en pacientes hospitalizados con 4 a 6 horas de antelación. Este enfoque permite a los sanitarios iniciar tratamientos como antibióticos o soporte hemodinámico de manera preventiva, reduciendo la mortalidad [104].

Por otro lado, **AIDx** utiliza redes neuronales profundas para analizar imágenes de diagnóstico, como radiografías y tomografías, junto

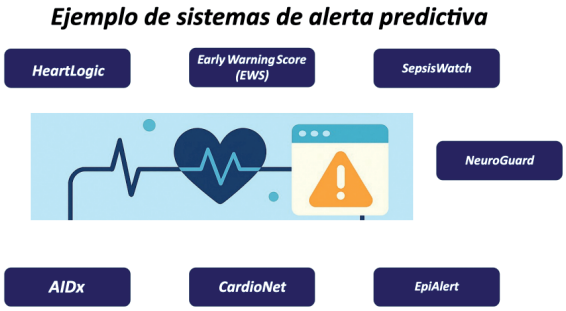


Imagen 11

con datos clínicos y biomarcadores, detectando enfermedades críticas como neumonía o cáncer con horas o días de aviso. Este sistema ha demostrado una precisión comparable a la de radiólogos expertos, facilitando diagnósticos rápidos y priorización de casos [105].

CardioNet se especializa en la predicción de eventos cardiovasculares, como infartos o fibrilación auricular, analizando electrocardiogramas, historiales médicos y datos demográficos. Con una antelación de minutos a horas, permite a los sanitarios implementar intervenciones como anticoagulantes o ajustes terapéuticos, mejorando los resultados cardiovasculares [106].

En el ámbito de la salud pública, **EpiAlert** analiza datos epidemiológicos, patrones de movilidad humana, registros hospitalarios y redes sociales para detectar brotes de enfermedades infecciosas con días o semanas de antelación. Este sistema apoya la preparación de sistemas de salud mediante la asignación de recursos y campañas de prevención [107].

Finalmente, **NeuroGuard** emplea signos vitales, imágenes cerebrales y patrones de actividad cerebral para predecir eventos neurológicos, como accidentes cerebrovasculares, con horas de aviso, permitiendo intervenciones rápidas como trombolíticos para minimizar daños [108].

Tabla 17. Sistemas de Alerta Temprana Basados en IA para Sanitarios

SISTEMA	PARÁMETROS ANALIZADOS	ANTELACIÓN EN PREDICCIÓN	APLICABILIDAD PRINCIPAL	REFERENCIA
HeartLogic	Tono cardíaco, impedancia torácica, respiración, actividad física, frecuencia cardíaca	Hasta 1 mes	Insuficiencia cardíaca	Boehmer JP, y cols. [102]
Early Warning Score (EWS)	Signos vitales, edad, comorbilidades	Más de 8 horas	Traslados a UCI	Escobar GJ, y cols. [103]
SepsisWatch	Signos vitales, análisis de sangre, registros electrónicos de salud	4 a 6 horas	Predicción de sepsis	Nemati S, y cols. [104]
AIDx	Imágenes diagnósticas, datos clínicos, biomarcadores	Horas a días	Detección de enfermedades críticas	Hwang EJ, y cols. [105]
CardioNet	Electrocardiogramas, historial médico, datos demográficos	Minutos a horas	Eventos cardiovasculares	Liu WT, y cols. [106]
EpiAlert	Datos epidemiológicos, movilidad humana, registros, redes sociales	Días a semanas	Brotes infecciosos	McKee M, y cols. [107]
NeuroGuard	Signos vitales, imágenes cerebrales, actividad cerebral	Horas	Eventos neurológicos	Schwartz L, y cols [108]

4.4.3. Desafíos para Implementar Sistemas de Seguimiento en Tiempo Real con IA en Urgencias [109, 110]

La introducción de sistemas de IA para el seguimiento continuo de pacientes en servicios de urgencias brinda notables oportunidades, pero también enfrenta diversos retos. A continuación se detallan los principales desafíos[111] que deben ser superados para una integración eficaz:

Calidad, Integración y Acceso a los Datos

- Interoperabilidad de sistemas: Muchos hospitales utilizan distintos sistemas de registro y monitorización que no siempre son compatibles, dificultando la consolidación y acceso a la información clave en tiempo real.
- Calidad de los datos: La precisión de los modelos de IA depende directamente de la integridad y veracidad de los datos recolectados. Datos incompletos, incorrectos o sesgados pueden llevar a fallos en el sistema de alerta o decisiones equivocadas.
- Flujos de datos robustos: Es indispensable contar con infraestructuras tecnológicas capaces de procesar grandes volúmenes de datos biomédicos de manera constante y segura.

Seguridad, Privacidad y Ética

- Privacidad del paciente: La protección de datos sensibles es un requisito fundamental. Se debe garantizar el cumplimiento de normativas de confidencialidad y manejo ético de la información clínica.
- Ciberseguridad: Los sistemas de IA pueden ser vulnerables a accesos no autorizados, manipulaciones o ataques cibernéticos, lo que pone en riesgo tanto la seguridad de los pacientes como la fiabilidad de los procesos.

Sesgo Algorítmico y Transparencia

- Sesgos en los modelos: El diseño y entrenamiento de algoritmos con datos sesgados puede llevar a errores sistemáticos en la priorización y manejo de pacientes, perpetuando desigualdades o discriminación.
- "Caja negra" de los algoritmos: La falta de transparencia en el funcionamiento de ciertos modelos de IA dificulta su aceptación por los clínicos, que pueden ser reacios a utilizar herramientas cuyo criterio no comprenden por completo.

Recursos Humanos, Formación y Aceptación

- Resistencia al cambio: El personal sanitario puede mostrar desconfianza o desconocimiento sobre el funcionamiento de la IA, lo que dificulta la adopción y aprovechamiento de los sistemas avanzados.
- Capacitación continua: Requiere formación específica, no solo técnica sino también ética y legal, que continúe adaptándose al desarrollo acelerado de estas tecnologías.

Coste e Infraestructura

- Inversión inicial elevada: La adquisición e implementación de sistemas de IA y monitorización avanzados puede suponer un coste elevado para muchos hospitales, especialmente en contextos con limitaciones de recursos.
- Actualización tecnológica: Es necesario mantener una infraestructura actualizada que soporte el crecimiento de datos y las nuevas versiones de los algoritmos de IA.

Regulación y Validación Clínica

- Normativas en evolución: La rápida evolución de la IA requiere marcos regulatorios flexibles y actualizados que aseguren la seguridad, responsabilidad y eficacia clínica de las aplicaciones.
- Validación multicéntrica: Muchos modelos requieren validaciones externas y multicéntricas para demostrar su aplicabilidad y efectividad en distintos entornos hospitalarios antes de una adopción masiva.

Estos desafíos deben abordarse de manera multidisciplinar, combinando avances tecnológicos, formación profesional y un marco ético y legal sólido para aprovechar al máximo el potencial de la IA en el seguimiento en tiempo real en urgencias.

Referencias

1. Grouse AI, Bishop RO, Bannon AM. The Manchester Triage System provides good reliability in an Australian emergency department. Emerg Med J. 2009 Jul;26(7):484-6.
2. Mirhaghi A, Heydari A, Mazlom R, Hasanzadeh F. Reliability of the Emergency Severity Index: Meta-analysis. Sultan Qaboos Univ Med J. 2015 Feb;15(1): e71-7.
3. Mirhaghi A, Heydari A, Mazlom R, Ebrahimi M. The Reliability of the Canadian Triage and Acuity Scale: Meta-analysis. N Am J Med Sci. 2015 Jul;7(7):299-305.
4. Park JB, Lee J, Kim YJ, Lee JH, Lim TH. Reliability of Korean Triage and Acuity Scale: Interrater Agreement between Two Experienced Nurses by Real-Time Triage and Analysis of Influencing Factors to Disagreement of Triage Levels. J Korean Med Sci. 2019 Jul 22;34(28): e189.
5. Grosgurin O, Gayet-Ageron A, Suppan L, Simon J, Villar A, Trombert V, Marti C, Sarasin FP, Rutschmann OT. Reliability and performance of the Swiss Emergency Triage Scale used by paramedics. Eur J Emerg Med. 2019 Jun;26(3):188-193.
6. Gómez Jiménez J, et al. Model Andorrà de Triatge (MAT). Hospital Nostra Senyora de Meritxell, Andorra la Vella. 2003 Disponible en: https://elenfermerodelpendiente.com/wp-content/uploads/2014/02/modelo_andorrano_de_triajemat.pdf
7. Sánchez Bermejo R, Ramos Miranda N, Sánchez Paniagua AB, Barrios Vicente E, Fernández Centeno E, Díaz Chaves MA, et al. Comparación de la capacidad de predecir hospitalización y consumo de recursos del Programa de Ayuda al Triaje 3M TAS y el Sistema Español de Triaje – Model Andorrà de Triaje (SET-MAT). Emergencias. 2016;28(1):21-5.
8. Soler W, Gómez J. El triaje: herramienta fundamental en urgencias y emergencias. An Sist Sanit Navar. 2010;33(Supl 1):55-68.
9. Triaje y Enfermería Disponible en: https://www.formacionalcala.com/articulos/73/triaje-y-enfermeria.
10. Gräff I, Goldschmidt B, Glien P, Bogdanow M, Fimmers R, Hoeft A, Kim SC, Grigutsch D. The German Version of the Manchester Triage System and its quality criteria--first assessment of validity and reliability. PLoS One. 2014 Feb 24;9(2):e88995.
11. Levin S, Toerper M, Hamrock E, Hinson JS, Barnes S, Gardner H, Dugas A, Linton B, Kirsch T, Kelen G. Machine-Learning-Based Electronic Triage More Accurately Differentiates Patients With Respect to Clinical Outcomes Compared With the Emergency Severity Index. Ann Emerg Med. 2018 May;71(5):565-574.e2.
12. Morrill J, Qirko K, Kelly J, Ambrosy A, Toro B, Smith T, Wysham N, Fudim M, Swaminathan S. A Machine Learning Methodology for Identification and Triage of Heart Failure Exacerbations. J Cardiovasc Transl Res. 2022 Feb;15(1):103-115.
13. Serrate Trigo S Triage Digital en Tiempo Real: Inteligencia Artificial en la Primera Línea de Emergencia. LinkedIn [Internet]. 2025 Disponible en: https://www.linkedin.com/pulse/triage-digital-en-tiempo-real-inteligencia-artificial-desingmed-0xcee/
14. Porto BM. Improving triage performance in emergency departments using machine learning and natural language processing: a systematic review. BMC Emerg Med. 2024 Nov 18;24(1):219.
15. Williams CW, Berthold J. Use of a large language model to assess clinical acuity among patients in the emergency department. JAMA Netw Open. 2024 May 7;7(5):e2412019.
16. Rajkomar A, Dean J, Kohane I. Machine learning in medicine. Nature. 2019;568(7753):193-5. doi:10.1038/d41586-019-01077-0.
17. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. Lancet Digit Health. 2019;1(1):e36-49. doi:10.1016/S2589-7500(19)30012-6.
18. Ribeiro AH, Ribeiro MH, Paixão GMM, Oliveira DM, Gomes PR, Canazart JA, Ferreira

M, Andersson CR, Macfarlane PW, Meira W Jr, Schön TB, Ribeiro ALP. Automatic diagnosis of the 12-lead ECG using a deep neural network. Nat Commun. 2020 Jul 21;11(1):1760.

19. Naved BA, Luo Y. Contrasting rule and machine learning based digital self triage systems in the USA. NPJ Digit Med. 2024;7:381.
20. Cortés S, Díaz Moya JR. Simulador de pre-triaje basado en clones clínicos: mejora del sistema de triaje en urgencias mediante inteligencia artificial. Disponible en: https://www.alhambrait.com/alhambra-health-y-el-hospital-general-la-mancha-centro-revolucionan-el-triaje-de-urgencias-hospitalarias-gracias-a-la-ia/
21. Centro de Emergencias Sanitarias 061 de Andalucía, Fundación Progreso y Salud (FPS) Disponible en: https://www.sspa.juntadeandalucia.es/servicioandaluzdesalud/ayudadigital/novedades/noticia/salud-inicia-el-proyecto-de-investigacion-triaje-dirigido-analizar-el-uso-de-la?utm_source=chatgpt.com
22. Instituto Tecnológico de Castilla y León (ITCL). Triage Smart Decision – AI Based COVID Triage System for Hospitals [Internet]. Burgos: ITCL; 4 Oct 202 Disponible en www.itcl.es
23. Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. Nat Med. 2019;25(1):24-29.
24. OpenAI. ChatGPT-4: Large Language Model for Natural Language Processing [Internet]. San Francisco (CA): OpenAI; 2023 [cited 2025 Feb 10]. Available from: https://openai.com/chatgpt
25. Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. Science. 2019;366(6464):447-453.
26. Rajkomar A, Hardt M, Howell MD, Corrado G, Chin MH. Ensuring fairness in machine learning to advance health equity. Annals of Internal Medicine. 2018;169(12):866-872.
27. European Parliament and Council of the European Union. Regulation (EU) 2016/679 (General Data Protection Regulation). Official Journal of the European Union. 2016.
28. Ailoitte. GDPR-Compliant AI in Healthcare: A Guide to Data Privacy. 2025 May 28 Journal of the European Union.
29. Laubenbacher R, Mehrad B, Shmulevich I, Trayanova N. Digital twins in medicine. Nat Comput Sci. 2024 Mar;4(3):184-191.
30. Da'Costa A, Teke J, Origbo JE, Osonuga A, Egbon E, Olawade DB. AI-driven triage in emergency departments: A review of benefits, challenges, and future directions. Int J Med Inform. 2025 May;197:105838.
31. Polevikov S. Advancing AI in healthcare: A comprehensive review of best practices. Clin Chim Acta. 2023 Aug 1;548:117519.
32. Kachman MM, Brennan I, Oskvarek JJ, Waseem T, Pines JM. How artificial intelligence could transform emergency care. Am J Emerg Med. 2024 Jul;81:40-46.
33. Rajkomar A, Dean J, Kohane I. Machine learning in medicine. N Engl J Med. 2019;380(14):1347-58.
34. Zhu H, Qiao S, Zhao D, Wang K, Wang B, Niu Y, Shang S, Dong Z, Zhang W, Zheng Y, Chen X. Machine learning model for cardiovascular disease prediction in patients with chronic kidney disease. Front Endocrinol (Lausanne). 2024 May 28;15:1390729.
35. Almustafa KM. Predictive modeling and optimization in dermatology: Machine learning for skin disease classification. Comput Biol Med. 2025 May;189:109946.
36. Choi A, Lee K, Hyun H, Kim KJ, Ahn B, Lee KH, Hahn S, Choi SY, Kim JH. A novel deep learning algorithm for real-time prediction of clinical deterioration in the emergency department for a multimodal clinical decision support system. Sci Rep. 2024 Dec 3;14(1):30116.
37. Dodig S, Čepelak I, Dodig M. Are we ready to integrate advanced artificial intelligence models in clinical laboratory? Biochem Med (Zagreb). 2025 Feb 15;35(1):010501. doi: 10.11613/BM.2025.010501
38. Wang Y, Kashyap R, Zhang P, Meng Q, Zhang Z. Editorial: Clinical application of artificial intelligence in emergency and critical care medicine, volume V. Front Med (Lausanne). 2025 Apr 11;12:1593416.

39. Rajpurkar P, Irvin J, Ball RL, et al. Deep learning for chest radiograph diagnosis: a retrospective comparison of the CheXNeXt algorithm to practicing radiologists. PLoS Med. 2018;15(11):e1002686.
40. Chilamkurthy S, Ghosh R, Tanamala S, et al. Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. Lancet. 2018;392(10162):2388-96.
41. Martínez-Sellés M, Marina-Breysse M. Current and Future Use of Artificial Intelligence in Electrocardiography. J Cardiovasc Dev Dis. 2023 Apr 17;10(4):175.
42. Bellfield RAA, Ortega-Martorell S, Lip GYH, Oxborough D, Olier I. Impact of ECG data format on the performance of machine learning models for the prediction of myocardial infarction. J Electrocardiol. 2024 May-Jun;84:17-26. doi: 10.1016/j.jelectrocard.2024.03.005
43. Ricci F, Martini C, Scordo DM, Rossi D, Gallina S, Fedorowski A, Sciarra L, Chahal CAA, Meyers HP, Herman R, Smith SW. ECG Patterns of Occlusion Myocardial Infarction: A Narrative Review. Ann Emerg Med. 2025 Apr;85(4):330-340.
44. Kim J, Shon B, Kim S, Cho J, Seo JJ, Jang SY, Jeong S. ECG data analysis to determine ST-segment elevation myocardial infarction and infarction territory type: an integrative approach of artificial intelligence and clinical guidelines. Front Physiol. 2024 Oct 7;15:1462847.
45. Naghashyar L. Improving Myocardial Infarction Detection via Synthetic ECG Pretraining. Proceedings of the 42nd International Conference on Machine Learning, Vancouver, Canada. PMLR 267, 2025.
46. Al-Zaiti S, Martin-Gill C, Zégre-Hemsey J, Bouzid Z, Faramand Z, Alrawashdeh M, et al. Machine learning for the ECG diagnosis and risk stratification of occlusion myocardial infarction at first medical contact. *Nat Med.* 2023;29(7):1804-13.
47. Attia ZI, Kapa S, Lopez-Jimenez F, McKie PM, Ladewig DJ, Satam G, et al. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. Nat Med. 2019;25(1):70-4.
48. Evans L, Rhodes A, Alhazzani W, et al. Surviving Sepsis Campaign: international guidelines for management of sepsis and septic shock 2021. Intensive Care Med. 2021;47(11):1181-1247.
49. Rhodes A, Evans LE, Alhazzani W, et al. Surviving Sepsis Campaign: international guidelines for management of sepsis and septic shock: 2016. Intensive Care Med. 2017;43(3):304-377.
50. Kim HJ, Ko RE, Lim SY, Park S, Suh GY, Lee YJ. Sepsis Alert Systems, Mortality, and Adherence in Emergency Departments: A Systematic Review and Meta-Analysis. JAMA Netw Open. 2024 Jul 1;7(7):e2422823.
51. Fleuren LM, Klausch TLT, Zwager CL, Schoonmade LJ, Guo T, Roggeveen LF, Swart EL, Girbes ARJ, Thoral P, Ercole A, Elbers PWG. Machine learning for the prediction of sepsis: a systematic review and meta-analysis of diagnostic test accuracy. Intensive Care Med. 2020 Mar;46(3):383-400.
52. Boussina, A.; Shashikumar, S.P.; Malhotra, A.; Owens, R.L.; El-Kareh, R.; Longhurst, C.A.; Quintero, K.; Donahue, A.; Chan, T.C.; Nemati, S.; et al. Impact of a deep learning sepsis prediction model on quality of care and survival. NPJ Digit. Med. 2024, 7, 14, Erratum in NPJ Digit. Med. 2024, 7, 153.
53. Pappada, S.M.; Owais, M.H.; Feeney, J.J.; Salinas, J.; Chaney, B.; Duggan, J.; Sparkle, T.; Aouthmany, S.; Hinch, B.; Papadimos, T.J. Development and validation of a sepsis risk index supporting early identification of ICU-acquired sepsis: An observational study. Anaesth. Crit. Care Pain. Med. 2024, 43, 101430.
54. Bhargava, A.; López-Espina, C.; Schmalz, L.; Khan, S.; Watson, G.L.; Urdiales, D.; Updike, L.; Kurtzman, N.; Dagan, A.; Doodlesack, A.; et al. FDA-Authorized AI/ML Tool for Sepsis Prediction: Development and Validation. NEJM AI 2024, 1, 1–12.
55. Kijpaisalratana, N.; Saoraya, J.; Nhuboonkaew, P.; Vongkulbhisan, K.; Musikatavorn,

K. Real-time machine learning-assisted sepsis alert enhances the timeliness of antibiotic administration and diagnostic accuracy in emergency department patients with sepsis: A cluster-randomized trial. Intern. Emerg. Med. 2024, 19, 1415–1424.

56. Park, S.W.; Yeo, N.Y.; Kang, S.; Ha, T.; Kim, T.H.; Lee, D.; Kim, D.; Choi, S.; Kim, M.; Lee, D.; et al. Early Prediction of Mortality for Septic Patients Visiting Emergency Room Based on Explainable Machine Learning: A Real-World Multicenter Study. J. Korean Med. Sci. 2024, 39, e53.
57. Zhang, G.; Shao, F.; Yuan, W.; Wu, J.; Qi, X.; Gao, J.; Shao, R.; Tang, Z.; Wang, T. Predicting sepsis in-hospital mortality with machine learning: A multi-center study using clinical and inflammatory biomarkers. Eur. J. Med. Res. 2024, 29, 156.
58. Wang, L.; Wu, Y.H.; Ren, Y.; Sun, F.F.; Tao, S.H.; Lin, H.X.; Zhang, C.S.; Tang, W.; Chen, Z.G.; Chen, C.; et al. Establishment and Verification of an Artificial Intelligence Prediction Model for Children With Sepsis. Pediatr. Infect. Dis. J. 2024, 43, 736–742.
59. Ates, H.C.; Alshanawani, A.; Hagel, S.; Cotta, M.O.; Roberts, J.A.; Dincer, C.; Ates, C. Unraveling the impact of therapeutic drug monitoring via machine learning for patients with sepsis. Cell Rep. Med. 2024, 5, 101681.
60. Valik, J.K.; Ward, L.; Tanushi, H.; Johansson, A.F.; Farnert, A.; Mogensen, M.L.; Pickering, B.W.; Herasevich, V.; Dalianis, H.; Henriksson, A.; et al. Predicting sepsis onset using a machine learned causal probabilistic network algorithm based on electronic health records data. Sci. Rep. 2023, 13, 11760.
61. Jiang, Z.; Bo, L.; Wang, L.; Xie, Y.; Cao, J.; Yao, Y.; Lu, W.; Deng, X.; Yang, T.; Bian, J. Interpretable machine-learning model for real-time, clustered risk factor analysis of sepsis and septic death in critical care. Comput. Methods Programs Biomed. 2023, 241, 107772.
62. Aguirre, U.; Urrechaga, E. Diagnostic performance of machine learning models using cell population data for the detection of sepsis: A comparative study. Clin. Chem. Lab. Med. 2022, 61, 356–365.
63. Park, J.Y.; Hsu, T.C.; Hu, J.R.; Chen, C.Y.; Hsu, W.T.; Lee, M.; Ho, J.; Lee, C.C. Predicting Sepsis Mortality in a Population-Based National Database: Machine Learning Approach. J. Med. Internet Res. 2022, 24, e29982.
64. Adams, R.; Henry, K.E.; Sridharan, A.; Soleimani, H.; Zhan, A.; Rawat, N.; Johnson, L.; Hager, D.N.; Cosgrove, S.E.; Markowski, A.; et al. Prospective, multi-site study of patient outcomes after implementation of the TREWS machine learning-based early warning system for sepsis. Nat. Med. 2022, 28, 1455–1460.
65. Henry, K.E.; Adams, R.; Parent, C.; Soleimani, H.; Sridharan, A.; Johnson, L.; Hager, D.N.; Cosgrove, S.E.; Markowski, A.; Klein, E.Y.; et al. Factors driving provider adoption of the TREWS machine learning-based early warning system and its effects on sepsis treatment timing. Nat. Med. 2022, 28, 1447–1454.
66. Shashikumar, S.P.; Josef, C.S.; Sharma, A.; Nemati, S. DeepAISE—An interpretable and recurrent neural survival model for early prediction of sepsis. Artif. Intell. Med. 2021, 113, 102036.
67. Persson, I.; Ostling, A.; Arlbrandt, M.; Soderberg, J.; Becedas, D. A Machine Learning Sepsis Prediction Algorithm for Intended Intensive Care Unit Use (NAVOY Sepsis): Proof-of-Concept Study. JMIR Form. Res. 2021, 5, e28000.
68. Taneja, I.; Damhorst, G.L.; Lopez-Espina, C.; Zhao, S.D.; Zhu, R.; Khan, S.; White, K.; Kumar, J.; Vincent, A.; Yeh, L.; et al. Diagnostic and prognostic capabilities of a biomarker and EMR-based machine learning algorithm for sepsis. Clin. Transl. Sci. 2021, 14, 1578–1589.
69. Wang, D.; Li, J.; Sun, Y.; Ding, X.; Zhang, X.; Liu, S.; Han, B.; Wang, H.; Duan, X.; Sun, T. A Machine Learning Model for Accurate Prediction of Sepsis in ICU Patients. Front. Public. Health 2021, 9, 754348.
70. Rodríguez, A.; Mendoza, D.; Ascuntar, J.; Jaimes, F. Supervised classification techniques for prediction of mortality in adult patients

with sepsis. Am. J. Emerg. Med. 2021, 45, 392–397.

71. Li, K.; Shi, Q.; Liu, S.; Xie, Y.; Liu, J. Predicting in-hospital mortality in ICU patients with sepsis using gradient boosting decision tree. Medicine 2021, 100, e25813.
72. Bataille, B.; de Selle, J.; Moussot, P.E.; Marty, P.; Silva, S.; Cocquet, P. Machine learning methods to improve bedside fluid responsiveness prediction in severe sepsis or septic shock: An observational study. Br. J. Anaesth. 2021, 126, 826–834.
73. Song, X.; Liu, M.; Waitman, L.R.; Patel, A.; Simpson, S.Q. Clinical factors associated with rapid treatment of sepsis. PLoS ONE 2021, 16, e0250923.
74. Yang, M.; Liu, C.; Wang, X.; Li, Y.; Gao, H.; Liu, X.; Li, J. An Explainable Artificial Intelligence Predictor for Early Detection of Sepsis. Crit. Care Med. 2020, 48, e1091–e1096.
75. Lauritsen, S.M.; Kalor, M.E.; Kongsgaard, E.L.; Lauritsen, K.M.; Jorgensen, M.J.; Lange, J.; Thiesson, B. Early detection of sepsis utilizing deep learning on electronic health record event sequences. Artif. Intell. Med. 2020, 104, 101820.
76. Burdick, H.; Pino, E.; Gabel-Comeau, D.; McCoy, A.; Gu, C.; Roberts, J.; Le, S.; Slote, J.; Pellegrini, E.; Green-Saxena, A.; et al. Effect of a sepsis prediction algorithm on patient mortality, length of stay and readmission: A prospective multicentre clinical outcomes evaluation of real-world patient data from US hospitals. BMJ Health Care Inform. 2020, 27, e100109.
77. Zheng, L.; Lin, F.; Zhu, C.; Liu, G.; Wu, X.; Wu, Z.; Zheng, J.; Xia, H.; Cai, Y.; Liang, H. Machine Learning Algorithms Identify Pathogen-Specific Biomarkers of Clinical and Metabolomic Characteristics in Septic Patients with Bacterial Infections. Biomed. Res. Int. 2020, 2020, 6950576.
78. Giannini, H.M.; Ginestra, J.C.; Chivers, C.; Draugelis, M.; Hanish, A.; Schweickert, W.D.; Fuchs, B.D.; Meadows, L.; Lynch, M.; Donnelly, P.J.; et al. A Machine Learning Algorithm to Predict Severe Sepsis and Septic Shock: Development, Implementation, and Impact on Clinical Practice. Crit. Care Med. 2019, 47, 1485–1492.
79. Barton, C.; Chettipally, U.; Zhou, Y.; Jiang, Z.; Lynn-Palevsky, A.; Le, S.; Calvert, J.; Das, R. Evaluation of a machine learning algorithm for up to 48-hour advance prediction of sepsis using six vital signs. Comput. Biol. Med. 2019, 109, 79–84.
80. ASEBIO. BI Alert: Intelligent Sepsis Alert System [Internet]. Madrid: Asociación Española de Bioempresas; 2024 [cited 2025 Oct 13]. Disponible en: https://www.asebio.com/actualidad/noticias/sistema-alertas-inteligentes-sepsis-iic-bialert-sepsis
81. Bignami EG, Berdini M, Panizzi M, Domenichetti T, Bezzi F, Allai S, Damiano T, Bellini V. Artificial Intelligence in Sepsis Management: An Overview for Clinicians. J Clin Med. 2025 Jan 6;14(1):286.
82. Olive-Gadea M, Crespo C, Granes C, Hernandez-Perez M, Pérez de la Ossa N, Laredo C, Urra X, Carlos Soler J, Soler A, Puyalto P, Cuadras P, Marti C, Ribo M. Deep Learning Based Software to Identify Large Vessel Occlusion on Noncontrast Computed Tomography. Stroke. 2020 Oct;51(10):3133-3137.
83. Huang CC, Chiang HF, Hsieh CC, Chou CL, Jhou ZY, Hou TY, Shaw JS. Using Deep-Learning-Based Artificial Intelligence Technique to Automatically Evaluate the Collateral Status of Multiphase CTA in Acute Ischemic Stroke. Tomography. 2023 Mar 16;9(2):647-656. doi: 10.3390/tomography9020052
84. RapidAI for Stroke Detection: Health Technologies [Internet]. Ottawa (ON): Canadian Agency for Drugs and Technologies in Health; 2024 Dec. Report No.: OP0556. PMID: 39869727.
85. Methinks AI. MethinksLVO: Artificial Intelligence Platform for Stroke Diagnosis [Internet]. Barcelona: Methinks AI; 2024 [cited 2025 Oct 13]. Available from: https://www.methinks.ai/
86. Wolcott ZC, English SW. Artificial intelligence to enhance prehospital stroke diagnosis and

triage: a perspective. Front Neurol. 2024 May 2;15:1389056. doi: 10.3389/fneur.2024.1389056

87. Helwig SA, Ragoschke-Schumm A, Schwindling L, Kettner M, Roumia S, et al. Prehospital Stroke Management Optimized by Use of Clinical Scoring vs Mobile Stroke Unit for Triage of Patients With Stroke: A Randomized Clinical Trial. JAMA Neurol. 2019 Dec 1;76(12):1484-1492.
88. Topol EJ. The Topol Review: Preparing the healthcare workforce to deliver the digital future. NHS Health Education England. 2019. Disponible en: https://topol.hee.nhs.uk/
89. Johnson KB, Wei WQ, Weeraratne D, Frisse ME, Misulis K, Rhee K, Zhao J, Snowdon JL. Precision Medicine, AI, and the Future of Personalized Health Care. Clin Transl Sci. 2021 Jan;14(1):86-93. doi: 10.1111/cts.12884
90. Basile AO, Yahi A, Tatonetti NP. Artificial Intelligence for Drug Toxicity and Safety. Trends Pharmacol Sci. 2019 Sep;40(9):624-635. doi: 10.1016/j.tips.2019.07.005
91. Zhang Y, Deng Z, Xu X, Feng Y, Junliang S. Application of Artificial Intelligence in Drug-Drug Interactions Prediction: A Review. J Chem Inf Model. 2024 Apr 8;64(7):2158-2173. doi: 10.1021/acs.jcim.3c00582
92. Merative. Micromedex ISI® Clinical Decision Support System [Internet]. Ann Arbor (MI): Merative; 2025 [cited 2025 Oct 13]. Disponible en: https://www.micromedexsolutions.com/
93. Mishra HP, Gupta R. Leveraging Generative AI for Drug Safety and Pharmacovigilance. Curr Rev Clin Exp Pharmacol. 2025;20(2):89-97.
94. Ghosh A. AI system can help doctors prescribe medicine with expert-level accuracy [Internet]. London (UK): The Guardian; 2024 Mar 31 [citado 2025 Oct 13]. Disponible en: https://www.theguardian.com/science/2024/mar/31/druggpt-new-ai-tool-could-help-doctors-prescribe-medicine-in-england
95. Wang W, Song H, Liu M, et al. PharmacyGPT: A large language model for medication plan recommendation in intensive care. arXiv:2307.10432 [preprint]. 2023 [citado 2025 Oct 13]. Disponible en: https://arxiv.org/abs/2307.10432
96. Khanna T, Li J, Pan C, et al. HELIOT: Large language models can accurately identify drug allergies. arXiv:2409.16395 [preprint]. 2024 [citado 2025 Oct 13]. Disponible en: https://arxiv.org/abs/2409.16395
97. Wang J, Liu S, Xie M, et al. TxAgent: An agent system for treatment recommendation using large language models. arXiv:2503.10970 [preprint]. 2025 [citado 2025 Oct 13]. Disponible en: https://arxiv.org/abs/2503.10970
98. Council for International Organizations of Medical Sciences (CIOMS). Practical approaches to medicines safety: draft for public consultation [Internet]. Geneva: CIOMS; 2022 [citado 2025 Oct 13]. Disponible en: https://cioms.ch/wp-content/uploads/2022/05/CIOMS-WG-XIV_Practical-approaches-to-medicines-safety_Draft-for-public-consultation.pdf
99. European Commission. Artificial intelligence in healthcare [Internet]. Brussels: HaDEA; 2024 [citado 2025 Oct 13]. Disponible en: https://health.ec.europa.eu/ehealth-digital-health-and-care/artificial-intelligence-healthcare_en
100. Metz C. The FDA is using artificial intelligence to help approve drugs [Internet]. San Francisco (CA): Wired; 2024 Apr 10 [citado 2025 Oct 13]. Disponible en: https://www.wired.com/story/openai-fda-doge-ai-drug-evaluation/
101. Gathright R, Mejia I, Gonzalez JM, Hernandez Torres SI, Berard D, Snider EJ. Overview of Wearable Healthcare Devices for Clinical Decision Support in the Prehospital Setting. Sensors (Basel). 2024 Dec 22;24(24):8204. doi: 10.3390/s24248204
102. Boehmer JP, Hariharan R, Devecchi FG, Smith AL, Molon G, Capucci A, An Q, Averina V, Stolen CM, Thakur PH, Thompson JA, Wariar R, Zhang Y, Singh JP. A Multisensor Algorithm Predicts Heart Failure Events in Patients With Implanted Devices: Results From the MultiSENSE Study. JACC Heart Fail. 2017 Mar;5(3):216-225.

103. Escobar GJ, Liu VX, Schuler A, Lawson B, Greene JD, Kipnis P. Automated Identification of Adults at Risk for In-Hospital Clinical Deterioration. N Engl J Med. 2020 Nov 12;383(20):1951-1960.

104. Nemati S, Holder A, Razmi F, Stanley MD, Clifford GD, Buchman TG. An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in the ICU. Crit Care Med. 2018 Apr;46(4):547-553.

105. Hwang EJ, Kim KB, Kim JY, Lim JK, Nam JG, Choi H, Kim H, Yoon SH, Goo JM, Park CM. COVID-19 pneumonia on chest X-rays: Performance of a deep learning-based computer-aided detection system. PLoS One. 2021 Jun 7;16(6):e0252440.

106. Liu WT, Lin C, Lee CC, Chang CH, Fang WH, Tsai DJ, Lin WY, Hung Y, Chen KC, Lee CH, Tsai TN, Lin WS, Hung YJ, Lin SH, Tsai CS, Lin CS. Artificial Intelligence-Enabled ECGs for Atrial Fibrillation Identification and Enhanced Oral Anticoagulant Adoption: A Pragmatic Randomized Clinical Trial. J Am Heart Assoc. 2025 Jul 15;14(14):e042106.

107. McKee M, Rosenbacke R, Stuckler D. The power of artificial intelligence for managing pandemics: A primer for public health professionals. Int J Health Plann Manage. 2025 Jan;40(1):257-270.

108. Schwartz L, Anteby R, Klang E, Soffer S. Stroke mortality prediction using machine learning: systematic review. J Neurol Sci. 2023 Jan 15;444:120529.

109. Piliuk K, Tomforde S. Artificial intelligence in emergency medicine. A systematic literature review. Int J Med Inform. 2023 Dec;180:105274.

110. Ahmed Abdalhalim AZ, Nureldaim Ahmed SN, Dawoud Ezzelarab AM, Mustafa M, Ali Albasheer MG, Abdelgadir Ahmed RE, Galal Eldin Elsayed MB. Clinical Impact of Artificial Intelligence-Based Triage Systems in Emergency Departments: A Systematic Review. Cureus. 2025 Jun 9;17(6):e85667.

111. OpenAI. ChatGPT-5: Multimodal Large Language Model with Clinical Applications [Internet]. San Francisco (CA): OpenAI; 2025 [cited 2025 Oct 10]. Disponible en: https://openai.com/

5.

OBJETIVOS OPERATIVOS Y LOGÍSTICOS DE LA IA EN URGENCIAS



Figura 1. Objetivos específicos de acciones asistidas por IA en urgencias

La integración de la IA en los servicios de urgencias representa una transformación significativa en la gestión operativa y logística de estos entornos de alta presión.

Aunque el triaje y el flujo de pacientes están relacionados, no son equivalentes. Como hemos visto anteriormente, el triaje es una etapa dentro del flujo de pacientes, cuyo objetivo es clasificar a los pacientes por nivel de gravedad para priorizar su atención. En cambio, el flujo de pacientes abarca todo el recorrido del paciente desde su llegada hasta su salida (alta, ingreso o derivación), incluyendo todos los procesos clínicos, logísticos y administrativos intermedios [1][2][3] (Tabla 1).

Tabla 1. Triaje y flujo de pacientes

CONCEPTO	DEFINICIÓN	OBJETIVO	HERRAMIENTAS TÍPICAS	INDICADORES
Triaje	Clasificación por gravedad	Priorizar atención urgente	ESI, START, ML para severidad	Tiempo a primera atención, adecuación de nivel
Flujo de Pacientes	Secuencia completa de pasos del paciente	Reducir tiempos, evitar cuellos de botella	Modelos de simulación, Lean, IA operativa	Tiempo total de estancia, tiempo en espera, saturación

ESI (Emergency Severity Index) [1]; START [2] ;Lean Healthcare [3]

5.1. OPTIMIZACIÓN DEL FLUJO DE PACIENTES

Uno de los principales desafíos en los servicios de urgencias es la gestión eficiente del flujo de pacientes, dado el volumen impredecible de ingresos y la necesidad de priorizar casos según su gravedad. Un flujo ineficiente de pacientes contribuye al hacinamiento en los entornos de atención médica y a resultados clínicos y experiencias de los pacientes negativos posteriormente. La gestión del flujo de pacientes tiene como objetivo lograr un movimiento fluido de pacientes garantizando un acceso oportuno a una atención de calidad.
La predicción del flujo de pacientes se puede dividir en cuatro secciones: predicción de la demanda y los ingresos en urgencias (SU), predicción del flujo de pacientes desde SU a la atención hospitalaria, predicción del movimiento de pacientes dentro del hospital y predicción de la duración de la estancia. Este método de previsión se utiliza a menudo para personas con enfermedades crónicas (p. ej., enfermedad de Alzheimer, traumatismo craneoencefálico,) que requieren tratamiento o gestión durante un período prolongado y que podrían necesitar diferentes tipos de atención aguda y a largo plazo en diferentes centros sanitarios durante ese tiempo.

5.1.1 Herramientas

La IA desempeña un papel crucial en este ámbito al ofrecer herramientas predictivas y de gestión dinámica [4]. En lugar de los métodos manuales que se utilizan actualmente para planificar y rastrear el flujo de pacientes, los algoritmos de IA utilizan datos (p. ej., edad del paciente, diagnóstico, signos vitales, duración promedio del tratamiento, historial clínico) que pueden extraerse directamente de los registros médicos electrónicos para predecir los resultados de los pacientes. Esas predicciones informan el pronóstico del flujo de pacientes y la planificación de recursos con el objetivo de maximizar la eficiencia y la calidad de la atención, al tiempo que se minimiza la interrupción del flujo.
Estas herramientas de IA pueden predecir ingresos, el traslado de pacientes desde urgencias a camas de hospitalización, el alta y los traslados a diferentes centros sanitarios. Se ha comprobado su eficacia en pacientes con ingresos de urgencias y transferidos a atención terciaria y cuaternaria, así como en pacientes hospitalizados de servicios generales o especialidades. Además, la evidencia sugiere que las herramientas de IA pueden optimizar la programación de citas en consultas externas y quirófanos.

5.1.2 Algoritmos de Flujo de Pacientes en Urgencias

La (Tabla 2) resume los algoritmos principales utilizados para gestionar el flujo de pacientes en servicios de urgencias, incluyendo tanto sistemas tradicionales de triaje, ya comentados en el capítulo 4, como enfoques modernos basados en IA [5-11].

ESI (Emergency Severity Index): Índice de Gravedad en Urgencias. Sistema de triaje ampliamente utilizado en Estados Unidos que clasifica a los pacientes en cinco niveles, según la urgencia clínica y los recursos necesarios para su atención.

ATS (Australasian Triaje Scale): Escala de Triaje australiana. Clasifica a los pacientes en cinco niveles basándose en el tiempo máximo aceptable para recibir atención médica. Se utiliza en países como Australia y Nueva Zelanda.

CTAS (Canadian Triaje and Acuity Scale): Escala Canadiense de Triaje y Agudeza.

Tabla 2. Algoritmos para gestionar el flujo de pacientes

ALGORITMO	OBJETIVO/FASE DEL FLUJO	MECANISMO PRINCIPAL	CONTEXTO DE USO	REFERENCIA
Emergency Severity Index (ESI)	Clasificación inicial	Sistema de 5 niveles según urgencia y recursos necesarios.	Urgencias generales en EE.UU. y otros países.	[5]
ATS / CTAS	Clasificación inicial	Escalas de 5 niveles basados en tiempos máximos de espera.	Hospitales en Australasia y Canadá.	[6]
START / JumpSTART	Masas/Incidentes Múltiples	Triaje rápido por respiración, perfusión y conciencia.	Catástrofes, MCI.	[7]
Split-flow / Streaming	División por gravedad/ flujo	Evaluación rápida por médico para derivar a Fast-Track.	Urgencias con alta demanda.	[8]
Simulación (ABM, DES, SD)	Optimización operativa	Modelos que simulan recursos, tiempos y cuellos de botella.	Gestión interna hospitalaria.	[9]
IA / ML	Predicción y triaje automatizado	Modelos de predicción para severidad, ocupación, etc.	Urgencias con infraestructura digital.	[10]
Algoritmos dinámicos de flujo	Modelado del flujo en tiempo real	Grafos dinámicos para rutas óptimas y saturación.	Investigación y planificación avanzada.	[11]

Similar a la ATS, está adaptada al sistema de salud canadiense y también utiliza cinco niveles para establecer prioridades de atención.

START (Simple Triaje and Rapid Treatment): Triaje Simple y Tratamiento Rápido. Herramienta de triaje rápido utilizada en incidentes con múltiples víctimas, basada en criterios básicos como la respiración, perfusión y estado de conciencia.

JumpSTART: Versión pediátrica del sistema START, adaptada a las características fisiológicas y clínicas de los niños, para su uso en escenarios de emergencias masivas.

Split-flow / Streaming: Modelo operativo en servicios de urgencias que consiste en una evaluación médica inicial rápida para derivar a los pacientes hacia circuitos diferenciados (por ejemplo, un área de Fast-Track), optimizando la atención según la gravedad o complejidad del caso.

ABM (Agent-Based Modeling): Modelado Basado en Agentes. Técnica de simulación que representa a los pacientes, profesionales y recursos como agentes individuales con comportamientos autónomos, útil para estudiar la dinámica interna del sistema hospitalario.

DES (Discrete Event Simulation): Simulación de Eventos Discretos. Modelo que representa el sistema como una secuencia cronológica de eventos (como la llegada de un paciente o la liberación de una cama),

permitiendo identificar cuellos de botella y planificar mejoras.

SD (System Dynamics): Dinámica de Sistemas. Técnica de simulación a nivel agregado que analiza el comportamiento de sistemas complejos a través de flujos, acumulaciones y bucles de retroalimentación.

MCI (Mass Casualty Incident): Incidente con Múltiples Víctimas. Situación en la que el número de pacientes excede la capacidad de respuesta habitual del sistema sanitario, y requiere estrategias de triaje específicas y protocolos de atención priorizada.

5.1.3 Gestión Operativa del Flujo de Pacientes en Urgencias en España

La gestión operativa del flujo de pacientes en los servicios de urgencias hospitalarios (SUH) en España constituye un desafío prioritario, marcado por la persistente sobrecarga asistencial. Un estudio multicéntrico de Font-Cabrera et al. [12] en ocho hospitales del Institut Català de la Salut, con más de 2,3 millones de pacientes, evidenció que más del 50% de las atenciones correspondieron a niveles de baja prioridad (niveles 4 y 5 del Sistema Español de Triaje, SET), principalmente mujeres jóvenes o de mediana edad. Este patrón se mantuvo incluso durante la pandemia de SARS-CoV-2, aunque se observó un aumento de los casos de mayor gravedad (niveles 1-3).

La concentración de casos leves en hospitales de alta complejidad agrava la saturación, dificultando la atención a los pacientes más graves. Factores adicionales, como la escasa derivación a atención primaria y la insuficiencia de camas de hospitalización, refuerzan este fenómeno. La literatura internacional coincide en señalar que la sobreutilización de urgencias por patologías menores no solo incrementa costes y demora diagnósticos, sino que también eleva la morbimortalidad.

Ante este panorama, se proponen varias estrategias: circuitos diferenciados para patologías leves, integración de enfermeras de práctica avanzada (EPA) y mejora de la precisión en el triaje. En países como Reino Unido, Estados Unidos o Canadá, las EPA ya desempeñan un papel clave en la resolución de casos de baja complejidad, con reducción de tiempos de espera y mayor satisfacción del paciente [13]. Su implementación en España, ya iniciándose en algunos centros, podría aliviar significativamente la presión asistencial.

¿Cuál deben ser los pasos para mejorar la gestión operativa del flujo de pacientes en los SUH españoles? Básicamente serían reforzar el triaje, optimizar recursos mediante modelos innovadores como las EPA, fomentar la coordinación con la atención primaria, implementar herramientas digitales y abordar desafíos estructurales Estas medidas reducirán la saturación, mejorarán la seguridad clínica y garantizarán un acceso equitativo a la atención urgente.

5.1.4 Predicción de tiempos de espera

La IA utiliza modelos de aprendizaje automático para analizar datos históricos y en tiempo real, como el número de pacientes, la gravedad de los casos, los tiempos de atención previos y las tendencias estacionales, para predecir los tiempos de espera con alta precisión [14]. Por ejemplo, algoritmos basados en redes neuronales pueden estimar la duración de los procesos de triaje, diagnóstico y tratamiento, permitiendo a los administradores de urgencias informar a los pacientes y ajustar los flujos de trabajo. Estudios han demostrado que estas predicciones pueden reducir la percepción de espera prolongada y mejorar la satisfacción del paciente [15].

5.1.5 Gestión Dinámica de Camas y Recursos

La IA también optimiza la asignación de recursos físicos, como camas, equipos médicos y salas de procedimientos. Sistemas de gestión hospitalaria asistidos por IA pueden monitorizar en tiempo real la disponibilidad de camas y predecir la necesidad de recursos adicionales en función de los patrones de admisión. Por ejemplo en un estudio de AIG Hospitals en Hyderabad (India), la implementación de un sistema de gestión de camas en tiempo real basado en tecnología avanzada (inteligencia artificial, análisis inteligente y dashboards en vivo) permitió reducir el tiempo de asignación entre admisión y llegada del paciente en un 65%, e incrementó la tasa de rotación de camas en un 11% [16] Estas herramientas permiten una toma de decisiones más ágil, evitando cuellos de botella en los momentos de alta demanda.

5.2 REDUCCION DEL TIEMPO DE ATENCION

La rapidez en la atención es crítica en los servicios de urgencias, donde cada minuto puede marcar la diferencia en los resultados clínicos. La IA contribuye a este objetivo automatizando tareas administrativas y apoyando la generación de documentación clínica.

5.2.1 Automatización de Tareas Repetitivas

La entrada manual de datos, como la elaboración de historias clínicas o el registro de información demográfica, consume tiempo valioso del personal médico. La IA permite automatizar estas tareas mediante sistemas de reconocimiento de voz y procesamiento de lenguaje natural (PLN). Por ejemplo, herramientas de transcripción automática pueden convertir las notas verbales de los médicos en registros digitales estructurados, reduciendo el tiempo dedicado a estas tareas en un 30% según estudios recientes [5]. Esto permite que el personal médico se enfoque en la atención directa al paciente.

5.2.2 Asistencia en la Generación de Informes Clínicos

La generación de informes clínicos detallados es esencial, pero puede ser un proceso laborioso. Los sistemas de IA basados en PLN pueden asistir en la redacción de informes al sugerir plantillas, completar secciones basadas en datos previos o identificar inconsistencias en la documentación. Un trabajo sintetiza evidencias revisadas por pares del impacto de las herramientas de IA y PLN en la mejora de la eficiencia, calidad y consistencia de la documentación clínica, detallando ejemplos de automatización de notas, estructuración asistida de textos, sugerencias y detección de errores en historias clínicas electrónicas [17]. Por ejemplo, un estudio realizado en un hospital de Estados Unidos mostró que la aplicación de PLN y modelos generativos de IA disminuyó significativamente el tiempo de documentación y aumentó la precisión del contenido registrado en informes clínicos estructurados, destacando ahorros de tiempo y mejoras medibles en la calidad del registro [18]. Esta asistencia no solo ahorra tiempo, sino que también reduce errores humanos.

5.3 ASIGNACION INTELIGENTE DE PERSONAL

La asignación eficiente del personal es otro aspecto crítico para garantizar la operatividad de los servicios de urgencias. La IA permite una planificación más estratégica basada en datos predictivos y en tiempo real.

5.3.1 Análisis Predictivo de Picos de Demanda

Mediante el análisis de datos históricos, patrones climáticos, eventos locales y tendencias epidemiológicas, los algoritmos de IA pueden predecir picos de demanda en los servicios de urgencias [19]. Por ejemplo, durante temporadas de gripe, los modelos predictivos pueden estimar el volumen esperado de pacientes y su distribución por especialidades, permitiendo una mejor preparación del personal y los recursos. Un estudio real y reciente sobre el uso conjunto de IA y simulación de eventos demuestra como acortar los tiempos de espera de camas en hospitales durante temporadas de enfermedades respiratorias estacionales en un grupo hospitalario europeo [20].

5.3.2 Planificación de Turnos en Función de la Carga Asistencial Esperada

La programación de turnos de enfermería representa un desafío complejo en los entornos sanitarios, con repercusiones tanto en la calidad asistencial como en el bienestar del personal. Los métodos tradicionales suelen ignorar las preferencias individuales, lo que contribuye a la insatisfacción laboral, el agotamiento y una alta rotación de personal, agravado por la falta de autonomía y transparencia en los procesos de asignación de turnos. La literatura evidencia que los enfoques participativos, en los que se incorporan activamente las preferencias de las enfermeras, mejoran su satisfacción en el trabajo.

Los métodos de IA y optimización matemática, como la programación entera mixta (MIP), la programación por restricciones (CP), la programación genética (GP) y el aprendizaje por refuerzo (RL), se presentan como alternativas prometedoras para abordar estos desafíos. Un estudio en instituciones de salud suizas, a través de entrevistas grupales, identificó la equidad y la participación como requisitos prioritarios en la programación de turnos (señalados por el 85% de los participantes), seguidos de la flexibilidad y la autonomía (76%), destacando el valor de mecanismos como los intercambios de turno y la autoprogramación.

Sobre la introducción de IA, el 62% de los participantes percibió oportunidades para mejorar la eficiencia y la justicia en la asignación de turnos, aunque el 38% expresó inquietud sobre la fiabilidad y la necesidad de mantener la supervisión humana. El mapeo de las necesidades a diversas técnicas de IA mostró que MIP es especialmente eficaz para la asignación equitativa de turnos, CP es apta para gestionar reglas complejas y preferencias, GP resulta útil para imprevistos como ausencias, y RL facilita la adaptación dinámica ante cambios en entornos hospitalarios. Una implementación preliminar de MIP en un hospital de entrenamiento ilustró cómo es posible diseñar un sistema optimizado desde la perspectiva matemática.

Así pues, los sistemas de programación apoyados por IA pueden incrementar significativamente la equidad, transparencia y eficiencia. Sin embargo, para lograr una adopción satisfactoria es necesario abordar los desafíos relativos a la confianza en la IA y garantizar un equilibrio entre automatización y supervisión humana. Un enfoque híbrido, donde la IA proporcione recomendaciones y el personal supervise la toma de decisiones, surge como la vía más adecuada para avanzar y responder tanto a las necesidades del personal como a la calidad asistencial [21].

Referencias

1. 1. Wandl B, Kellerer JD, Fuhrmann V, Tapinova K, Roth D, Müller G. Diagnostic test accuracy of the Emergency Severity Index: a systematic review and meta-analysis. Eur J Emerg Med. 2025 ;32(5):325-334.
2. Lin YK, Chen KC, Wang JH, Lai PF. Simple triaje and rapid treatment protocol for emergency department mass casualty incident victim triaje. Am J Emerg Med. 2022 ;53:99-103.
3. de Barros LB, Bassi LC, Caldas LP, Sarantopoulos A, Zeferino EBB, Minatogawa V, Gasparino RC. Lean Healthcare Tools for Processes Evaluation: An Integrative Review. Int J Environ Res Public Health. 2021 Jul 10;18(14):7389.
4. Artificial Intelligence for Patient Flow: Emerging Health Technologies [Internet]. Ottawa (ON): Canadian Agency for Drugs and Technologies in Health; 2024 Apr. Report No.: EH0125.
5. Emergency Severity Index (ESI): Implementation Handbook. ed 5. Washington (DC): Emergency Nurses Association; 2021Accesible en https://media.emscimprovement.center/documents/Emergency_Severity_Index_Handbook.pdf
6. Australasian College for Emergency Medicine. Policy on the Australasian Triaje Scale Accesible en https://www.academia.edu/7346967/Aust_Triaje_Scale
7. Romig LE. Pediatric triaje. A system to JumpSTART your triaje of young patients at MCIs. JEMS. 2002 Jul;27(7):52-8, 60-3.
8. Handel DA, Ginde AA, Raja AS, Rogers J, Sullivan AF, Espinola JA, Camargo CA. Implementation of crowding solutions from the American College of Emergency Physicians Task Force Report on Boarding. Int J Emerg Med. 2010 Aug 21;3(4):279-86.
9. Aljebori ST et al. Modeling the Patients Flow Behavior in Hilla Emergency Departments 2018 Int J Eng Technol 7(4.19):801.
10. Liu Z, Shu W, Liu H, Zhang X, Chong W. Development and validation of interpretable machine learning models for triaje patients admitted to the intensive care unit. PLoS One. 2025 Feb 18;20(2):e0317819.
11. Boodaghian Asl A, Raghothama J, Darwich AS, Meijer S. A dynamic nonlinear flow algorithm to model patient flow. Sci Rep. 2025 Apr 8;15(1):12052.
12. Font-Cabrera C, Juvé-Udina ME, Adamuz J, Diaz Membrives M, Fabrellas N, Guix-Comellas EM. Activity, triaje levels and impact of the pandemic on hospital emergency departments: A multicentre cross-sectional study. J Adv Nurs. 2025 Mar;81(3):1332-1342.
13. Woo BFY, Lee JXY, Tam WWS. The impact of the advanced practice nursing role on quality of care, clinical outcomes, patient satisfaction, and cost in the emergency and critical care settings: a systematic review. Hum Resour Health. 2017 Sep 11;15(1):63.
14. Napoli AM, Smith-Shain R, Lin T, Baird J. The Accuracy of Predictive Analytics in Forecasting Emergency Department Volume Before and After Onset of COVID-19. West J Emerg Med. 2024 Jan;25(1):61-66.
15. Chenais G, Lagarde E, Gil-Jardiné C. Artificial Intelligence in Emergency Medicine: Viewpoint of Current Applications and Foreseeable Opportunities and Challenges. J Med Internet Res. 2023 May 23;25:e40031.
16. Wankar, Abhinav and Jalota, Capri and Chaitanya, Krishna and Ahmed Uddin, Mohammed and Saxena, Kinjal and Mojasia, Gaurav and Pareek, Satish, Leveraging Technology for Efficient Bed Management in a Large Complex Healthcare System. Disponible en: SSRN: https://ssrn.com/abstract=5155970
17. Perkins SW, Muste JC, Alam T, Singh RP. Improving Clinical Documentation with Artificial Intelligence: A Systematic Review. Perspect Health Inf Manag. 2024 Jun 1;21(2):1d.
18. Biswas A, Talukdar W. Intelligent Clinical Documentation: Harnessing Generative AI for Patient-Centric Clinical Note Generation. Int J Innov Sci Res Technol. 2024 May;9(5):994–

1008. doi:10.38124/ijisrt/ijisrt24may1483. Disponible en: https://www.researchgate.net/publication/380929105_Intelligent_Clinical_Documentation_Harnessing_Generative_AI_for_Patient-Centric_Clinical_Note_Generation

19. Zhu, X., Zhang, G. & Sun, B. A comprehensive literature review of the demand forecasting methods of emergency resources from the perspective of artificial intelligence. *Nat Hazards* 97, 65–82 (2019). Disponible en: https://doi.org/10.1007/s11069-019-03626-z

20. Ortiz-Barrios M, Cuenca L, Arias-Fonseca S, McClean S, Pérez-Aguilar A. Nurse Staffing Management in the Context of Emergency Departments and Seasonal Respiratory Diseases: An Artificial Intelligence and Discrete-Event Simulation Approach. J Med Syst. 2025 Aug 16;49(1):106.

21. Renggli FJ, Gerlach M, Bieri JS, Golz C, Sariyar M. Integrating Nurse Preferences Into AI-Based Scheduling Systems: Qualitative Study. JMIR Form Res. 2025 Jun 4;9:e67747.

6.

OBJETIVOS DE GESTIÓN Y TOMA DE DECISIONES

Objetivo Específico		Acciones Asistidas por IA
	Soporte en decisiones administrativa	Evaluación del rendimiento del servicio en tiempo real Identificación de cuellos de botella y propuestas automáticas de mejora
	Análisis de datos para mejora continua	Detección de patrones de reingresos o errores clinicos Informes periódicos sobre indicadores de calidad y seguridad

Imagen 1. Objetivos de gestión y toma de decisiones

La integración de la IA en el ámbito de las urgencias médicas ha transformado la gestión y la toma de decisiones, permitiendo optimizar recursos, mejorar la calidad del cuidado y reducir errores clínicos. Este capítulo explora los objetivos específicos y las acciones asistidas por IA que apoyan estos procesos, destacando su impacto en la atención sanitaria en tiempo real.

6.1 SOPORTE EN DECISIONES ADMINISTRATIVAS

Un objetivo clave de la IA en urgencias es proporcionar soporte en decisiones administrativas. Esto incluye la automatización de tareas rutinarias, como la asignación de personal y recursos, así como el análisis continuo de datos para identificar áreas de mejora. El tiempo de espera del paciente para ser trasladado a hospitalización se define como el intervalo entre la decisión de hospitalización y el ingreso real en una cama de hospitalización. Una de las principales dificultades para medir este tiempo radica en la incapacidad de los sistemas de información hospitalaria para registrarlo con precisión. En general, los hospitales cuentan con equipos especializados en la asignación de camas, los cuales gestionan la distribución entre diferentes departamentos mediante comunicación telefónica, un proceso que genera una carga de trabajo adicional significativa y de efectividad cuestionable.

Se han desarrollado algoritmos basados en inteligencia artificial, integrados en una plataforma web diseñada para pacientes ingresados. Esta solución incorpora tecnología IoT-Beacons para optimizar el intercambio de información sobre la disponibilidad de camas en tiempo real (Figura1). Los IoT-Beacons son dispositivos pequeños basados en la tecnología de Internet de las Cosas (IoT) que emiten señales de baja energía (generalmente mediante Bluetooth Low Energy, BLE) para transmitir información a dispositivos cercanos, como teléfonos inteligentes, tabletas o sistemas

hospitalarios. En el contexto de la gestión de camas en hospitales, los IoT-Beacons se utilizan para monitorizar y actualizar en tiempo real la disponibilidad de camas, enviando datos automáticamente a una plataforma centralizada. Esto permite una asignación más eficiente de recursos al eliminar la necesidad de comunicación manual, como las llamadas telefónicas, y mejora la precisión en la toma de decisiones. Por ejemplo, en el Centro Hospitalario Universitario de Lille (LUHC), se integran con algoritmos de inteligencia artificial para optimizar la gestión de camas [1].

Ya hemos visto como el uso de algoritmos de aprendizaje automático ha incrementado la eficiencia en la gestión de camas hospitalarias. Además, el análisis de datos en tiempo real permite a los administradores ajustar dinámicamente los flujos de pacientes, reduciendo tiempos de espera y mejorando la experiencia del usuario.

6.1.1 Evaluación del Rendimiento del Servicio en Tiempo Real

Así pues, la IA permite una evaluación dinámica y continua del rendimiento de los servicios hospitalarios, utilizando estos sistemas comentados que integran datos en tiempo real procedentes de registros electrónicos, sensores IoT y sistemas administrativos. Esta tecnología monitoriza indicadores clave de rendimiento (KPIs) como (Figura 2):



Figura 1. Tecnología IoT-Beacons para optimizar el intercambio de información sobre la disponibilidad de camas en tiempo real

- Tiempo de respuesta en emergencias: seguimiento automático desde la llegada del paciente hasta la primera atención médica, identificando cuellos de botella.
- Ocupación de unidades críticas (UCI, urgencias): análisis en tiempo real del número de camas disponibles, tasas de rotación y predicción de saturación mediante algoritmos predictivos.
- Eficiencia del flujo asistencial: comparación de tiempos promedio de atención entre turnos o servicios, detectando áreas de mejora.

En contextos de alta presión, como los servicios de urgencias hospitalarias, estos sistemas son esenciales para anticipar picos de demanda y reasignar recursos de forma automática. Por ejemplo, si un modelo IA detecta que el tiempo de espera supera los estándares, puede sugerir refuerzos de personal o derivaciones interhospitalarias antes de que la situación empeore. Un estudio desarrollado en EE. UU. [2] implementó un sistema de IA para monitorizar el rendimiento en urgencias, utilizando datos en tiempo real de sensores y registros clínicos. El sistema redujo los tiempos de espera y mejoró la disponibilidad de camas críticas mediante algoritmos de predicción de ocupación.

6.1.2 Identificación de Cuellos de Botella y Propuestas Automáticas de Mejora

Uno de los aspectos más relevantes es la capacidad de la IA para identificar cuellos de botella en los procesos clínicos, que incluyen tiempos



Figura 2. Indicadores clave de rendimiento de los servicios hospitalarios

de espera excesivos, retrasos en la atención inicial o acumulaciones de pacientes en áreas específicas como el triaje o las salas de observación. Estos cuellos de botella no solo afectan la eficiencia operativa, sino que también pueden tener un impacto directo en la calidad de la atención y la satisfacción del paciente [3]. Estudios recientes han demostrado que el uso de algoritmos de aprendizaje automático puede analizar flujos de pacientes en tiempo real, detectando puntos críticos con una precisión que supera los métodos tradicionales basados en observación manual [4].

Además de la detección, las propuestas automáticas de mejora generadas por IA ofrecen soluciones prácticas y adaptativas que pueden transformar la gestión de urgencias. Estas propuestas se fundamentan en el análisis continuo de datos en tiempo real, incluyendo información sobre la ocupación de camas, la disponibilidad de personal médico y los tiempos de respuesta de los equipos diagnósticos. Este enfoque permite una toma de decisiones más ágil y efectiva, reduciendo la dependencia de intervenciones humanas reactivas. Un ejemplo concreto es el uso de sistemas de recomendación que sugieren ajustes dinámicos en los turnos del personal médico para mitigar saturaciones en momentos de alta demanda, asegurando una distribución equitativa de la carga laboral [5]. Otro caso práctico incluye la optimización automática de los flujos de pacientes mediante la reasignación de recursos, como la priorización de equipos de resonancia magnética o rayos X para casos urgentes, lo que disminuye los tiempos de espera y mejora los resultados clínicos [6].

La integración de estas tecnologías también tiene un impacto positivo en la reducción de errores clínicos, un problema común en entornos de alta presión como las urgencias. La sobrecarga laboral y la falta de coordinación entre equipos pueden llevar a fallos en el diagnóstico o en la administración de tratamientos. La IA, al analizar grandes volúmenes de datos históricos y en tiempo real, puede identificar patrones que anticipan estos errores y proponer medidas preventivas, como alertas automáticas para revisiones adicionales o la sugerencia de protocolos específicos según el perfil del paciente [7]. Además, la capacidad de la IA para simular escenarios futuros basados en datos actuales permite a los administradores planificar mejor la asignación de recursos a largo plazo, evitando saturaciones recurrentes y mejorando la resiliencia del sistema de salud frente a crisis imprevistas.

6.2 ANÁLISIS DE DATOS PARA MEJORA CONTINUA

El análisis de datos para la mejora continua es un pilar fundamental en la optimización de los servicios de urgencias mediante IA. Este enfoque permite a los profesionales de la salud identificar áreas de oportunidad y establecer estrategias sostenibles para elevar la calidad del cuidado. A continuación, se detallan dos aspectos clave: la detección de patrones y los informes periódicos.

6.2.1 Detección de Patrones

La detección de patrones mediante IA facilita la identificación de tendencias que se repiten en los flujos de pacientes, como picos de demanda o errores frecuentes en el diagnóstico. Estudios han demostrado que algoritmos de aprendizaje automático pueden analizar grandes volúmenes de datos clínicos en tiempo real, detectando anomalías con alta precisión. Por ejemplo, la identificación de patrones relacionados con demoras en la atención inicial ha permitido ajustar protocolos de triaje, mejorando los tiempos de respuesta. Este proceso

no solo optimiza la operativa diaria, sino que también apoya la prevención de complicaciones al anticipar necesidades específicas de los pacientes [8].

6.2.2 Informes Periódicos

Los informes periódicos generados por IA ofrecen una visión estructurada y actualizada del rendimiento del departamento de urgencias. Estos informes integran datos sobre tiempos de espera, tasas de ocupación y resultados clínicos, proporcionando a los administradores herramientas para la toma de decisiones. Investigaciones recientes destacan que la automatización de estos informes reduce significativamente el tiempo dedicado a la recopilación manual de datos, permitiendo intervenciones más rápidas y efectivas [9]. Además, la inclusión de indicadores de calidad personalizados asegura que los informes sean relevantes para las necesidades específicas de cada institución.

REFERENCIAS

1. Ajmi F, Ajmi F, Ben Othman S, Zgaya H, Smith G, Renard JM, Hammadi S. Impact of the Automation of Inpatient Bed Management to Reduce the Emergency Service Waiting Time. Stud Health Technol Inform. 2022 Jun 6;290:942-946.
2. Resar R, Nolan K, Kaczynski D, Jensen K. Using real-time demand capacity management to improve hospitalwide patient flow. Jt Comm J Qual Patient Saf. 2011 May;37(5):217-27
3. Canellas M, Michael S, Kotkowski K, Reznek M. Operations Factors Associated with Emergency Department Length of Stay: Analysis of a National Operations Database. West J Emerg Med. 2023 Jan 31;24(2):178-184.
4. Wu W, Li M, Jiang H, Sun M, Zhu Y, Zhu G, Li Y, Li Y, Mo J, Chen X, Mao H. Development of an emergency department length-of-stay prediction model based on machine learning. World J Emerg Med. 2025 May 1;16(3):220-224
5. Ongesa TN, Ugwu OP, Ugwu CN, Alum EU, Eze VHU, Basajja M, Ugwu JN, Ogenyi FC, Okon MB, Ejemot-Nwadiaro RI. Optimizing emergency response systems in urban health crises: A project management approach to public health preparedness and response. Medicine (Baltimore). 2025 Jan 17;104(3):e41279.
6. Narendra Chennupati. AIRA-Hospital: Generative AI-enhanced robotic process automation for dynamic resource allocation in acute care settings. World Journal of Advanced Research and Reviews, 2025, 26(02), 1561-1571. Article DOI: https://doi.org/10.30574/wjarr.2025.26.2.165
7. Taylor RA, Sangal RB, Smith ME, Haimovich AD, Rodman A, Iscoe MS, Pavuluri SK, Rose C, Janke AT, Wright DS, Socrates V, Declan A. Leveraging artificial intelligence to reduce diagnostic errors in emergency medicine: Challenges, opportunities, and future directions. Acad Emerg Med. 2025 Mar;32(3):327-339.
8. El-Bouri R, Taylor T, Youssef A, Zhu T, Clifton DA. Machine learning in patient flow: a review. Prog Biomed Eng (Bristol). 2021 Apr;3(2):022002.
9. Farrokhi M, Fallahian AH, Rahmani E, y cols . Current Applications, Challenges, and Future Directions of Artificial Intelligence in Emergency Medicine: A Narrative Review. Arch Acad Emerg Med. 2025 Apr 15;13(1):e45].

7.
OBJETIVOS DE SEGURIDAD DEL PACIENTE



Imagen 1. Objetivos de seguridad del paciente

La integración de la IA en la medicina de urgencias ha mostrado un gran potencial para mejorar la seguridad del paciente al abordar desafíos críticos como la prevención de errores médicos y el control de infecciones.

7.1. PREVENCIÓN DE ERRORES MÉDICOS

La prevención de errores médicos es un objetivo clave en los departamentos de urgencias (DU) donde la rapidez en la toma de decisiones puede llevar a equivocaciones. La IA ofrece herramientas para minimizar estos errores mediante sistemas automatizados que verifican procedimientos y alertan sobre discrepancias en los datos clínicos.

7.1.1 Verificación automatizada de procedimientos

Los sistemas de IA basados en algoritmos de aprendizaje automático (Machine Learning, ML) pueden verificar la adherencia a protocolos clínicos en tiempo real, reduciendo errores humanos. Por ejemplo, un sistema de soporte de decisiones clínicas basado en IA puede analizar los datos de un paciente durante el triaje y verificar si los procedimientos propuestos, como la administración de medicamentos,

cumplen con las guías clínicas. Un estudio demostró que una red neuronal artificial logró una alta precisión en la predicción de mortalidad intrahospitalaria postoperatoria, ayudando a los médicos a ajustar los procedimientos para evitar complicaciones [1]. En un caso práctico, en un DU que atiende a un paciente con dolor torácico, la IA podría verificar si se siguieron los protocolos para descartar un infarto agudo de miocardio, alertando si se omitió una prueba clave, como un electrocardiograma.

Alertas ante discrepancias en el historial clínico
Los sistemas de IA integrados en los registros electrónicos de salud (EHR) pueden identificar discrepancias en el historial clínico, como alergias no registradas o interacciones medicamentosas. Por ejemplo, un algoritmo de procesamiento de lenguaje natural (NLP) puede analizar notas clínicas y detectar inconsistencias, como una prescripción de penicilina en un paciente con alergia conocida. Un estudio mostró que un sistema de soporte de decisiones basado en IA mejoró la precisión del triaje en un DU, identificando discrepancias en los datos del paciente con una precisión superior al 99% en comparación con métodos tradicionales [2]. En un escenario real, si un paciente con antecedentes de insuficiencia renal llega al DU y se le prescribe un medicamento nefrotóxico, la IA podría emitir una alerta inmediata al médico, sugiriendo una alternativa más segura.

7.2 MEJOR CONTROL DE INFECCIONES

El control de infecciones es crucial en los DU, donde la rápida identificación y manejo de brotes puede salvar vidas. La IA permite monitorizar patrones de infecciones en tiempo real y proporciona recomendaciones basadas en datos para optimizar el aislamiento y tratamiento.

7.2.1 Identificación de brotes en tiempo real
Los algoritmos de IA pueden analizar grandes volúmenes de datos de pacientes para detectar patrones indicativos de brotes infecciosos, como picos en casos de sepsis o infecciones nosocomiales. Un estudio demostró que un modelo de aprendizaje profundo (COMPOSER) predijo sepsis en pacientes de urgencias, logrando una reducción del 17% en la mortalidad al permitir intervenciones tempranas [3]. Por ejemplo, en un hospital con un aumento repentino de casos de fiebre y síntomas respiratorios, un sistema de IA podría analizar los datos del registro electrónico y detectar un posible brote de influenza, alertando al personal para implementar medidas de control de infecciones de inmediato.

Recomendaciones sobre aislamiento y tratamiento del registro.
Se trata de generar recomendaciones personalizadas para el aislamiento y tratamiento de pacientes con infecciones, basándose en guías clínicas y datos en tiempo real. Un ejemplo es el uso de sistemas de IA que integran datos de laboratorio y signos vitales para sugerir protocolos de aislamiento en casos de infecciones resistentes, como MRSA (Staphylococcus aureus resistente a la meticilina). Un estudio destacó que los sistemas de aprendizaje automático pueden optimizar las decisiones clínicas en la gestión de infecciones nosocomiales, contribuyendo a reducir su propagación en el departamento de urgencias [4].

Referencias

1. Lee CK, Samad M, Hofer I, Cannesson M, Baldi P. Development and validation of an interpretable neural network for prediction of postoperative in-hospital mortality. NPJ Digit Med. 2021 Jan 8;4(1):8.
2. Hong WS, Haimovich AD, Taylor RA. Predicting hospital admission at emergency department triaje using machine learning. PLoS One. 2018 Jul 20;13(7): e0201016.
3. Boussina A, Shashikumar SP, Malhotra A, Owens RL, El-Kareh R, Longhurst CA, Quintero K, Donahue A, Chan TC, Nemati S, Wardi G. Impact of a deep learning sepsis prediction model on quality of care and survival. NPJ Digit Med. 2024 Jan 23;7(1):14.
4. Bates DW, Levine DM, Salmasian H, Syrowatka A, Shahian DM, Lipsitz S, Zebrowski JP, Myers LC, Logan MS, Roy CG, Iannaccone C, Frits ML, Volk LA, Dulgarian S, Amato MG, Edrees HH, Sato L, Folcarelli P, Einbinder JS, Reynolds ME, Mort E. The Safety of Inpatient Health Care. N Engl J Med. 2023 Jan 12;388(2):142-153.

8.

OBJETIVOS EDUCATIVOS Y FORMATIVOS

Objetivo Especifico	Acciones Asistidas por IA
Apoyo al aprendizaje clinico	Simulación de casos clínicos reales mediante IA Retroalimentación personalizada para residentes y estudiantes
Evaluación continua del desempño	Análisis de decisiones clínicas y su comparacion con patrones óptimos Recomendaciones de mejora basadas en IA
Impacto en el futuro de la educación médica	Integración de curriculos personalizados apoyados en IA Optimización del Aprendizaje Basado en Problemas (ABP) con escenarios dinámicos Colaboración global mediante plataformas inteligentes
Riesgos y estrategias educativas para la supervisión clinica del uso de IA	Evaluación de trabajos clínicos cuando los estudiantes han usdo PLN (ChatGPT, etc.) sin esfuerzo propio Detección de dependencia excesiva en herramientas de IA Estrategias de supervisión docente con rúbricas especficas Promoción del pensamiento critico

Imagen 1.

La integración de la IA en el ámbito de las urgencias no solo transforma la gestión operativa y clínica, sino que también redefine los objetivos educativos y formativos del personal sanitario. Estos objetivos buscan capacitar a los profesionales para aprovechar al máximo las herramientas de IA, mejorar sus competencias clínicas y adaptarse a un entorno de trabajo cada vez más tecnológico.

8.1 APOYO AL APRENDIZAJE CLÍNICO

8.1.1 Simulación de casos clínicos reales mediante IA

La integración de la IA en la educación médica está transformando la forma en que los estudiantes y residentes desarrollan habilidades clínicas, con un enfoque particular en el apoyo al aprendizaje clínico y la evaluación continua. El apoyo al aprendizaje clínico se ha visto revolucionado mediante la simulación de casos clínicos reales con IA, una herramienta que permite a los estudiantes practicar en entornos seguros y realistas. Por ejemplo, plataformas como *MedSimAI* utilizan modelos de lenguaje avanzados para generar interacciones con pacientes virtuales, mejorando la competencia comunicativa y el razonamiento clínico [1] Este enfoque ha demostrado ser especialmente útil en la formación de los primeros años, donde los estudiantes pueden simular encuentros con pacientes que presentan síntomas variados,

desde enfermedades comunes hasta casos complejos, recibiendo retroalimentación inmediata basada en marcos de evaluación establecidos como la *Master Interview Rating Scale (MIRS)* [2] . Otro ejemplo notable es el uso de grandes modelos de lenguaje (LLM) para simular conversaciones de historia clínica es el *Clinical Reasoning Indicator - History Taking Inventory (CRI-HTI)* con aumento de 3.02 a 3.60 en solo cuatro sesiones [3].

8.1.2 Retroalimentación personalizada para residentes y estudiantes

Diversos estudios han demostrado que los sistemas basados en modelos de lenguaje (LLM) pueden analizar patrones de interacción de los estudiantes y ofrecer sugerencias personalizadas que fortalecen el aprendizaje autodirigido. Estas plataformas no solo identifican áreas de mejora —como la recolección de datos clínicos o la formulación de hipótesis diagnósticas—, sino que también orientan al estudiante para establecer objetivos de aprendizaje y reflexionar sobre su progreso.

Por ejemplo, en un estudio piloto con 104 estudiantes de medicina, la plataforma **MedSimAI** no solo incrementó el compromiso y la participación, sino que también promovió la autorregulación del aprendizaje. En uno de los escenarios clínicos, un estudiante que omitió preguntar antecedentes epidemiológicos recibió una recomendación automatizada para revisar los pasos de anamnesis enfocados en exposición geográfica. A partir de esta retroalimentación, el estudiante formuló un objetivo personal de mejora y, al repetir la simulación, mostró un progreso significativo. Este tipo de interacción evidencia cómo los sistemas impulsados por IA pueden fomentar hábitos de aprendizaje autónomo esenciales para el desarrollo profesional médico.[1].

8.2 EVALUACIÓN CONTINUA DEL CONOCIMIENTO

Hasta la actualidad, la evaluación en medicina tradicionalmente se sustenta en exámenes teóricos y en evaluaciones prácticas limitadas y esporádicas, lo que restringe una visión integral y longitudinal del progreso del estudiante. Este enfoque, centrado principalmente en la memorización y en pruebas de destreza puntual, presenta limitaciones para identificar de manera temprana las competencias clínicas y de conocimiento que requieren refuerzo. En este contexto, la IA ofrece un cambio hacia modelos de evaluación continua, caracterizados por la objetividad, la personalización y la capacidad de generar retroalimentación temprana y adaptativa conforme evoluciona el aprendizaje del estudiante.

8.2.1 Análisis de decisiones clínicas

Los sistemas inteligentes pueden registrar y analizar las decisiones clínicas tomadas en simulaciones o en la práctica supervisada. Posteriormente, comparan dichas decisiones con patrones óptimos basados en guías clínicas y en bases de datos masivas de pacientes [4]. Este análisis permite identificar discrepancias entre la práctica del estudiante y la evidencia científica actualizada, reduciendo la brecha entre la formación y la práctica clínica real.

Una de las aplicaciones más prometedoras en este ámbito es la integración de técnicas de aprendizaje automático con métodos explicativos como SHapley Additive exPlanations (SHAP). SHAP, basado en teoría de juegos, asigna un valor de Shapley a cada característica de entrada, explicando así la contribución individual de cada variable a la predicción del modelo. Su utilización en investigación médica ha demostrado ser especialmente útil para reducir la "caja negra" de los algoritmos y facilitar la alineación entre las decisiones del

modelo y el razonamiento de los clínicos. De hecho, en estudios recientes se ha observado que las explicaciones generadas por SHAP lograron mejorar la correspondencia entre la selección de características realizada por profesionales de la salud y las del algoritmo, aumentando la confianza en el uso clínico de modelos de IA.

Un ejemplo relevante lo constituye el trabajo desarrollado en Corea del Sur con una cohorte de más de 10,5 millones de adultos y un seguimiento de 5 años. Este estudio creó un modelo de predicción de cáncer gástrico (CG) mediante aprendizaje automático, en el que la regresión logística obtuvo el mejor rendimiento (AUC: 0,708). La explicación de sus resultados a través de SHAP permitió identificar como factores de riesgo primordiales la edad avanzada, el sexo masculino, la infección por *Helicobacter pylori*, el tabaquismo activo y los antecedentes familiares de CG. Al tratarse de predictores de bajo costo y no invasivos, este modelo muestra un potencial clínico relevante para mejorar la detección temprana y optimizar programas de cribado personalizados [5].

Veamos ahora cómo SHAP y la IA mejoran la evaluación del estudiante:

- En la evaluación tradicional, el profesor suele observar solo "fotografías" del conocimiento del alumno (examen puntual). Con IA y técnicas explicativas, se pueden analizar miles de interacciones del estudiante con casos clínicos digitales, preguntas online o simuladores. Esto transforma la evaluación en algo continuo.

- Los algoritmos identifican patrones de manejo (por ejemplo, siempre falla en diagnóstico diferencial respiratorio). SHAP permite explicar *por qué* el modelo concluye que esa es la debilidad del estudiante, ofreciendo transparencia sobre qué rasgos (tiempo de respuesta, selección de variables clínicas, errores recurrentes) contribuyen más.

- Del mismo modo que en el estudio clínico SHAP identificaba los factores de riesgo más relevantes de cáncer gástrico, en educación puede señalar factores de riesgo académico (omisión de pasos de exploración, tendencia a escoger tratamientos inapropiados, falta de integración de datos de laboratorio). Esto posibilita intervenir antes de que esos errores se consoliden.

- Pero es que no solo se muestra una calificación final, sino una explicación detallada de *qué aspectos concretos contribuyeron* al resultado del estudiante. Por ejemplo: "tu baja precisión en interpretar imágenes fue el principal factor de descenso en tu respuesta (40% de peso en la predicción), seguido de la lentitud en decidir pruebas complementarias (25%)".

En medicina se busca evaluar razonamiento clínico y toma de decisiones integrada. Un modelo de IA entrenado con datos de múltiples estudiantes y pacientes simulados puede resaltar cómo cada alumno usa (o descuida) variables críticas, algo muy difícil de capturar en un examen tradicional.

Estos avances, sin embargo, no están exentos de desafíos. La dependencia excesiva de la IA puede llevar a un sesgo de automatización, donde los clínicos delegan responsabilidad sin verificar resultados, un riesgo exacerbado por la naturaleza de «caja negra» de muchos algoritmos [4]. Por ello, es crucial combinar estas tecnologías con supervisión humana y entrenamiento continuo para mitigar errores.

En conclusión, la IA ofrece un potencial transformador en la educación médica, desde simulaciones realistas hasta evaluaciones precisas,

pero su implementación debe ir acompañada de un enfoque ético y crítico para maximizar beneficios y minimizar riesgos.

8.2.2 Recomendaciones de mejora

Más allá de señalar errores, la IA tiene la capacidad de generar recomendaciones personalizadas de mejora, que incluyen sugerencias de recursos educativos, guías de práctica clínica y ejercicios adaptativos. Esto no solo fortalece el aprendizaje individual, sino que también contribuye a la estandarización de la calidad formativa entre distintas instituciones [6].
En el contexto hospitalario, esta función puede extenderse a los médicos residentes, permitiendo monitorizar el desempeño durante guardias y procedimientos, aportando un sistema de seguridad que protege al paciente y, a la vez, fortalece la formación profesional [7].

8.3 IMPACTO EN EL FUTURO DE LA EDUCACIÓN MÉDICA

La integración de estas tecnologías no busca reemplazar al tutor humano, sino potenciar su labor. La IA se convierte en un aliado pedagógico, capaz de manejar grandes volúmenes de información y ofrecer un nivel de personalización difícilmente alcanzable por métodos convencionales La **simulación realista de casos**, la **retroalimentación personalizada**, el **análisis de decisiones clínicas** y las **recomendaciones basadas en IA** representan avances que fortalecen el aprendizaje, garantizan una formación homogénea y mejoran la seguridad del paciente [8][9][10][11]. La combinación de estas herramientas con metodologías activas como el aprendizaje basado en problemas (ABP) constituye el camino hacia una educación médica más efectiva, personalizada y alineada con las necesidades del siglo XXI.

El impacto de la inteligencia artificial en el futuro de la educación médica ya es evidente y se divide en cuatro grandes subapartados: integración de currículos personalizados apoyados en IA, optimización del aprendizaje basado en problemas (ABP) con escenarios dinámicos, colaboración global mediante plataformas inteligentes, y formación médica más equitativa y estandarizada.

8.3.1 Integración de currículos personalizados apoyados en IA

La inteligencia artificial posibilita la adaptación automática de los contenidos formativos a las necesidades individuales de cada estudiante, ajustando el ritmo, el tipo de recursos y el nivel de dificultad según su progreso y resultados. Los sistemas educativos basados en IA analizan datos de evaluación y desempeño para diseñar rutas de aprendizaje individualizadas, lo que fomenta el aprendizaje autónomo y fortalece competencias diferenciadas. Esta personalización reduce tiempos de formación y mejora la retención de conocimientos clínicos relevantes.

8.3.2 Optimización del Aprendizaje Basado en Problemas (ABP) con escenarios dinámicos

La integración de IA permite crear escenarios clínicos virtuales y dinámicos, simular casos complejos y realizar retroalimentaciones inmediatas. Estas herramientas generan entornos controlados para la toma de decisiones, facilitando el razonamiento diagnóstico y la práctica clínica segura sin riesgo para los pacientes. La IA potencia el ABP al personalizar los retos y adaptar los contenidos a la evolución de las competencias del grupo. En la Universidad de Deusto, por ejemplo, la combinación de ABP y sistemas de IA podría estructurar un currículo donde los estudiantes enfrenten casos clínicos generados automáticamente, reciban retroalimentación inmediata y sean evaluados de manera continua. Esto colocaría

a la institución en la vanguardia de la formación médica en Europa, alineándose con experiencias exitosas ya implementadas en universidades relevantes [12][13].

8.3.3 Colaboración global mediante plataformas inteligentes

En un futuro ya muy cercano, las plataformas educativas basadas en IA permitirán la cooperación internacional entre estudiantes y docentes, superando barreras geográficas y temporales. Sistemas de comunicación multilingües, recursos didácticos compartidos y tutores virtuales automatizados facilitan ya el intercambio de experiencias, conocimientos y resolución de casos reales. Esto contribuirá al desarrollo de competencias globales y a la inclusión de diversos enfoques biomédicos.

8.4 RIESGOS Y ESTRATEGIAS EDUCATIVAS PARA LA SUPERVISIÓN CLÍNICA DEL USO DE IA

La irrupción de la inteligencia artificial, en especial de los modelos de lenguaje grande (LLMs), simulan razonamiento clínico con aparente fluidez humana, lo que ofrece oportunidades educativas inéditas, pero también riesgos. En medicina lo importante es el razonamiento con pensamiento crítico, algo que se alcanza con los años. La llegada de la IA puede ayudar a impulsar ese razonamiento. La inteligencia artificial no debe verse como un sustituto del médico, sino como un complemento formativo y seguro. Su verdadero valor radica en potenciar la pericia clínica humana, ayudando a los profesionales a ahorrar tiempo, acceder a información actualizada y mejorar la toma de decisiones. Una IA bien comprendida y bien usada amplía las capacidades del médico; una IA mal entendida puede poner en riesgo la seguridad del paciente.

El problema viene cuando la IA en lugar de impulsar el razonamiento lo que hace es sustituirlo, algo que en los jóvenes es más probable. Si los médicos solo usan la IA para producir respuestas sin reflexión, el proceso se convierte en una fachada cognitiva sin estructura solida detrás. Entre los peligros destacan la pérdida de habilidades adquiridas (deskilling), la falta de desarrollo de competencias esenciales (never-skilling) y la consolidación de errores por sesgos de la IA (mis-skilling). Estos riesgos son críticos ya que los modelos funcionan como cajas negras, con respuestas convincentes, pero no siempre fiables [14].

Para enfrentar estos desafíos, el pensamiento crítico se vuelve un pilar fundamental, permitiendo a los clínicos evaluar recomendaciones de IA, identificar sesgos y mantener la práctica adaptativa, es decir, alternar entre la eficiencia de rutinas conocidas y la innovación en la resolución de problemas. (Tabla 1). Los educadores deben enseñar y modelar estas competencias, transformando cada interacción con IA en un momento formativo.

Tabla 1. Estrategias educativas de supervisión ante el uso de IA

ASPECTO	MODELO / ENFOQUE	PROPÓSITO PRINCIPAL
Riesgos formativos	Deskilling, Never-skilling, Mis-skilling	Identificar y mitigar pérdida de habilidades, ausencia de competencias o aprendizajes erróneos inducidos por la IA.
Práctica adaptativa	Flexibilidad cognitiva y clínica	Alternar entre rutinas estandarizadas y resolución innovadora de problemas.
Marco DEFT-AI	Diagnosis, Evidence, Feedback, Teaching, Recommendation	Estructurar la supervisión docente y clínica en cinco ejes pedagógicos.
Modelos de interacción	Centauro y Cyborg	Definir grados de integración humano–IA, desde división crítica de tareas hasta colaboración estrecha.
Alfabetización en IA	Diseño de prompts y verificación crítica	Desarrollar competencias para interactuar, evaluar evidencias y aplicar la regla de 'verificar antes de confiar'.
Conclusión	IA como apoyo educativo y clínico	Reforzar que la IA es complemento, nunca sustituto del juicio y la pericia humana.

En este sentido, el marco **DEFT-AI** (Figura 1) constituye una estrategia estructurada para supervisar el uso de IA: Diagnosis/Discusión (explorar el razonamiento y cómo se usó la IA), Evidence (justificar con evidencias clínicas y bibliográficas), Feedback (retroalimentación y autorreflexión), Teaching (enseñanza de principios clínicos y alfabetización en IA) y Recommendation (definir condiciones seguras de uso de IA). Este enfoque ayuda a consolidar la integración crítica de la IA en la educación médica [15].



Figura 1. Marco DEFT-AI

El educador reconoce que el estudiante-residente usó IA.

A partir de ahí, sigue la secuencia DEFT–AI:

- *Diagnosis/Discusión → "¿Qué prompts usaste? ¿Cómo utilizaste la IA?"*
- *Evidence (Evidencia) → "¿Cómo verificaste la salida? ¿Hay estudios que avalen esta IA?"*
- *Feedback (Retroalimentación) → "Reflexiona: ¿cómo mejorarías tu uso de la IA?"*
- *Teaching (Enseñanza) → El educador enseña principios de razonamiento clínico, prompting y verificación.*
- *Recommendation (Recomendación) → Conclusión: cuándo y cómo puede usar IA de forma segura.*

Modelos de interacción Humano/IA
En el debate actual sobre la colaboración entre humanos e IA se han descrito dos modelos de interacción: **el modelo Centauro** y **el modelo Cyborg**.

- El **modelo Centauro** se refiere a una división de tareas con supervisión crítica: el humano delega a la IA aquellas actividades que son más rutinarias, mecánicas o que requieren gran capacidad de cálculo, pero conserva siempre la capacidad de supervisión y la decisión final. Un ejemplo clásico se encuentra en la radiología: un sistema de IA puede realizar un pre-análisis de cientos de imágenes en busca de patrones anormales, reduciendo el tiempo de cribado, mientras que **el radiólogo valida** el resultado y decide el diagnóstico definitivo. Otro caso es la urgencia hospitalaria, donde un sistema de triaje automatizado clasifica inicialmente a los pacientes, pero **el médico revisa y confirma** antes de que se ejecute cualquier decisión crítica.
- En contraste, el **modelo Cyborg** implica una integración estrecha y fluida entre humano e IA, de modo que ambas partes trabajan de manera simbiótica, como si fueran un único sistema ampliado. En este caso, no hay una división rígida de tareas, sino una interacción dinámica y constante. Ejemplos de este enfoque pueden verse en herramientas de redacción clínica asistida por IA, donde **el médico comienza un informe y la IA completa frases o sugiere diagnósticos diferenciales en tiempo real**, generando un proceso creativo conjunto. Otro ejemplo se encuentra en la **cirugía asistida por robot**, en la que el cirujano no solo supervisa, sino que interactúa de manera continua con el sistema, ajustando y recibiendo retroalimentación inmediata de la IA en cada movimiento.

En síntesis, el modelo Centauro enfatiza la supervisión crítica con un reparto claro de funciones, mientras que el modelo Cyborg apuesta por la fusión operativa humano–IA. Ambos enfoques no son excluyentes y, de hecho, probablemente coexistan en el futuro de la medicina, dependiendo del contexto clínico y del nivel de riesgo asociado.

Alfabetización en IA en Medicina
La alfabetización en inteligencia artificial (IA) es una competencia esencial para los profesionales de la salud del siglo XXI. No se trata solo de saber usar herramientas digitales, sino de comprender cómo y cuándo la IA puede apoyar el razonamiento clínico y la toma de decisiones médicas.

- Un primer paso es **reconocer cuándo se está interactuando con una IA**. Hoy en día, muchas plataformas —desde sistemas de apoyo diagnóstico hasta asistentes de redacción de informes— utilizan algoritmos inteligentes. Saber identificar estos momentos permite al profesional usar la herramienta de forma crítica, entendiendo sus límites y riesgos. Por ejemplo, si un médico utiliza un asistente de IA para resumir la historia clínica de un paciente, debe saber que el texto generado no es un documento oficial ni necesariamente exacto. La IA puede cometer errores de interpretación o generar información plausible pero incorrecta.
- Otro aspecto clave de la alfabetización en IA es **evaluar las herramientas y los resultados según los principios de la medicina basada en la evidencia (MBE)**. Así como un médico no adoptaría un nuevo fármaco sin revisar los ensayos clínicos que lo respaldan, tampoco debería confiar ciegamente en una herramienta de IA sin entender cómo fue validada, cuál es su precisión y en qué contexto fue entrenada.

Por ejemplo, si una aplicación promete "predecir riesgo de diabetes" mediante una foto del rostro, el profesional debe preguntarse: ¿qué evidencia científica respalda esa afirmación?¿cuál es la población con la que se entrenó el modelo?¿se han publicado resultados revisados por pares? Este tipo de cuestionamiento protege al paciente y mantiene el rigor clínico.

- **Diseño de prompts y pensamiento crítico.** Saber diseñar prompts efectivos (es decir, las instrucciones que se dan a la IA) también es parte de la alfabetización digital moderna. Un buen prompt puede mejorar la calidad y relevancia de la respuesta. Por ejemplo, en lugar de escribir: "explícame la insuficiencia cardíaca." un médico puede formular: "resume la fisiopatología de la insuficiencia cardíaca en lenguaje accesible para un paciente de 60 años sin formación médica." Esto orienta a la IA a generar una respuesta más útil, empática y precisa.
- Finalmente, la regla de oro de la alfabetización en IA es **"verificar antes de confiar"**. Toda información o recomendación generada por un modelo debe ser revisada y contrastada con fuentes confiables y con el juicio clínico del profesional. Por ejemplo, si una IA sugiere un esquema terapéutico para hipertensión, el médico debe confirmarlo con las guías clínicas oficiales (como las de la ESC o la AHA) antes de aplicarlo en la práctica.

8.4.1 Evaluación de trabajos clínicos cuando los estudiantes han usado PLN (Chat GPT, Gemini, Claude,Perplexity, Grok, Copilot …) sin esfuerzo propio (copiar y pegar)

La llegada de ChatGPT y otros modelos de lenguaje a la educación médica está transformando el modo en que los alumnos preparan sus trabajos clínicos. Estas herramientas pueden generar diagnósticos diferenciales, planes terapéuticos o resúmenes con aparente rigor académico en pocos segundos. El problema es que el estudiante puede limitarse a copiar y pegar respuestas de la IA, sin análisis crítico ni razonamiento propio. Como hemos dicho anteriormente en lugar de que la IA ayude al razonamiento en muchos casos lo sustituye. Los docentes necesitan estrategias para detectar estas situaciones y, más importante aún, para evaluar el pensamiento crítico real del alumno más allá del texto presentado. Aunque ya hemos comentado algunas de ellas merece la pena estructurarlas a pesar de alguna repetición poniendo CHAT GPT como procesador del lenguaje.

a). Cambiar el foco: del producto al proceso

- No basta con corregir el informe escrito. Lo importante es indagar cómo llegó el alumno a esas conclusiones.
- Pregunte directamente:
  - *"¿Qué prompt (entrada de texto que proporcionas a la IA para iniciar una conversación o solicitar información específica) usaste en ChatGPT para obtener esta respuesta?"*
  - *"¿Qué parte validaste tú con bibliografía clínica?"*
  - *"Si ChatGPT hubiera cometido un error, ¿cómo lo habrías detectado?"*

De esta manera, el profesor desplaza la evaluación hacia la capacidad de análisis crítico y validación, no hacia la prosa del documento.

b). Uso del marco DEFT–AI

Sobre la base de lo ya comentado en el artículo del NEJM [14] Savaria y cols [15] proponen el modelo DEFT–AI (Diagnosis, Evidence, Feedback, Teaching, AI-engagement recommendation) adaptado como rúbrica de evaluación. Veámoslo más detallado:

1. **Diagnosis / Discussion** → Pida al alumno explicar con sus propias palabras el razonamiento clínico y cómo interactuó con la IA (qué preguntó, qué aceptó, qué descartó).

2. **Evidence** → Evalúe si aporta referencias, guías o artículos que respalden (o contradigan) lo que dijo ChatGPT.
3. **Feedback** → Ofrezca comentarios específicos sobre su razonamiento, señalando lagunas o dependencias excesivas de la IA.
4. **Teaching** → Aproveche la ocasión para reforzar principios de razonamiento clínico y de uso responsable de la IA.
5. **AI Recommendation** → Indique al alumno cómo debería emplear la IA en adelante (ej. como apoyo, no sustituto del análisis).

c). Estrategias prácticas para docentes

- Entrevista breve al presentar el trabajo: 5 minutos de preguntas orales sobre los pasos seguidos. Muchas veces revela si hubo reflexión propia o simple copia.
- Pedir versión "sin IA": Solicitar que rehaga un esquema breve del caso sin consultar la herramienta, para comparar.
- Detectar automatismos: Frases genéricas, listas demasiado completas o sin jerarquización suelen ser huella de ChatGPT.
- Evaluar prompts: El alumno debería mostrar qué instrucciones dio a la IA y cómo refinó las respuestas.
- Aplicar el marco centauro–cyborg: los alumnos pueden actuar como *centauro* (dividen tareas: IA para resumir, alumno para analizar) o *cyborg* (fusión estrecha con IA). El profesor debe comprobar si supo elegir el estilo adecuado según el riesgo del caso.

d). Guía de evaluación sugerida

Esta guía (Tabla 2) está diseñada para ayudar a los profesores a evaluar trabajos clínicos que han sido elaborados con apoyo de ChatGPT u otras herramientas de inteligencia artificial. El énfasis está en valorar el razonamiento crítico y el uso responsable de la IA, más que el producto escrito.

Interpretación de la puntuación

- 0–10 puntos → Dependencia ciega de IA, sin razonamiento propio.

Tabla 2. Guía de evaluación de trabajos académicos

CRITERIO (DEFT–AI)	0–1 PUNTOS (DEFICIENTE)	2–3 PUNTOS (INTERMEDIO)	4–5 PUNTOS (AVANZADO)
Diagnosis / Discusión (¿Explica el razonamiento clínico y cómo interactuó con la IA?)	No explica su proceso; se limita a presentar el texto generado por IA.	Describe parcialmente su razonamiento o el uso de IA, pero sin claridad.	Explica paso a paso cómo pensó el caso y cómo integró/ajustó la respuesta de la IA.
Evidence / Evidencia (¿Apoya sus decisiones con fuentes válidas?)	No aporta bibliografía ni guías.	Usa alguna referencia, pero limitada o poco crítica.	Contrasta la respuesta de la IA con guías clínicas, estudios o consensos, señalando concordancias y discrepancias.
Feedback / Autorreflexión (¿Reconoce limitaciones de su propio análisis y del uso de IA?)	No identifica errores ni limitaciones.	Reconoce alguna limitación, pero sin profundizar.	Reflexiona críticamente sobre su desempeño y sobre sesgos/errores posibles de la IA.
Teaching / Aprendizaje demostrado (¿Qué muestra haber aprendido del caso y del uso de IA?)	No evidencia aprendizaje nuevo; repite la salida de IA.	Identifica algún aprendizaje, pero poco elaborado.	Demuestra haber extraído lecciones clínicas y sobre el uso responsable de IA.
AI Engagement / Uso de IA (¿Cómo utilizó la IA: pasivo vs crítico?)	Uso pasivo: copia/pega sin control.	Uso parcial: ajusta algo, pero sin validar a fondo.	Uso crítico: plantea prompts adecuados, valida respuestas, descarta errores y justifica decisiones.

- 11–18 puntos → Uso parcial de IA con algo de análisis crítico. Necesita supervisión estrecha.
- 19–25 puntos → Uso crítico y reflexivo de IA. Integra adecuadamente razonamiento clínico y apoyo tecnológico.

Cómo aplicarla en la práctica docente

1. Revisión del trabajo escrito → Señalar posibles signos de IA (estilo impersonal, listas extensas, falta de ejemplos clínicos propios).
2. Mini-entrevista (5 minutos) → Hacer 2–3 preguntas rápidas ya comentadas :¿qué prompts usaste?¿qué parte contrastaste con bibliografía?dame un ejemplo de error que pudo cometer la IA en este caso.
3. Asignación de puntuación en cada criterio según las respuestas y el documento entregado.

e). Mensaje clave para profesores

El objetivo no es prohibir los PLN, sino enseñar a usarlos bien. Los alumnos deben comprender que la IA es un punto de partida, nunca la respuesta final. La evaluación debe centrarse en:

- ¿Reconoce el alumno las limitaciones de la IA?
- ¿Es capaz de verificar y corregir errores?
- ¿Integra lo que ofrece la IA con sus propios conocimientos clínicos?

Por tanto, cuando un trabajo clínico parece demasiado "perfecto" o poco personal, el verdadero examen es oral, breve y centrado en el razonamiento. Aplicar el esquema DEFT–AI ofrece un marco claro y reproducible para guiar esa evaluación.

8.4.2 Detección de dependencia excesiva en herramientas de IA

La incorporación de herramientas basadas en IA en la redacción académica y otras tareas relacionadas ha crecido de forma exponencial. Si bien ofrecen ventajas claras, como hemos comentado, el uso indebido o la dependencia excesiva de estas herramientas pueden comprometer la integridad académica, la originalidad, y la calidad científica del trabajo [16].

Ventajas del uso de herramientas ia

Preguntamos a Copilot un listado de las ventajas de utilizar la IA, su respuesta fué:

- Se emplean herramientas basadas en IA para escanear grandes volúmenes de literatura académica de forma rápida y eficiente.
- Los asistentes de escritura con IA se han vuelto cada vez más sofisticados para generar textos con una calidad similar a la humana.
- Los modelos de lenguaje basados en IA pueden ayudar a los autores que no son hablantes nativos de inglés a producir manuscritos de alta calidad y bien escritos.
- Capacidad de gestionar grandes cantidades de datos de forma eficiente.
- Las herramientas de IA reducen el riesgo de plagio al detectar similitudes involuntarias entre manuscritos recién redactados y trabajos previamente publicados.
- También se están desarrollando sistemas de IA para facilitar el proceso de revisión por pares. Las herramientas automatizadas utilizan la IA para analizar manuscritos, comprobar su integridad, el cumplimiento de las directrices de las revistas e incluso sugerir posibles revisores.
- Asimismo, la IA facilita la gestión de citas, ayudando a los investigadores a organizar e insertar referencias correctamente.

Desafios del uso de herramientas IA

Pero por otro lado a pesar de los beneficios de la IA en la escritura científica, su adopción conlleva diversas consideraciones y desafíos éticos.

- Es preocupante la posible dependencia excesiva de la IA para generar textos y realizar análisis críticos. Además, la autoría se vuelve cada vez más compleja con la participación de la IA en la escritura.
- Otro problema importante se refiere al potencial sesgo en el contenido generado por IA. Los modelos de IA se entrenan con grandes cantidades de datos, que a menudo reflejan sesgos existentes en la literatura publicada. Esto es especialmente preocupante en campos como la atención médica, donde la investigación sesgada podría tener graves consecuencias para la atención al paciente y los resultados del tratamiento.
- Otro problema es la pérdida del pensamiento crítico y habilidades propias. Varios estudios en educación superior han observado que el uso excesivo de IA puede reducir la capacidad de los estudiantes para resolver problemas de forma independiente, disminuir habilidades interpersonales y emocionales [17].
- Finalmente, el uso de la IA plantea inquietudes sobre la privacidad y la seguridad de los datos. A medida que la IA continúa evolucionando, es esencial que la comunidad científica establezca pautas que garanticen el uso responsable de estas herramientas, maximizando sus beneficios y mitigando los riesgos potenciales.

8.4.2.1. Cuáles son las señales de alerta de uso excesivo de generadores de Texto de IA

- Estilo uniforme sospechoso: Cuando múltiples partes de un documento presentan una "voz" muy homogénea, sin variaciones de tono, estructura de frase o complejidad léxica, podría indicar uso extensivo de generadores de texto de IA. Un estudio reciente muestra que detectores de texto generado por IA pueden identificar con una buena precisión (AUC entre 0,75 y 1,00) textos generados por modelos como ChatGPT versus escritos humanos, aunque ninguno logra fiabilidad perfecta [18][19].
- Corta pega. Aceptación pasiva de sugerencias de IA sin verificación crítica. La dependencia excesiva se evidencia cuando el usuario acepta recomendaciones, análisis o conclusiones generadas por IA sin revisarlas o validarlas con fuentes originales. En "Use of Artificial Intelligence in Scientific Writing", se señala que uno de los riesgos importantes es el uso desmedido de la IA para generar texto y hacer análisis críticos sin supervisión exhaustiva [20].
- Uso no declarado de IA en la elaboración académica: existe evidencia de que muchos trabajos académicos usan herramientas de IA sin hacer una declaración explícita de ello, lo que plantea problemas de transparencia. Por ejemplo, el conjunto de datos Academ-AI documenta casos de uso de IA no declarados en publicaciones, detectados por características lingüísticas propias de herramientas generativas [21][22].

8.4.2.2. Cuáles son las estrategias para detección del uso excesivo de generadores de Texto de IA y su minoración.

Ya hemos comentado alguna de estas estrategias que se enmarcan en actitudes institucionales y de comprobación con tecnología . Un propio genedaror de texto (Perplexity) nos resume estas estrategias:

- Políticas editoriales claras: las revistas y universidades deben exigir que los autores declaren el uso de IA en la redacción y análisis. Las políticas deben definir qué se considera uso aceptable, qué debe declararse, y qué no.
- Uso combinado de herramientas de detección + revisión humana Los detectores automáticos pueden señalar patrones

sospechosos, pero deben utilizarse como complemento de la revisión humana. Herramientas como GPTZero, ZeroGPT o Corrector han mostrado un buen rendimiento, pero también falsos positivos y negativos [18].
- Formación en alfabetización de IA: enseñar a estudiantes/investigadores cómo funcionan estas herramientas, sus límites, cómo reconocer contenidos generados por IA, y cómo utilizarlas de manera ética.
- Evaluaciones diseñadas para reducir la dependencia de IA. Por ejemplo, tareas que requieren reflexión personal, análisis crítico profundo, respuestas orales, discusiones en vivo, actividades donde se documente el "proceso" de pensamiento.
- Verificación de contenidos generados por IA: Comprobar citas, datos, estadísticas, afirmaciones empíricas. Verificar que los resultados coincidan con la evidencia primaria. Si la IA produce referencias, contrastarlas con fuentes reales para evitar referencias "inventadas".

8.4.2.3. ¿Cómo funcionan las herramientas como GPTZero y ZeroGPT para detectar contenido generado por IA?

- **GPTZero** es una plataforma que detecta si un fragmento de texto fue generado por un modelo de lenguaje grande (LLM), por ejemplo, ChatGPT, Gemini, Claude, etc. Permite pegar texto o cargar documentos, y otorga un *score* (probabilidad) de que el texto sea generado por IA, señalando frases sospechosas. Tiene una versión gratuita con ciertas limitaciones (por ejemplo, número de palabras por mes o frecuencia de escaneo) [23].
- **ZeroGPT** (o "zerogpt") es otra herramienta parecida: ingreso de texto, análisis automático, que da una estimación del porcentaje de "AI vs humano", con posibilidad de subir archivos, uso web, etc. Algunas versiones son gratuitas [24].

No obstante, estas herramientas detectoras tienen limitaciones y riesgos:
- No son infalibles: hay falsos positivos (texto humano marcado como IA) y falsos negativos (texto generado por IA que no es detectado). Además, pueden ser engañadas mediante parafraseos, cambios estilísticos, etc.
- El rendimiento puede variar mucho según el idioma, el género del texto, el estilo del autor, longitud del texto (cuanto más corto, más difícil detectar correctamente).
- Confianza excesiva puede llevar a sancionar injustamente. Es importante usar estos detectores como apoyo, no como "prueba concluyente".
- Algunos detectores gratis tienen límites: número de palabras, número de escaneos, funcionalidad restringida.

8.4.2.4. Evidencia en estudios académicos

Diversos estudios recientes han investigado la capacidad de los detectores automáticos de texto generado por IA para distinguir textos generados por modelos como GPT u otros, y algunos han encontrado que simples estrategias como la paráfrasis o modificaciones menores pueden vulnerar dichos detectores:

- Krishna y cols. muestran que al parafrasear texto generado por modelos grandes (incluyendo GPT-3.5) usando un modelo especializado ("DIPPER"), se reduce drásticamente la precisión de detectores como DetectGPT, GPTZero, clasificándolos erróneamente como texto humano incluso cuando semánticamente el contenido se mantiene. Por ejemplo, la precisión de DetectGPT cae de ~70,3 % a ~4,6 % manteniendo una tasa de falsos positivos del 1 % [25].

- Otro estudio, evalúa herramientas como ZeroGPT, GPTZero encontrando que tienen niveles importantes tanto de falsos positivos como de falsos negativos. Además, demuestra que mediante la paráfrasis inducida desde ChatGPT 3.5 se puede aumentar considerablemente la tasa de falsos negativos —es decir, hacer que el texto generado por IA pase por humano— engañando a estos detectores [26].
- En un estudio sobre textos académicos del ámbito médico, se comparó la eficacia de varios detectores (Originality.ai, ZeroGPT, GPTZero, Turnitin, etc.) y de revisores humanos, en textos generados por IA y parafraseados por herramientas. Se encontró que, aunque algunos detectores mantienen buen rendimiento, la paráfrasis reduce significativamente su eficacia, y los revisores humanos también tienen dificultades, especialmente cuando los textos han sido parafraseados [27].

8.4.2.5 Sugerencia de dependencia excesiva de herramientas IA

- Texto base suficientemente largo: usar fragmentos largos mejora la precisión del detector. Si solo se analiza un párrafo corto, los resultados serán menos fiables.
- Comparar versiones: si tienes una versión del borrador sin asistencia de IA, compararla con la versión revisada con IA para ver diferencias en estilo o nivel de "previsibilidad".
- Revisar manualmente las partes marcadas como "altamente sospechosas": comprobar si hay errores, citas incorrectas, estilo muy homogéneo, etc.
- Usar múltiples detectores si es posible: si varios apuntan lo mismo, la sospecha se refuerza; si hay discrepancias, investigar más.
- Ser transparente en la publicación: declarar qué partes del trabajo usaron asistencia de IA.

8.4.3 Estrategias de supervisión docente con rubricas especificas

Las rúbricas son instrumentos que se utilizan en la evaluación educativa para calificar de manera clara y objetiva trabajos, proyectos o actividades de los estudiantes. Consisten en tablas que describen criterios específicos y distintos niveles de desempeño para cada criterio, permitiendo saber qué se espera en cada aspecto de la tarea y cómo se va a valorar [28][29][30]. Se usan para ofrecer retroalimentación detallada tanto al estudiante como al docente, indicando fortalezas, debilidades y grados de logro, lo cual facilita la autoevaluación y mejora continua. Además, las rúbricas garantizan transparencia y coherencia en las evaluaciones, reduciendo la subjetividad en la calificación y aclarando las expectativas desde el inicio del proceso [31].

Por ejemplo (Tabla 3), una rúbrica para evaluar un trabajo escrito puede tener criterios como organización, argumentación, ortografía y presentación. Para cada criterio, se describen niveles desde «excelente» hasta «necesita mejorar», con descripciones claras. Así, el docente marca el nivel alcanzado y puede explicar al estudiante qué debe mejorar y cómo.

En suma, las rúbricas estructuran la evaluación para hacerla más justa, educativa y formativa.

8.4.4 Promoción del pensamiento critico

Históricamente, el pensamiento crítico ha sido un objetivo primordial de la educación, para promover la habilidad de analizar hechos, generar conexiones y evaluar argumentos de manera lógica. Aunque existe preocupación sobre que la dependencia excesiva de la IA pueda limitar la autonomía y capacidad crítica de los estudiantes, su integración bien manejada puede potenciar habilidades analíticas y reflexivas al proveer los datos y escenarios necesarios para el razonamiento profundo. La IA puede ser una aliada en enseñar a los

Tabla 3. Rúbrica de Evaluación

CRITERIO	EXCELENTE (5)	BUENO (4)	ACEPTABLE (3)	MEJORABLE (2)	DEFICIENTE (1)
Organización y estructura	Trabajo con estructura clara: introducción, desarrollo y conclusión coherentes y bien definidas.	Estructura clara, pero con pequeñas incoherencias.	Estructura básica, con algunas partes confusas.	Estructura poco clara que dificulta comprensión.	Carece de estructura coherente.
Claridad y coherencia de ideas	El texto es claro, con ideas lógicas y bien enlazadas.	Ideas mayormente claras y coherentes.	Algunas ideas están poco claras o poco conectadas.	Ideas confusas o poco conectadas.	Texto incoherente y difícil de entender.
Contenido y argumento	Contenido profundo, bien argumentado y fundamentado con ejemplos.	Contenido adecuado con algunos argumentos sólidos.	Contenido superficial o argumentación débil.	Contenido poco desarrollado y argumento pobre.	Contenido irrelevante o sin argumentos claros.
Ortografía y gramática	Sin errores ortográficos ni gramaticales.	Muy pocos errores que no afectan la comprensión.	Algunos errores que afectan leve comprensión.	Errores frecuentes que dificultan comprensión.	Numerosos errores graves que impiden entendimiento.

estudiantes no solo a encontrar respuestas, sino a hacer las preguntas correctas [32].

La IA generativa, como chatbots, puede facilitar el acceso a gran cantidad de información y ayudar a plantear preguntas complejas que estimulen la indagación y la evaluación crítica, en lugar de simplemente entregar respuestas fáciles. Como hemos visto antes la alfabetización digital en IA es clave para que los estudiantes aprendan no solo a usar estas herramientas, sino también a cuestionar la validez y los sesgos de las fuentes generadas, fortaleciendo así el pensamiento crítico [33].

La verdadera inteligencia no reside únicamente en reconocer lo evidente, sino en atreverse a pensar y expresar lo improbable de manera coherente. En medicina, esto se refleja en la capacidad de identificar tanto una enfermedad rara como una presentación atípica de un cuadro frecuente. Para ello, los buenos médicos combinan dos modos de pensamiento complementarios: uno rápido, intuitivo y de bajo esfuerzo cognitivo, comparable al «ojo clínico», y otro más lento, analítico y deliberado, que corresponde al razonamiento clínico hipotético-deductivo y dialéctico, donde se evalúan posibilidades, se plantean hipótesis y se contrastan con la evidencia. Esta dualidad muestra cómo el pensamiento crítico y la inteligencia artificial se entrelazan en la práctica médica: la primera aporta flexibilidad y capacidad de cuestionamiento, mientras que la segunda ofrece apoyo analítico y patrones probabilísticos. Ambas dimensiones no se excluyen, sino que se potencian mutuamente en la toma de decisiones clínicas [34].

8.4.5. Plataformas y webs de Inteligencia Artificial Médica

En los últimos años, el escenario de la Inteligencia Artificial Médica ha crecido exponencialmente, abarcando desde el análisis de imágenes y la documentación clínica automatizada, hasta la investigación farmacéutica y

la personalización de tratamientos. A continuación, se presenta una tabla con una selección de plataformas y webs especializadas en IA médica. Estas herramientas ilustran la diversidad de enfoques actuales —clínicos, operativos, de investigación y tecnológicos— que impulsan la transformación digital en la práctica sanitaria.

Tabla 4. Plataformas y webs especializadas en IA médica

NOMBRE / WEB / PLATAFORMA	TIPO / ENFOQUE PRINCIPAL	DESCRIPCIÓN BREVE	NOTAS / PARTICULARIDADES
Viz.ai	Coordinación clínica / imagen médica	Analiza imágenes médicas con algoritmos de IA para alertas y optimizar flujos clínicos (https://www.viz.ai)	Cuenta con más de 50 algoritmos aprobados en EE.UU.
Heidi Health	Scribe médico automatizado	Convierte las consultas médico–paciente en notas clínicas estructuradas mediante IA (https://www.heidihealth.com)	Se integra con sistemas de registros médicos (EHR).
Aidoc	Análisis de imagen radiológica	Plataforma de IA para priorizar diagnósticos urgentes en radiología (https://www.aidoc.com)	Muy usada para detectar ACV, hemorragias y embolias.
MONAI	Framework / código abierto	Librerías de IA para imágenes médicas: segmentación, clasificación, registro (https://monai.io)	Usado en investigación e implementación clínica.
OpenEvidence	Soporte de decisión clínica / búsqueda médica	Motor de búsqueda médica con IA que cita publicaciones científicas (https://openevidence.com)	Incluye DeepConsult para casos clínicos complejos.
Notable Health	Automatización de operaciones sanitarias	Personaliza flujos de trabajo clínicos y administrativos con IA (https://www.notablehealth.com)	Optimiza tareas administrativas repetitivas.
IBM Watson Health	IA en salud amplia	Procesa datos clínicos con IA y NLP para apoyo diagnóstico (https://www.ibm.com/watson-health)	Proyectos en oncología, imagen médica, etc.
PathAI	Patología digital / diagnóstico	Aprendizaje profundo para interpretar muestras patológicas (https://www.pathai.com)	Reduce errores humanos en anatomía patológica.
Keragon	Automatización / operaciones en salud	IA para automatizar procesos clínicos y administrativos (https://www.keragon.com)	Integra sistemas clínicos y administrativos (EHR, CRM).
Aiddison	Descubrimiento de fármacos	IA para identificar moléculas candidatas a fármacos (https://www.aiddison.com)	Aplicada a investigación farmacéutica.
BioMorph	Análisis predictivo molecular	Predice efectos de compuestos mediante modelos de IA (https://www.biomorph.ai)	Útil en etapas tempranas de I+D farmacéutico.
Microsoft Dragon Copilot	Asistente clínico / documentación	Genera notas clínicas a partir de conversaciones médico–paciente (https://www.microsoft.com)	Evolución del sistema DAX de Nuance.
Tempus	Datos clínicos / medicina personalizada	Integra datos genómicos y clínicos para terapias personalizadas (https://www.tempus.com)	Usado en oncología y ensayos clínicos.
Butterfly iQ	Dispositivo / hardware + IA	Ultrasonido portátil con guía de IA para análisis (https://www.butterflynetwork.com)	Hace accesible la imagen médica en entornos con pocos recursos.

NOMBRE / WEB / PLATAFORMA	TIPO / ENFOQUE PRINCIPAL	DESCRIPCIÓN BREVE	NOTAS / PARTICULARIDADES
SenseCare	Investigación / imágenes 3D	Plataforma con visualización 3D, segmentación y registro de imágenes (https://arxiv.org/abs/2004.07031)	Facilita investigación y planificación quirúrgica.
MAIA	Plataforma colaborativa de IA médica	Gestión de datos, modelos y despliegue de IA médica (https://arxiv.org/abs/2507.19489)	Promueve interoperabilidad médico–tecnológica.

REFERENCIAS

1. Hicke Y, y cols MedSimAI: Simulation and Formative Feedback Generation to Enhance Deliberate Practice in Medical Education. arXiv preprint arXiv:2503.05793. 2025. Accesible en: https://arxiv.org/pdf/2503.05793
2. Pfeiffer CA. The Master Interview Rating Scale (MIRS): an instrument for faculty, students, and standardized patients to use for teaching and evaluation. https://www.dmu.edu/wp-content/uploads/Master-Interview-Rating-Scale.pdf
3. Brügge E, Ricchizzi S, Arenbeck M, Keller MN, Schur L, Stummer W, Holling M, Lu MH, Darici D. Large language models improve clinical decision making of medical students through patient simulation and structured feedback: a randomized controlled trial. BMC Med Educ. 2024 Nov 28;24(1):1391].
4. Magrabi F, Ammenwerth E, McNair JB, De Keizer NF, Hyppönen H, Nykänen P, Rigby M, Scott PJ, Vehko T, Wong ZS, Georgiou A. Artificial Intelligence in Clinical Decision Support: Challenges for Evaluating AI and Practical Implications. Yearb Med Inform. 2019 Aug;28(1):128-134.
5. Park B, Kim CH, Jun JK, Suh M, Choi KS, Choi IJ, Oh HJ. A Machine Learning Risk Prediction Model for Gastric Cancer with SHapley Additive exPlanations. Cancer Res Treat. 2025 Jul;57(3):821-829.
6. Wartman SA, Combs CD. Reimagining Medical Education in the Age of AI. AMA J Ethics. 2019 Feb 1;21(2): E146-152.
7. Kolachalama VB, Garg PS. Machine learning and medical education. NPJ Digit Med. 2018 Sep 27;1:54.
8. Cooper A, Rodman A. AI and medical education — a 21st-century Pandora's box. N Engl J Med 2023; 389: 385-7.
9. Lavigne E, Lopez A, Frandon J, et al. AI-standardized clinical examination training on OSCE performance. NEJM AI 2025;2(8) (https://ai.nejm.org/doi/10.1056/AIoa2500066). 7.
10. Boscardin CK, Gin B, Golde PB, Hauer KE. Chatgpt and generative artificial intelligence for medical education: potential impact and opportunity. Acad Med 2024;99:22-7.
11. Waldock WJ, Lam G, Baptista A, Walls R, Sam AH. Which curriculum components do medical students find most helpful for evaluating AI outputs? BMC Med Educ 2025;25:195.
12. Trullàs JC, Blay C, Sarri E, Pujol R. Effectiveness of problem-based learning methodology in undergraduate medical education: a scoping review. BMC Med Educ. 2022 Feb 17;22(1):104.
13. [Hui Z, Zewu Z, Jiao H, Yu C. Application of ChatGPT-assisted problem-based learning teaching method in clinical medical education. BMC Med Educ. 2025 Jan 11;25(1):50.
14. Abdulnour RE, Gin B, Boscardin CK. Educational Strategies for Clinical Supervision of Artificial Intelligence Use. N Engl J Med. 2025 Aug 21;393(8):786-797.
15. Savaria MC, Min S, Aghagoli G, Tunkel AR, Hirsh DA, Michelow IC. Enhancing the one-minute preceptor method for clinical

teaching with a DEFT approach.Int J Infect Dis 2022; 115: 149-53.

16. Khan MK, Ferdous J, Mourshed G, Hossain SB. Use of Artificial Intelligence in Scientific Writing. Mymensingh Med J. 2025 Apr;34(2):592-597.
17. Klimova B, Pikhart M. Exploring the effects of artificial intelligence on student and academic well-being in higher education: a mini-review. Front Psychol. 2025 Feb 3;16:1498132.
18. Erol G, Ergen A, Gülşen Erol B, Kaya Ergen Ş, Bora TS, Çölgeçen AD, Araz B, Şahin C, Bostancı G, Kılıç İ, Macit ZB, Sevgi UT, Güngör A. Can we trust academic AI detective? Accuracy and limitations of AI-output detectors. Acta Neurochir (Wien). 2025 Aug 7;167(1):214.
19. Gao CA, Howard FM, Markov NS, Dyer EC, Ramesh S, Luo Y, Pearson AT. Comparing scientific abstracts generated by ChatGPT to real abstracts with detectors and blinded human reviewers. NPJ Digit Med. 2023 Apr 26;6(1):75. doi: 10.1038/s41746-023-00819-6
20. Khan MK, Ferdous J, Mourshed G, Hossain SB. Use of Artificial Intelligence in Scientific Writing. Mymensingh Med J. 2025 Apr;34(2):592-597 Disponible en: https://www.researchgate.net/publication/390377312_Use_of_Artificial_Intelligence_in_Scientific_Writing
21. Glynn A Suspected Undeclared Use of Artificial Intelligence in the Academic Literature: An Analysis of the Academ-AI Dataset Disponible en https://doi.org/10.48550/arXiv.2411.15218
22. Kizilcec RF, Prabhakaran V, Zheng C, Park E, Zeng J. Academ-AI: A dataset of undisclosed AI-generated text in academic writing. *arXiv*. 2024. Disponible en: https://arxiv.org/abs/2411.15218
23. GPTZero Accesible en: https://gptzero.me/?utm_source=chatgpt.com
24. zerogpt: Accesible en : https://www.zerogpt.com/?utm_source=chatgpt.com
25. Krishna K, Song Y, Karpinska M, Wieting J, Iyyer M. *Paraphrasing evades detectors of AI-generated text, but retrieval is an effective defense*. NeurIPS; 2023. arXiv:2303.13408.
26. Weichert J, Dimobi C. *DUPE: Detection Undermining via Prompt Engineering for Deepfake Text*. 2024. arXiv:2404.11408 Disponible en: https://arxiv.org/abs/2404.11408
27. Liu JQJ; et al. *The great detectives: humans versus AI detectors in catching medical writing after paraphrasing*. BMC Med Educ. 2024;24:1.
28. Espinoza B y cols Autoevaluación del aprendizaje clínico en estudiantes de enfermería. Validación de rúbrica Disponible en https://doi.org/10.14482/zp.34.610.73
29. Shipman D., Roa M., Hooten J., *et al*. Using the analytic rubric as an evaluation tool in nursing education: The positive and the negative.Nurse Education Today, 32 (2012), pp. 246-249 Disponible en: http://dx.doi.org/10.1016/j.nedt.2011.04.007
30. Malini R.Y., Andrade H..A review of rubric use in higher education. Assessment & Evaluation in Higher Education, 35 (2010), pp. 435-44.
31. Gatica Lara F y cols Cómo elaborar una rubrica Investigación en educación medica 2013 Disponible en: https://www.elsevier.es/es-revista-investigacion-educacion-medica-343-articulo-como-elaborar-una-rubrica-S200750571372684X
32. Mayol J inteligencia Artificial y pensamiento critico 2024 Disponible en : https://juliomayol.com/inteligencia-artificial-y-pensamiento-critico/
33. Barrios Sánchez, Freddy, & Carazas Durand, Cecilia Raquel. (2025). Alfabetización desde la inteligencia artificial en universitarios: un artículo de revisión sistemática. *Revista InveCom*, *5*(4), e504088. Epub 12 de junio de 2025.Disponible en https://doi.org/10.5281/zenodo.14934489
34. Cuestas E. El razonamiento clínico y la inteligencia artificial [[Clinical reasoning and artificial intelligence]. Rev Fac Cien Med Univ Nac Cordoba. 2023 Dec 26;80(4):306-310.

9.

RECOMENDACIONES DE MEJORA BASADAS EN IA PARA LA EVALUACIÓN CONTINUA EN LA ACTUACIÓN EN MEDICINA DE URGENCIAS



Imagen 1

Como hemos visto en anteriores capítulos, la IA puede transformar la evaluación continua del trabajo en medicina de urgencias, proporcionando retroalimentación específica, recursos educativos personalizados y un enfoque basado en datos para mejorar la práctica clínica. Su implementación requiere una infraestructura tecnológica robusta y un compromiso con la capacitación del personal, pero los beneficios en términos de seguridad del paciente y desarrollo profesional son significativos.

Veamos un marco detallado con ejemplos prácticos y concretos para médicos de urgencias, residentes y estudiantes, con el fin de optimizar sus decisiones clínicas y mejorar sus habilidades a través de herramientas de IA.

9.1 CONTEXTO Y PROPÓSITO

Las recomendaciones de mejora basadas en IA buscan analizar el rendimiento y eficacia de los profesionales de urgencias mediante la comparación de sus decisiones clínicas con patrones óptimos derivados de datos médicos basados en evidencia. Este enfoque permite identificar áreas de mejora, ofrecer retroalimentación específica y personalizada, y fomentar un aprendizaje continuo en un entorno de alta presión como las urgencias.

9.2 PROGRAMA PRÁCTICO: RECOMENDACIONES DE MEJORA BASADAS EN IA

9.2.1 Estructura del Programa

El programa se basa en un sistema de IA que evalúa el desempeño clínico en tiempo real o retrospectivamente, utilizando datos de historias clínicas electrónicas (HCE), simulaciones y registros de decisiones tomadas durante la atención de pacientes. En la (Tabla 1) se detalla el proceso en pasos claros, con ejemplos prácticos.

Paso 1: Recopilación de Datos Clínicos

- Descripción: La IA recopila datos de las decisiones clínicas tomadas por el médico o residente durante la atención de un caso en urgencias (diagnósticos, tratamientos, pruebas ordenadas, tiempos de respuesta, etc.).

- Herramientas: Integración con Historia Clinica Electrónica (HCE) (ej. Epic, Cerner, que son plataformas digitales utilizadas en hospitales y clínicas para gestionar la información médica de los pacientes) o plataformas de simulación clínica (ej. software como Body Interact[1].

- Ejemplo Práctico:
  - Un residente atiende a un paciente con dolor torácico. La IA registra que el residente ordena un electrocardiograma (ECG) y un panel de biomarcadores cardíacos, pero no solicita una radiografía de tórax.
  - Datos recopilados: Tiempo de orden del ECG (5 minutos tras la admisión), biomarcadores ordenados (troponina, CK-MB), diagnóstico presuntivo (síndrome coronario agudo).

Paso 2: Comparación con Patrones Óptimos

- Descripción: La IA compara las decisiones clínicas del profesional con un modelo basado en guías clínicas actualizadas (ej. AHA/ESC para síndrome coronario agudo) y datos de cohortes de pacientes similares.

Tabla 1.

PASO	DESCRIPCIÓN	EJEMPLO PRÁCTICO
Paso 1: Recopilación de Datos Clínicos	La IA recopila datos de decisiones clínicas en urgencias usando HCE y simulaciones.	Residente atiende dolor torácico, ordena ECG y biomarcadores, pero omite radiografía de tórax.
Paso 2: Comparación con Patrones Óptimos	La IA compara decisiones con guías clínicas (AHA/ESC) y bases de datos (MIMIC-III).	IA detecta omisión de radiografía de tórax en dolor torácico con factores de riesgo cardiovascular.
Paso 3: Recomendaciones Personalizadas	Genera retroalimentación breve y accionable en tiempo real o en sesiones de revisión crítica.	Recomendación: Ordenar radiografía de tórax y revisar módulo interactivo de diagnóstico diferencial.
Paso 4: Estrategias de Mejora	IA sugiere simulaciones, revisión de guías y sesiones con expertos según el nivel del profesional.	Residente completa simulación IA con caso de dolor torácico y recibe retroalimentación inmediata.
Paso 5: Seguimiento Longitudinal	La IA evalúa adherencia a guías, tiempos de respuesta y precisión diagnóstica a lo largo del tiempo.	Informe: Adherencia a guías mejoró de 80% a 92% y tiempo de respuesta bajó de 7 a 4 minutos.

- Algoritmos Utilizados: Modelos de aprendizaje automático (Machine Learning) como redes neuronales o árboles de decisión, entrenados con grandes bases de datos clínicas. Por ejemplo, Medical Information Mart for Intensive Care III (MIMIC-III), que es una base de datos pública que contiene información clínica detallada de pacientes ingresados en unidades de cuidados intensivos (UCI) del Beth Israel Deaconess Medical Center en Boston, EE. UU., entre 2001 y 2012. Es ampliamente utilizada en investigación médica y desarrollo de IA para la salud [2].

- Ejemplo Práctico:
  - La IA detecta que, según las guías, en pacientes con dolor torácico de inicio reciente y factores de riesgo cardiovascular, una radiografía de tórax es recomendada para descartar otras causas (ej. neumotórax, disección aórtica).
  - Discrepancia identificada: Omisión de la radiografía de tórax, lo cual podría retrasar un diagnóstico diferencial.

Paso 3: Generación de Recomendaciones Personalizadas

- Descripción: La IA genera retroalimentación específica basada en las discrepancias detectadas, priorizando áreas críticas para la seguridad del paciente y el aprendizaje del profesional.

- Retroalimentación: Reportes breves, entregados en tiempo real (en dispositivos móviles o HCE) o como parte de sesiones de revisión crítica (*debriefing.)*

- Ejemplo Práctico:
  - Reporte de IA para el Residente:
    - Área de Mejora: Inclusión de pruebas diagnósticas adicionales.
    - Recomendación: «En pacientes con dolor torácico y factores de riesgo cardiovascular, considera ordenar una radiografía de tórax para descartar causas no cardíacas, como neumotórax o disección aórtica, según las guías de la AHA».
    - Recurso de Aprendizaje: Enlace a un módulo interactivo sobre diagnóstico diferencial en dolor torácico, con simulaciones de casos similares.
  - Visualización: Gráfico comparativo que muestra la adherencia del residente a las guías clínicas (80% en este caso, debido a la omisión de la radiografía).

Paso 4: Implementación de Estrategias de Mejora

- Descripción: La IA sugiere estrategias de aprendizaje activo, como simulaciones adicionales, revisión de guías clínicas, o reuniones con expertos, adaptadas al nivel de experiencia del profesional.

- Herramientas: Plataformas de aprendizaje adaptativo (ej. sistemas que ajustan la dificultad de los casos según el progreso del usuario).

- Ejemplo Práctico:
  - El residente recibe una notificación en su dispositivo móvil para completar un caso simulado en una plataforma de IA, donde debe atender a un paciente con dolor torácico y decidir si ordena una radiografía de tórax.
  - La IA evalúa la decisión en tiempo real y proporciona retroalimentación inmediata: «Correcto, la radiografía de tórax fue ordenada, lo que permitió identificar un neumotórax. Continúa revisando las guías de la ESC para optimizar el diagnóstico diferencial».

Paso 5: Seguimiento y Evaluación Longitudinal

- Descripción: La IA realiza un seguimiento del desempeño a lo largo del tiempo, midiendo mejoras en la adherencia a guías clínicas, tiempos de respuesta y precisión diagnóstica.
- Métricas Clave:
- Porcentaje de adherencia a guías clínicas.
- Tiempo promedio para ordenar pruebas críticas.
- Tasa de diagnósticos correctos en simulaciones.
- Ejemplo Práctico:
  - Después de un mes, la IA genera un informe longitudinal:
    - Progreso del Residente:
      - Adherencia a guías clínicas: Mejoró de 80% a 92%.
      - Tiempo para ordenar pruebas críticas: Reducido de 7 minutos a 4 minutos.
      - Diagnósticos correctos en simulaciones: Aumentó de 75% a 90%.
    - Recomendación de Seguimiento: «Continúa practicando casos de dolor torácico en simulaciones avanzadas para consolidar el diagnóstico diferencial. Considera una sesión con un mentor para discutir casos complejos.»

9.2.2 Implementación en Medicina de Urgencias

- Infraestructura Necesaria:
  - Integración de la IA con HCE para recopilar datos en tiempo real.
  - Plataformas de simulación clínica accesibles en dispositivos móviles o computadoras.
  - Conexión a bases de datos clínicas actualizadas (ej. UpToDate, PubMed).
- Capacitación del Personal:
  - Talleres de 2 horas para enseñar a médicos y residentes cómo interpretar los reportes de IA y utilizar las recomendaciones.
  - Sesiones mensuales de debriefing con supervisores para discutir el progreso.
- Ejemplo de Flujo de Trabajo en Urgencias:
  - Un residente atiende un caso real → La IA analiza las decisiones → Genera un reporte con recomendaciones → El residente completa un módulo de simulación sugerido → La IA evalúa el progreso y ajusta las recomendaciones.

9.3 BENEFICIOS DEL PROGRAMA

- Personalización: Retroalimentación adaptada al nivel de experiencia y necesidades específicas del profesional.
- Mejora Continua: Seguimiento longitudinal que fomenta el aprendizaje a largo plazo.
- Seguridad del Paciente: Reducción de errores diagnósticos al alinear decisiones con guías basadas en evidencia.
- Eficiencia: Retroalimentación en tiempo real que permite ajustes inmediatos en la práctica clínica.

9.4 CONSIDERACIONES ÉTICAS Y TÉCNICAS

- Privacidad: Garantizar que los datos clínicos sean anónimos y cumplan con regulaciones como HIPAA (USA Health Insurance Portability and Accountability Act) [3][4].

- Transparencia: Los algoritmos de IA deben ser explicables para que los profesionales confíen en las recomendaciones.

- Limitaciones: La IA no reemplaza el juicio clínico, sino que lo complementa. Los médicos deben ser capacitados para cuestionar las recomendaciones de la IA cuando sea necesario.

9.5 CASO DE ESTUDIO PRÁCTICO

Escenario: Un residente atiende a un paciente de 45 años con disnea aguda en urgencias.

- Acciones del Residente:
  - Ordena oxígeno, pulsioximetría y una gasometría arterial.
  - Diagnóstico presuntivo: Exacerbación de asma.
  - Omite una radiografía de tórax y no considera tromboembolismo pulmonar (TEP).

- Análisis de IA:
  - Compara las decisiones con guías de la ATS/ERS (guías y estándares desarrollados conjuntamente por la American Thoracic Society (ATS) y la European Respiratory Society (ERS) y detecta la omisión de la radiografía y la falta de evaluación de riesgo para TEP (ej. puntaje de Wells).

- Recomendaciones de IA:
  - Inmediata: «Considera una radiografía de tórax para descartar neumotórax o TEP en pacientes con disnea aguda.»
  - Educativa: «Completa un módulo simulado sobre diagnóstico diferencial de disnea (15 minutos).»
  - Recurso: Enlace a un video de 5 minutos sobre el uso del puntaje de Wells para TEP.

- Resultado tras Implementación:
  - El residente completa el módulo y mejora su adherencia a guías en un 15% en casos similares durante el próximo mes.

9.6 APLICACIÓN A ENFERMERÍA EN URGENCIAS

La IA no solo puede apoyar la práctica médica, sino también la práctica de enfermería, donde la toma de decisiones rápidas, la priorización de cuidados y la vigilancia constante del paciente son esenciales. A través de análisis basados en datos, simulaciones y retroalimentación personalizada, la enfermería puede beneficiarse de un sistema de mejora continua que impacta directamente en la calidad asistencial.

9.6.1 Contexto y Propósito

En el área de urgencias, la enfermería cumple funciones críticas: triaje, monitorización, administración de tratamientos, coordinación interdisciplinaria y educación al paciente. La IA puede:

- Analizar intervenciones de enfermería en tiempo real o retrospectivamente.

- Compararlas con protocolos seguros y basados en evidencia.

- Generar recomendaciones personalizadas que optimicen la atención.

9.6.2 Programa Práctico en Enfermería

Paso 1: Recopilación de Datos de Práctica

- Qué analiza: tiempos de triaje, cumplimiento de protocolos de administración de medicación, registro de signos vitales, aplicación de medidas de seguridad (checklists, escalas de riesgo).

- Ejemplo: Enfermera clasifica a un paciente con dolor torácico como nivel 3 (urgencia relativa) en lugar de nivel 2, retrasando el ECG inicial. La IA registra este dato.

Paso 2: Comparación con Patrones Óptimos

- La IA revisa: protocolos de triaje (Manchester, ESI), guías de administración segura de fármacos, protocolos de sepsis o paro cardiorrespiratorio.

- Ejemplo: IA detecta que, según la escala de dolor y factores de riesgo, el paciente debía ser nivel 2, recomendando ECG inmediato.

Paso 3: Recomendaciones Personalizadas

- Tipo de feedback: breve, en lenguaje accesible, enfocado en intervenciones de enfermería.

- Ejemplo de retroalimentación:
  - *Inmediata:* "En pacientes con dolor torácico intenso y factores de riesgo, aumenta la prioridad de triaje a nivel 2."
  - *Educativa:* acceso a un módulo de 5 minutos sobre escalas de triaje en síndrome coronario agudo.

Paso 4: Estrategias de Mejora

- Simulaciones de escenarios (paros cardíacos, manejo de shock, administración IV en urgencias).

- Revisión periódica de protocolos de seguridad (doble chequeo de medicación, manejo de catéteres, prevención de errores en administración).

Paso 5: Seguimiento Longitudinal

- Métricas clave para enfermería:
  - Tiempo de clasificación inicial (triaje).
  - Precisión en identificación de pacientes de alto riesgo.
  - Adherencia a protocolos de administración de medicación urgente (antibióticos en sepsis, analgésicos).
  - Documentación precisa en HCE.

9.6.3 Ejemplo Concreto (Caso de Estudio)

Escenario: paciente con fiebre, taquicardia y sospecha de infección en urgencias.

- Acciones de la enfermera: monitoriza signos vitales, canaliza vía venosa y administra líquidos. No activa el protocolo de sepsis ni registra el screening completo.

- IA detecta: omisión en la aplicación del código sepsis [5].

- Recomendaciones de IA:
  - *Inmediata:* activar protocolo de sepsis y solicitar lactato venoso en coordinación con el equipo médico.
  - *Educativa:* módulo de 10 min sobre "Reconocimiento precoz de sepsis en triaje" basado en Surviving Sepsis Campaign.

- Resultado tras implementación:
  - Tiempo de activación de protocolo de sepsis mejorado de 20 min → 10 min en el siguiente mes.
  - Reducción de errores de omisión documental en un 15%.

9.6.4. Beneficios para Enfermería

- Mayor seguridad del paciente: detección temprana de fallos en triaje, monitorización o administración de medicación.

- Aprendizaje ágil y continuo: retroalimentación breve y aplicable al momento de la práctica.

- Confianza profesional: empoderamiento de enfermería al tener reportes objetivos de desempeño.
- Optimización de trabajo en equipo: integración de informes de IA tanto para médicos como para enfermeras, favoreciendo coordinación interdisciplinaria.

9.7 TABLA COMPARATIVA DE APLICACIONES DE IA EN URGENCIAS MÉDICOS VS ENFERMERÍA

Tabla 2.

EJE / DIMENSIÓN	MÉDICOS EN URGENCIAS	ENFERMERÍA EN URGENCIAS
Evaluación continua	- Sistemas de apoyo a la decisión clínica (CDSS) que sugieren diagnósticos diferenciales y priorizan gravedad. - Análisis predictivo en tiempo real para anticipar complicaciones (ej. sepsis, shock). - Feedback inmediato sobre decisiones diagnósticas comparadas con guías clínicas.	- Monitorización inteligente de signos vitales con alertas automáticas. - Evaluación del desempeño en triaje mediante algoritmos que comparan con estándares. - Retroalimentación sobre adherencia a protocolos de administración de fármacos y cuidados críticos.
Seguridad del paciente	- Detección temprana de errores de prescripción mediante algoritmos de reconciliación de fármacos. - IA aplicada a imágenes (TC, RX, ecografía) para descartar patologías críticas más rápido. - Prevención de eventos adversos mediante modelos de riesgo personalizados.	- Alarmas inteligentes que discriminan entre ruido clínico y emergencias reales (menos fatiga por alarmas). - Control de interacciones medicamentosas en administración de fármacos. - IA en control de infecciones: detección temprana de patrones en heridas, catéteres o dispositivos.
Desarrollo profesional	- Plataformas de simulación clínica con IA para entrenar en escenarios de urgencia poco frecuentes. - Evaluación automática del razonamiento clínico durante el ABP (aprendizaje basado en problemas). - Detección de brechas formativas individuales con planes de aprendizaje personalizados.	- Simuladores de alta fidelidad con IA que recrean urgencias críticas (parada cardiorrespiratoria, politrauma). - Evaluación continua de competencias técnicas (ej. canalización de vías, ventilación) y no técnicas (comunicación, liderazgo). - Itinerarios de formación adaptativos según desempeño real en urgencias.

REFERENCIAS

1. Body Interact https://bodyinteract.com/
2. Johnson, A., Pollard, T., Shen, L. *et al.* MIMIC-III, a freely accessible critical care database. *Sci Data* **3**, 160035 (2016). https://doi.org/10.1038/sdata.2016.35.
3. USA Health Insurance Portability and Accountability Act. Accesible en: https://www.cdc.gov/phlp/php/resources/health-insurance-portability-and-accountability-act-of-1996-hipaa.html

4. GDPR. (UE General Data Protection Regulation) Accesible en https://gdpr-info.eu/
5. Llopis-Roca F, López Izquierdo R, Miro O, García-Lamberechts JE, Julián Jiménez A, González Del Castillo J. Mapa de la situación actual de la atención a la sepsis en los servicios de urgencias españoles Rev Esp Quimioter. 2022 Apr;35(2):192-203.

10.

APÉNDICE

10.1 RESUMEN DE PUBLICACIONES SOBRE APLICACIONES DE IA EN URGENCIAS

En los últimos años, la IA ha adquirido un papel central en la transformación del funcionamiento de los servicios de urgencias médicas a nivel internacional. La literatura revisada identifica múltiples aplicaciones prácticas de la IA, desde la predicción de diagnósticos críticos hasta la optimización del triaje y la gestión de recursos hospitalarios. Resumimos y ampliamos el trabajo de revisión de Aleksandra S y colaboradores sobre los diferentes estudios [1] (Tabla 1).

Numerosos estudios retrospectivos y de cohortes han demostrado el potencial de los modelos de aprendizaje automático (Machine Learning, ML) para mejorar la precisión diagnóstica en situaciones críticas. Por ejemplo, investigaciones realizadas en EE. UU., Canadá, China y Taiwán han desarrollado modelos para la detección precoz de infartos agudos de miocardio, accidentes cerebrovasculares, shock séptico y riesgo de mortalidad, utilizando datos derivados de electrocardiogramas, notas de triaje y resultados de análisis de sangre. Estos modelos han sido validados en grandes cohortes, con muestras que en algunos casos superan los 200.000 pacientes.

Otra línea de aplicación destacada ha sido el uso de IA en la optimización del triaje, tanto en contextos presenciales como a través de aplicaciones móviles de autoevaluación. Estudios en Alemania y Corea del Sur han explorado la eficacia del triaje asistido por IA frente al triaje tradicional realizado por personal sanitario, reportando beneficios en términos de rapidez y precisión.

En el campo de la imagenología, los algoritmos de Deep Learning han sido entrenados para detectar anomalías en radiografías de tórax, tomografías computarizadas y análisis de imágenes oculares. Investigaciones en China, Islandia y Portugal han mostrado que la IA puede reducir significativamente el número de estudios innecesarios, mejorar la calidad diagnóstica y apoyar la toma de decisiones clínicas en tiempo real.

Por otro lado, la IA también se ha aplicado a la predicción de eventos clínicos adversos, como el delirio, el riesgo de reconsulta frecuente o el desarrollo de enfermedades infecciosas como COVID-19. En Italia, Taiwán y Ucrania, se han utilizado modelos de IA para apoyar decisiones clínicas en pacientes con enfermedades respiratorias, afecciones infecciosas o patologías inflamatorias en niños, como la enfermedad de Kawasaki.

Además, el uso de modelos de lenguaje natural (NLP) ha permitido automatizar tareas rutinarias, como la generación de notas clínicas o la extracción de información relevante de

historias médicas electrónicas. Este enfoque ha sido evaluado positivamente en entornos clínicos de Canadá y EE. UU., donde se ha mejorado la eficiencia del personal médico.
Los estudios revisados también abordan aspectos éticos y regulatorios del uso de IA, con énfasis en la necesidad de una implementación responsable, evitando sesgos, protegiendo la privacidad de los pacientes y asegurando la trazabilidad de las decisiones clínicas automatizadas. Revisiones sistemáticas y artículos de opinión provenientes de EE.UU., Polonia y Bélgica destacan tanto los beneficios como los riesgos potenciales de estas tecnologías, incluyendo la dependencia excesiva de sistemas automatizados.
En términos de participación geográfica, los estudios provienen de una diversidad de países como EE. UU., Canadá, China, Taiwán, Corea del Sur, Italia, Alemania, Portugal y Australia, lo que demuestra un interés global por integrar la IA en los entornos de atención urgente.

Referencias

1. Aleksandra S, Robert K, Klaudia K, Dawid L, Mariusz S. Artificial Intelligence in Optimizing the Functioning of Emergency Departments; a Systematic Review of Current Solutions. Arch Acad Emerg Med. 2024 Jan 27;12(1):e22. doi: 10.22037/aaem.v12i1.2110. PMID: 38572221; PMCID: PMC10988184.

Tabla 1. Resumen de publicaciones

AUTOR	AÑO	TIPO DE ESTUDIO	PAÍS	OBJETIVO	PARTICIPANTES	CAMPO
Annis	2022/09	Estudio de cohorte	EE. UU.	Desarrollar un modelo de aprendizaje automático basado en factores de riesgo para identificar rápidamente el trastorno por consumo de opioides.	345 728	Toxicología / intoxicaciones
Badal	2023/04	Revisión	EE. UU.	Formular principios rectores para el desarrollo responsable de herramientas de inteligencia artificial en salud.	Not applicable	No aplica
Bat-Orgil Bat-Erdene	2021/07	Revisión	Mongolia	Mostrar los avances en la detección automática de síntomas de ictus y la alerta a sistemas de emergencias mediante tecnologías móviles.	Not applicable	Ictus
Blomberg	2023/01	Ensayo clínico aleatorizado	Dinamarca	Investigar las características de llamadas de emergencia en las que un modelo de aprendizaje automático no reconoció la parada cardiorrespiratoria extrahospitalaria.	169 049	Parada cardiorrespiratoria

AUTOR	AÑO	TIPO DE ESTUDIO	PAÍS	OBJETIVO	PARTICI-PANTES	CAMPO
Blomberg	2021/01	Ensayo clínico aleatorizado	Dinamarca	Analizar cómo un modelo de aprendizaje automático fue entrenado para identificar la parada cardiorrespiratoria extrahospitalaria.	169 049	Parada cardiorrespiratoria
Cadamuro	2023/04	Evaluación	Austria, Italy, Croatia, Spain	Evaluar si ChatGPT es capaz de interpretar resultados de laboratorio.	10	Análisis de laboratorio
Casano	2023/03	Estudio de cohorte	Italia	Gestionar el alta segura o la hospitalización de pacientes con COVID-19 no vacunados.	779	COVID-19
Cellina	2022/12	Revisión	Italia	Revisar las aplicaciones de la inteligencia artificial en radiología de urgencias.	Not applicable	No aplica
Chamber-lin	2022/07	Estudio retrospectivo	EE. UU.	Desarrollar un algoritmo para el diagnóstico y pronóstico de neumonía por COVID-19 a partir de radiografías de tórax.	2 456	COVID-19
Chang	2022/12	Estudio de cohorte	Taiwán	Establecer un modelo de aprendizaje automático para predecir pacientes de baja gravedad con corta estancia en urgencias.	44 839	Triaje
Chang	2022/09	Revisión	Corea	Mostrar los puntos de apoyo de la IA en la toma de decisiones clínicas durante las fases de atención en urgencias.	Not applicable	No aplica
Chen	2023/05	Estudio retrospectivo	China	Desarrollar un sistema multimodal (EE-Explorer) para clasificar urgencias oftalmológicas y asistir en el diagnóstico primario mediante metadatos e imágenes oculares.	2 405	Triaje
Chen	2023/01	Estudio retrospectivo	Taiwán	Desarrollar un algoritmo predictivo de ictus basado en datos clínicos disponibles al ingreso hospitalario.	143 203	Ictus
Chen	2022/10	Ensayo clínico aleatorizado	Taiwán	Implementar un sistema en línea asistido por IA para la detección de STEMI mediante electrocardiogramas prehospitalarios de 12 derivaciones.	362	Infarto agudo de miocardio
Cheng	2020/11	Estudio retrospectivo	Taiwán	Mejorar el rendimiento diagnóstico de los médicos en fracturas de cadera mediante apoyo con IA.	3 605	Fracturas

AUTOR	AÑO	TIPO DE ESTUDIO	PAÍS	OBJETIVO	PARTICI-PANTES	CAMPO
Cotte	2022/03	Estudio prospectivo	Alemania	Evaluar la seguridad del consejo de urgencia proporcionado por una aplicación.	378	Triaje
Crampton	2020/01	Estudio de caso	Canadá	Desarrollar un sistema de transcripción automática con NLP para generar datos de historia clínica electrónica de alta calidad.	Not applicable	Triaje
D'Amato	2022/10	Estudio prospectivo	Italia	Identificar predictores principales de exacerbaciones graves de asma que requieren ingreso hospitalario.	260	Asma
Dave	2023/05	Revisión	Ucrania	Revisar las aplicaciones, ventajas, limitaciones y consideraciones éticas de ChatGPT en medicina.	Not applicable	Chatbots en salud
Ellertsson	2023/05	Estudio retrospectivo	Islandia	Reducir el número de radiografías de tórax realizadas en urgencias mediante herramientas basadas en IA.	1 500	Trastornos respiratorios
Elston	2022/09	Ensayo clínico aleatorizado	Reino Unido	Evaluar la efectividad de un servicio telefónico dirigido a reducir la asistencia a urgencias de pacientes hiperfrecuentadores.	808	Atención primaria
Emakhu	2022/10	Estudio retrospectivo	EE. UU.	Identificar pacientes con síndrome coronario agudo de forma temprana mediante refinamiento y validación de modelos.	31 228	Síndrome coronario agudo
Grant	2020/06	Revisión	Canadá	Identificar barreras para la implementación de IA en urgencias desde perspectivas técnicas, regulatorias y de flujo clínico.	Not applicable	No aplica
Gustafsson	2022/11	Ensayo clínico aleatorizado	Suecia	Predecir infarto de miocardio en pacientes de urgencias en un contexto real.	214 250	Infarto agudo de miocardio
Hunter	2023/03	Revisión	Canadá	Revisar la utilidad de la IA a lo largo del proceso completo de atención al trauma.	Not applicable	Gestión de datos
Hwang	2023/03	Ensayo clínico aleatorizado	Corea	Comparar la precisión de la interpretación de radiografías de tórax asistida por IA-CAD frente a la interpretación convencional en urgencias.	1 761	Trastornos respiratorios

AUTOR	AÑO	TIPO DE ESTUDIO	PAÍS	OBJETIVO	PARTICI-PANTES	CAMPO
Ivanov	2020/12	Estudio retrospectivo	EE. UU.	Determinar si datos históricos de EHR pueden usarse junto con NLP y ML para predicción clínica (algoritmo KATE).	166 175	Triaje
Jadczyk	2019/09	Estudio prospectivo	EE. UU.	Recolectar y documentar datos médicos mediante una interfaz de voz.	22	Gestión de datos
Jalal	2021/02	Revisión	Canadá	Revisar el papel de la IA en la asistencia al diagnóstico en radiología de urgencias y trauma.	Not applicable	Imagen médica
Kaothan-thong	2022/12	Estudio retrospectivo	Tailandia	Detectar áreas de infarto cerebral en TC sin contraste.	804	Ictus
Karatzia	2022/10	Revisión	Reino Unido	Resumir las aplicaciones de IA en cardiología.	Not applicable	Cardiology
Kuo	2020/07	Estudio retrospectivo	Hong Kong	Aplicar algoritmos de ML para la predicción personalizada y en tiempo real de tiempos de espera en urgencias.	12 440	Predicción de tiempos de espera
Lin	2020/08	Ensayo clínico aleatorizado	China	Desarrollar una herramienta para detectar enfermedad coronaria a partir de fotografías faciales.	5 796	Enfermedad coronaria
Liu	2022/07	Estudio retrospectivo	Taiwán	Desarrollar una herramienta basada en IA para detectar pericarditis aguda.	66 633	Pericarditis
Liu	2021/10	Estudio retrospectivo	Taiwán	Desarrollar un sistema de apoyo diagnóstico basado en ECG de 12 derivaciones.	450	Infarto agudo de miocardio
Mueller	2023/05	Estudio retrospectivo	EE. UU.	Identificar un modelo clínicamente útil de estimación de riesgo de delirio en pacientes trasladados de urgencias a hospitalización.	28 531	Triaje
Na-darzynski	2019/08	Métodos mixtos	Reino Unido	Explorar la disposición de los participantes a interactuar con chatbots sanitarios basados en IA.	215	Chatbots en salud
Neri	2020/06	Revisión	Italia	Analizar quién es responsable de los beneficios y riesgos del uso de IA en radiología.	Not applicable	Imagen médica
Pak	2021/01	Estudio retrospectivo	Australia	Demostrar que los modelos de predicción son más precisos que los promedios móviles en la estimación de tiempos de espera en urgencias.	122 716	Predicción de tiempos de espera

AUTOR	AÑO	TIPO DE ESTUDIO	PAÍS	OBJETIVO	PARTICI-PANTES	CAMPO
Park	2023/05	Estudio retrospectivo	Corea	Evaluar la utilidad de un analizador de ECG basado en IA en la angina estable y en el desarrollo de un nuevo biomarcador de ECG.	723	Enfermedad coronaria
Raghunath	2021/03	Estudio retrospectivo	EE. UU.	Identificar pacientes con riesgo de ictus relacionado con fibrilación auricular a partir de registros clínicos.	430 000	Fibrilación auricular
Safaripour	2022/06	Estudio retrospectivo	Canadá	Comparar el rendimiento de regresión logística vs. modelos de ML para predecir la hiperfrecuentación en urgencias.	24 616	No aplica
Schwab	2021/08	Estudio retrospectivo	EE. UU.	Determinar la tasa de identificación de fibrilación auricular y las recomendaciones de anticoagulación en pacientes atendidos en urgencias.	70 000	Fibrilación auricular
Shahban-degan	2022/12	Estudio retrospectivo	Canadá	Predecir la necesidad de estudios de TC en urgencias.	81 118	Imagen médica
Silva	2023/04	Estudio retrospectivo	Portugal	Desarrollar un modelo basado en IA para el diagnóstico de embolia pulmonar mediante ECG de 12 derivaciones.	1 014	Embolia pulmonar
Sun	2023/02	Estudio retrospectivo	Canadá	Desarrollar modelos de ML basados en ECG para predecir riesgo de mortalidad en pacientes atendidos en urgencias.	240 077	Predicción de riesgo de mortalidad
Tahayori	2020/10	Estudio retrospectivo	Australia	Predecir la disposición de pacientes a partir de notas de triaje en urgencias.	249 532	Triaje
Tsai	2023/04	Estudio retrospectivo	Taiwán	Desarrollar un modelo de predicción para diferenciar la enfermedad de Kawasaki de otras fiebres infantiles.	74 641	Enfermedad de Kawasaki
Van Bulck	2023/04	Revisión	Bélgica	Analizar la fiabilidad, el valor y los riesgos de las respuestas generadas por ChatGPT.	Not applicable	Chatbots en salud
Vearrier	2022/04	Revisión	EE. UU.	Revisar beneficios, riesgos y recomendaciones del uso de IA en medicina de urgencias.	Not applicable	No aplica
Wang	2021/06	Estudio retrospectivo	EE. UU.	Demostrar el potencial de los datos de EHR para predecir automáticamente la carga de trabajo en urgencias.	5 532	No aplica

AUTOR	AÑO	TIPO DE ESTUDIO	PAÍS	OBJETIVO	PARTICI-PANTES	CAMPO
Wardi	2021/04	Estudio retrospectivo	EE. UU.	Desarrollar una herramienta para la predicción de shock séptico tardío en pacientes de urgencias.	9 354	Shock séptico
Weisberg	2020/08	Revisión	EE. UU.	Analizar el impacto de la IA en la práctica radiológica.	Not applicable	Imagen médica
Wu	2022/03	Estudio retrospectivo	China	Desarrollar sistemas basados en ECG para detectar STEMI y predecir la oclusión de la arteria culpable.	883	Infarto agudo de miocardio
Yang	2023/03	Estudio retrospectivo	Suiza	Utilizar análisis de sangre rutinario como herramienta de triaje para indicar neuroimagen en pacientes con cefalea.	121 241	Cefaleas
Yu	2020/01	Estudio retrospectivo	Corea	Desarrollar un modelo de triaje de enfermería basado en IA para predecir desenlaces adversos en urgencias.	54 501	Triaje
Zhang	2022/11	Estudio prospectivo	China	Desarrollar un algoritmo para predecir anemia mediante análisis de vídeo.	316	Anemia
Zhang	2020/09	Estudio retrospectivo	Taiwán	Mejorar la predicción de eventos cardíacos en pacientes con dolor torácico en urgencias.	85 254	Dolor torácico
Zheng	2022/05	Estudio retrospectivo	China	Desarrollar y validar modelos de ML para diagnóstico de ictus isquémico a partir de análisis de sangre.	10 476	Ictus

REFERENCIAS

1. Annis IE, Jordan R, Thomas KC. Quickly identifying people at risk of opioid use disorder in emergency departments: trade-offs between a machine learning approach and a simple EHR flag strategy. BMJ Open. 2022;12(9):e059414.
2. Badal K, Lee CM, Esserman LJ. Guiding principles for the responsible development of artificial intelligence tools for healthcare. Commun Med (Lond). 2023;3(1):47.
3. Bat-Erdene BO, Saver JL. Automatic Acute Stroke Symptom Detection and Emergency Medical Systems Alerting by Mobile Health Technologies: A Review. J Stroke Cerebrovasc Dis. 2021;30(7):105826.
4. Blomberg SN, Christensen HC, Lippert F, Ersboll AK, Torp-Petersen C, Sayre MR, et al. Effect of Machine Learning on Dispatcher Recognition of Out-of-Hospital Cardiac Arrest During Calls to Emergency Medical Services: A Randomized Clinical Trial. JAMA Netw Open. 2021;4(1):e2032320.
5. Blomberg SN, Jensen TW, Porsborg Andersen M, Folke F, Kjaer Ersboll A, Torp-Petersen C, et al. When the machine is wrong. Characteristics

of true and false predictions of Out-of-Hospital Cardiac arrests in emergency calls using a machine-learning model. Resuscitation. 2023;183:109689.

6. Cadamuro J, Cabitza F, Debeljak Z, De Bruyne S, Frans G, Perez SM, et al. Potentials and pitfalls of ChatGPT and natural-language artificial intelligence models for the understanding of laboratory medicine test results. Clin Chem Lab Med. 2023;61(7):1158-66.
7. Casano N, Santini SJ, Vittorini P, Sinatti G, Carducci P, Mastroianni CM, et al. Application of machine learning approach in emergency department to support clinical decision making for SARS-CoV-2 infected patients. J Integr Bioinform. 2023;20(2):20220047.
8. Cellina M, Ce M, Irmici G, Ascenti V, Caloro E, Bianchi L, et al. Artificial Intelligence in Emergency Radiology: Where Are We Going? Diagnostics (Basel). 2022;12(12):3223.
9. Chamberlin JH, Aquino G, Nance S, Worth T, Patel A, Bunn J, et al. Conventional Versus Artificial Intelligence-Assisted Interpretation of Chest Radiographs in Patients With Acute Respiratory Symptoms in Emergency Department: A Pragmatic Randomized Clinical Trial. Korean J Radiol. 2023;24(3):259-70.
10. Chang YH, Shih HM, Wu JE, Huang FW, Chen WK, Chen DM, et al. Machine learning-based triaje to identify low-severity patients with a short discharge length of stay in emergency department. BMC Emerg Med. 2022;22(1):88.
11. Chang H, Cha WC. Artificial intelligence decision points in an emergency department. Clin Exp Emerg Med. 2022;9(3):165-8.
12. Chen J, Wu X, Li M, Liu L, Zhong L, Xiao J, et al. EE-Explorer: A Multimodal Artificial Intelligence System for Eye Emergency Triaje and Primary Diagnosis. Am J Ophthalmol. 2023;252:253-64.
13. Chen M, Tan X, Padman R. A Machine Learning Approach to Support Urgent Stroke Triaje Using Administrative Data and Social Determinants of Health at Hospital Presentation: Retrospective Study. J Med Internet Res. 2023;25:e36477.
14. Chen KW, Wang YC, Liu MH, Tsai BY, Wu MY, Hsieh PH, et al. Artificial intelligence-assisted remote detection of ST-elevation myocardial infarction using a mini-12-lead electrocardiogram device in prehospital ambulance care. Front Cardiovasc Med. 2022;9:1001982.
15. Cheng CT, Chen CC, Cheng FJ, Chen HW, Su YS, Yeh CN, et al. A Human-Algorithm Integration System for Hip Fracture Detection on Plain Radiography: System Development and Validation Study. JMIR Med Inform. 2020;8(11):e19416.
16. Cotte F, Mueller T, Gilbert S, Blumke B, Multmeier J, Hirsch MC, et al. Safety of Triaje Self-assessment Using a Symptom Assessment App for Walk-in Patients in the Emergency Care Setting: Observational Prospective Cross-sectional Study. JMIR Mhealth Uhealth. 2022;10(3):e32340.
17. Crampton NH. Ambient virtual scribes: Mutuo Health's AutoScribe as a case study of artificial intelligence-based technology. Healthc Manage Forum. 2020;33(1):34-8.
18. D'Amato M, Ambrosino P, Simioli F, Adamo S, Stanziola AA, D'Addio G, et al. A machine learning approach to characterize patients with asthma exacerbation attending an acute care setting. Eur J Intern Med. 2022;104:66-72.
19. Dave T, Athaluri SA, Singh S. ChatGPT in medicine: an overview of its applications, advantages, limitations, future prospects, and ethical considerations. Front Artif Intell. 2023;6:1169595.
20. Ellertsson S, Hlynsson HD, Loftsson H, Sigurðsson EL. Triaging Patients With Artificial Intelligence for Respiratory Symptoms in Primary Care to Improve Patient Outcomes: A Retrospective Diagnostic Accuracy Study. Ann Fam Med. 2023;21(3):240-8.
21. Elston J, Gradinger FP, Streeter AJ, Macey S, Martin S. Effectiveness of a targeted telephone-based case management service on activity in an Emergency Department in the UK: a pragmatic difference-in-differences evaluation. BMC Health Serv Res. 2022;22(1):1038.

22. Emakhu J, Monplaisir L, Aguwa C, Arslanturk S, Masoud S, Nassereddine H, et al. Acute coronary syndrome early detection using further refined machine learning models: retrospective study. JMIR Med Inform. 2022;10(10):e40365.
23. Grant K, McParland A, Mehta S, Ackery AD. Artificial Intelligence in Emergency Medicine: Surmountable Barriers With Revolutionary Potential. Ann Emerg Med. 2020;75(6):721-6.
24. Gustafsson TT, Holmén A, Fu M, Vidlund M, Lantz J, Mandalenakis Z, et al. Artificial intelligence-based prediction of myocardial infarction in patients presenting to the emergency department. Eur Heart J. 2022;43(43):4517-29.
25. Hunter OF, Perry F, Salehi M, Bandurski H, Hubbard A, Ball CG, et al. Science fiction or clinical reality: a review of the applications of artificial intelligence along the continuum of trauma care. World J Emerg Surg. 2023;18(1):16.
26. Hwang SY, Ryoo SM, Park YS, Ahn JY, Jo YH, Kim WY, et al. Comparison of the Accuracy of Chest Radiograph Interpretation Between Artificial Intelligence-Based Computer-Aided Detection and Conventional Reading in Emergency Department Patients With Acute Respiratory Symptoms: A Randomized Clinical Trial. Korean J Radiol. 2023;24(3):259-70.
27. Ivanov O, Wolf L, Brecher D, Lewis E, Masek K, Montgomery K, et al. Improving ED Emergency Severity Index Acuity Assignment Using Machine Learning and Clinical Natural Language Processing. J Emerg Nurs. 2021;47(2):265-78.e7.
28. Jadczyk T, Kiwic O, Khandwalla RM, Grabowski K, Rudawski S, Magaczewski P, et al. Feasibility of a voice-enabled automated platform for medical data collection: CardioCube. Int J Med Inform. 2019;129:388-93.
29. Jalal S, Parker W, Ferguson D, Nicolaou S. Exploring the Role of Artificial Intelligence in an Emergency and Trauma Radiology Department. Can Assoc Radiol J. 2021;72(1):167-74.
30. Kaothanthong N, Atsavasirilert K, Sarampakhul S, Chantangphol P, Songsaeng D, Makhanov S. Artificial intelligence for localization of the acute ischemic stroke by non-contrast computed tomography. PLoS One. 2022;17(12):e0277573.
31. Karatzia L, Aung N, Aksentijevic D. Artificial intelligence in cardiology: Hope for the future and power for the present. Front Cardiovasc Med. 2022;9:945726.
32. Kuo YH, Chan NB, Leung JMY, Meng H, So AM, Tsoi KKF, et al. An Integrated Approach of Machine Learning and Systems Thinking for Waiting Time Prediction in an Emergency Department. Int J Med Inform. 2020;139:104143.
33. Lin S, Li Z, Fu B, Chen S, Li X, Wang Y, et al. Feasibility of using deep learning to detect coronary artery disease based on facial photo. Eur Heart J. 2020;41(46):4400-11.
34. Liu WC, Lin CS, Tsai CS, Tsao TP, Cheng CC, Liou JT, et al. A deep learning algorithm for detecting acute myocardial infarction. EuroIntervention. 2021;17(9):765-73.
35. Liu W, Wu X, Peng G, Gao X, Yu W, Fang J, et al. Artificial intelligence for acute pericarditis diagnosis based on electrocardiogram. Front Physiol. 2022;13:905760.
36. Mueller B, Street WN, Carnahan RM, Lee S. Evaluating the performance of machine learning methods for risk estimation of delirium in patients hospitalized from the emergency department. Acta Psychiatr Scand. 2023;147(5):493-505.
37. Nadarzynski T, Miles O, Cowie A, Ridge D. Acceptability of artificial intelligence (AI)-led chatbot services in healthcare: A mixed-methods study. Digit Health. 2019;5:2055207619871808.
38. Neri E, Coppola F, Miele V, Bibbolino C, Grassi R. Artificial intelligence: Who is responsible for the diagnosis? Radiol Med. 2020;125(6):517-21.
39. Pak A, Gannon B, Staib A. Predicting waiting time to treatment for emergency department patients. Int J Med Inform. 2021;145:104303.
40. Park J, Yoon Y, Cho Y, Kim J. Feasibility of Artificial Intelligence-Based Electrocardiography Anal-

ysis for the Prediction of Obstructive Coronary Artery Disease in Patients With Stable Angina: Validation Study. JMIR Cardio. 2023;7:e44791.

41. Raghunath S, Pfeifer JM, Ulloa-Cerna AE, Nemati S, Carbonati T, Jing L, et al. Prediction of Atrial Fibrillation From Electrocardiography Using a Deep Neural Network. Circulation. 2021;143(13):1287-98.
42. Safaripour R, Lim HJJ. Comparative analysis of machine learning approaches for predicting frequent emergency department visits. Health Inform J. 2022;28(2):14604582221106396.
43. Schwab P, Sontag D, Schulz A, Frommeyer G, Buhlmeier J, Kook S, et al. Real-world evidence: accuracy of artificial intelligence in identifying atrial fibrillation from emergency department records. PLoS One. 2021;16(8):e0256177.
44. Shahbandegan A, Mago V, Alaref A, van der Pol CB, Savage DW. Developing a machine learning model to predict patient need for computed tomography imaging in the emergency department. PLoS One. 2022;17(12):e0278229.
45. Silva BV, Marques J, Nobre Menezes M, Oliveira AL, Pinto FJ. Artificial intelligence-based diagnosis of acute pulmonary embolism: Development of a machine learning model using 12-lead electrocardiogram. Rev Port Cardiol. 2023;42(7):643-51.
46. Sun J, Zhou Y, Zeng D, Wu J, Duan H, Zhang P. ECG-based machine learning models for risk prediction of mortality in patients in emergency department. BMC Med Inform Decis Mak. 2023;23:33.
47. Tahayori B, Chini-Foroush N, Akhlaghi H. Advanced natural language processing technique to predict patient disposition based on emergency triaje notes. Emerg Med Australas. 2021;33(3):480-4.
48. Tsai CM, Lin CR, Kuo HC, Cheng FJ, Yu HR, Hung TC, et al. Use of Machine Learning to Differentiate Children With Kawasaki Disease From Other Febrile Children in a Pediatric Emergency Department. JAMA Netw Open. 2023;6(4):e237489.
49. Van Bulck L, Moons P. What if your patient switches from Dr. Google to Dr. ChatGPT? A vignette-based survey of the trustworthiness, value and danger of ChatGPT-generated responses to health questions. Eur J Cardiovasc Nurs. 2023;zvad038.
50. Vearrier L, Derse AR, Basford JB, Larkin GL, Moskop JC. Artificial Intelligence in Emergency Medicine: Benefits, Risks, and Recommendations. J Emerg Med. 2022;62(4):492-9.
51. Wang X, Blumenthal HJ, Hoffman D, Benda N, Kim T, Perry S, et al. Modeling patient-related workload in the emergency department using electronic health record data. Int J Med Inform. 2021;150:104451.
52. Wardi G, Carlile M, Holder A, Shashikumar S, Hayden SR, Nemati S. Predicting Progression to Septic Shock in the Emergency Department Using an Externally Generalizable Machine-Learning Algorithm. Ann Emerg Med. 2021;77(4):395-406.
53. Weisberg EM, Chu LC, Fishman EK. The first use of artificial intelligence (AI) in the ER: triaje not diagnosis. Emerg Radiol. 2020;27(4):361-6.
54. Wu L, Huang G, Yu X, Ye M, Liu L, Ling Y, et al. Deep Learning Networks Accurately Detect ST-Segment Elevation Myocardial Infarction and Culprit Vessel. Front Cardiovasc Med. 2022;9:797207.
55. Yang F, Meng T, Torben-Nielsen B, Magnus C, Liu C, Dejean E. A machine learning approach to support triaging of primary versus secondary headache patients using complete blood count. PLoS One. 2023;18(3):e0282237.
56. Yu JY, Jeong GY, Jeong OS, Chang DK, Cha WC. Machine Learning and Initial Nursing Assessment-Based Triaje System for Emergency Department. Healthc Inform Res. 2020;26(1):13-9.
57. Zhang A, Lou J, Pan Z, Luo J, Zhang X, Zhang H, et al. Prediction of anemia using facial images and deep learning technology in the emergency department. Front Public Health. 2022;10:964385.

58. Zhang PI, Hsu CC, Kao Y, Chen CJ, Kuo YW, Hsu SL, et al. Real-time AI prediction for major adverse cardiac events in emergency department patients with chest pain. Scand J Trauma Resusc Emerg Med. 2020;28(1):93.
59. Zheng Y, Guo Z, Zhang Y, Shang J, Yu L, Fu P, et al. Rapid triaje for ischemic stroke: a machine learning-driven approach in the context of predictive, preventive and personalised medicine. EPMA J. 2022;13(2):285-98.

Publicaciones más recientes 2024-2025

1. Yi N, Baik D, Baek G. The effects of applying artificial intelligence to triaje in the emergency department: A systematic review of prospective studies. J Nurs Scholarsh. 2025 Jan;57(1):105-118.
2. Miralles Linares F, Martín Quirós A, Jaén Cañadas M. Artificial intelligence-based triaje in emergency departments: A promising tool. Med Clin (Barc). 2025 Apr 25;164(8):437-438
3. Sáenz-Abad D, Sachi Martínez-Mihara M, Lahoza-Pérez MC. Artificial intelligence as a diagnostic support tool in emergency departments. Emergencias. 2025 Feb;37(1):78-79
4. Da'Costa A, Teke J, Origbo JE, Osonuga A, Egbon E, Olawade DB. AI-driven triaje in emergency departments: A review of benefits, challenges, and future directions. Int J Med Inform. 2025 May;197:105838.
5. Ahmed Abdalhalim AZ, Nureldaim Ahmed SN, Dawoud Ezzelarab AM, Mustafa M, Ali Albasheer MG, Abdelgadir Ahmed RE, Galal Eldin Elsayed MB. Clinical Impact of Artificial Intelligence-Based Triaje Systems in Emergency Departments: A Systematic Review. Cureus. 2025 Jun 9;17(6):e85667
6. Amiot F, Potier B. Artificial Intelligence (AI) and Emergency Medicine: Balancing Opportunities and Challenges. JMIR Med Inform. 2025 Aug 13;13:e70903. doi: 10.2196/70903.
7. Sanchez D, Paris F, Laribi S, Gilbert A. Reducing administrative burden in emergency departments using artificial intelligence: a workflow-based analysis. Eur J Emerg Med. 2025 Jul 1. doi: 10.1097/MEJ.0000000000001251.
8. Ahmadzadeh B, Patey C, Norman P, Farrell A, Knight J, Czarnuch S, Asghari S. Artificial Intelligence Solutions to Improve Emergency Department Wait Times: Living Systematic Review. J Emerg Med. 2025 Aug;75:174-187.
9. Garrido NJ, González-Martínez F, Torres AM, Blasco-Segura P, Losada S, Plaza A, Mateo J. Role of Artificial Intelligence in Identifying Vital Biomarkers with Greater Precision in Emergency Departments During Emerging Pandemics. Int J Mol Sci. 2025 Jan 16;26(2):722.
10. Kuo KM, Chang CS. A meta-analysis of the diagnostic test accuracy of artificial intelligence predicting emergency department dispositions. BMC Med Inform Decis Mak. 2025 May 15;25(1):187.
11. Limon Ö, Bayram B, Çetin M, Limon G, Dirican N. A bibliometric analysis of clinical studies on artificial intelligence in emergency medicine. Medicine (Baltimore). 2025 Jul 11;104(28):e43282.
12. Kareemi H, Yadav K, Price C, Bobrovitz N, Meehan A, Li H, Goel G, Masood S, Grant L, Ben-Yakov M, Michalowski W, Vaillancourt C. Artificial intelligence-based clinical decision support in the emergency department: A scoping review. Acad Emerg Med. 2025 Apr;32(4):386-395
13. De Rouck R, Wille E, Gilbert A, Vermeersch N. Assessing artificial intelligence-generated patient discharge information for the emergency department: a pilot study. Int J Emerg Med. 2025 Apr 25;18(1):85.
14. Tang C, Mudunna N, Turner I, Asghari-Jafarabadi M, Joe K, Brichko L. Use of artificial intelligence to generate emergency department discharge summaries. Aust Health Rev. 2025 Apr;49:AH24326.
15. Farrokhi M, Fallahian AH, Rahmani E, Aghajan A, Alipour M, Jafari Khouzani P, Boustani Hezarani H, Sabzehie H, Pirouzan M, Pirouzan Z, Dalvandi B, Dalvandi R, Doroudgar P, Azimi H, Moradi F, Nozari A, Sharifi M, Ghorbani H, Moghimi S, Azarkish F, Bolandi

S, Esfahani H, Hosseinmirzaei S, Niknam A, Nikfarjam F, Talebi Boroujeni P, Noorbakhsh M, Rahmani P, Rostamian Motlagh F, Harati K, Farrokhi M, Talebi S, Zare Lahijan L. Current Applications, Challenges, and Future Directions of Artificial Intelligence in Emergency Medicine: A Narrative Review. Arch Acad Emerg Med. 2025 Apr 15;13(1):e45.

16. Taylor RA, Sangal RB, Smith ME, Haimovich AD, Rodman A, Iscoe MS, Pavuluri SK, Rose C, Janke AT, Wright DS, Socrates V, Declan A. Leveraging artificial intelligence to reduce diagnostic errors in emergency medicine: Challenges, opportunities, and future directions. Acad Emerg Med. 2025 Mar;32(3):327-339.
17. Rony MKK, Das A, Khalil MI, Peu UR, Mondal B, Alam MS, Shaleah AZM, Parvin MR, Alrazeeni DM, Akter F. The Role of Artificial Intelligence in Nursing Care: An Umbrella Review. Nurs Inq. 2025 Apr;32(2):e70023.
18. Qureshi BQ, Waheed S, Jawed R. Strategic Implementation of Artificial Intelligence in Emergency Department Roster Planning: Benefits, Challenges, and Future Directions. J Coll Physicians Surg Pak. 2025 Aug;35(8):1058-1061.
19. Kareemi H, Li H, Rajaram A, Holodinsky JK, Hall JN, Grant L, Goel G, Hayward J, Mehta S, Ben-Yakov M, Pelletier EB, Scheuermeyer F, Ho K. Establishing methodological standards for the development of artificial intelligence-based Clinical Decision Support in emergency medicine. CJEM. 2025 Feb;27(2):87-95.
20. Han C, Jung YJ, Park JE, Chung WY, Yoon D. Artificial Intelligence-Based Early Prediction of Acute Respiratory Failure in the Emergency Department Using Biosignal and Clinical Data. Yonsei Med J. 2025 Feb;66(2):121-130.
21. Haimovich JS, Kolossváry M, Alam R, Padrós-Valls R, Lu MT, Aguirre AD. Risk stratification of chest pain in the emergency department using artificial intelligence applied to electrocardiograms. Open Heart. 2025 Sep 1;12(2):e003343.
22. Taules Y, Gros S, Viladrosa M, Llorens N, Solis S, Yuguero O. Use of artificial intelligence for reverse referral between a hospital emergency department and a primary urgent care center. Front Digit Health. 2025 Mar 3;7:1546467.
23. Lindner G, Ravioli S. Performance of the artificial intelligence-based Swiss medical assessment system versus Manchester triaje system in the emergency department: A retrospective analysis. Am J Emerg Med. 2025 Aug;94:46-49.
24. Rice J, Ó'Briain E, Kilkenny CJ, Hogan RE, McIntyre TV, Kavanagh D, Neary PC, O'Riordan JM, Sahebally SM. Assessing Artificial Intelligence as a Diagnostic Support Tool for Surgical Admissions in the Emergency Department. J Surg Educ. 2025 Oct;82(10):103676.
25. Vural O, Ozaydin B, Aram KY, Booth J, Lindsey BF, Ahmed A. An Artificial Intelligence-Based Framework for Predicting Emergency Department Overcrowding: Development and Evaluation Study. JMIR Med Inform. 2025 Sep 17;13:e73960.
26. Tyler S, Olis M, Aust N, Patel L, Simon L, Triantafyllidis C, Patel V, Lee DW, Ginsberg B, Ahmad H, Jacobs RJ. Use of Artificial Intelligence in Triaje in Hospital Emergency Departments: A Scoping Review. Cureus. 2024 May 8;16(5):e59906.
27. Kachman MM, Brennan I, Oskvarek JJ, Waseem T, Pines JM. How artificial intelligence could transform emergency care. Am J Emerg Med. 2024 Jul;81:40-46.
28. Yi N, Baik D, Baek G. The effects of applying artificial intelligence to triaje in the emergency department: A systematic review of prospective studies. J Nurs Scholarsh. 2025 Jan;57(1):105-118.
29. Petrella RJ. The AI Future of Emergency Medicine. Ann Emerg Med. 2024 Aug;84(2):139-153.
30. Aleksandra S, Robert K, Klaudia K, Dawid L, Mariusz S. Artificial Intelligence in Optimizing the Functioning of Emergency Departments; a Systematic Review of Current Solutions. Arch Acad Emerg Med. 2024 Jan 27;12(1):e22.

31. Tan S, Mills G. Designing Chinese hospital emergency departments to leverage artificial intelligence-a systematic literature review on the challenges and opportunities. Front Med Technol. 2024 Mar 21;6:1307625.
32. Miralles Linares F, Martín Quirós A, Jaén Cañadas M. Artificial intelligence-based triaje in emergency departments: A promising tool. Med Clin (Barc). 2025 Apr 25;164(8):437-438.
33. Ahmadzadeh B, Patey C, Hurley O, Knight J, Norman P, Farrell A, Czarnuch S, Asghari S. Applications of Artificial Intelligence in Emergency Departments to Improve Wait Times: Protocol for an Integrative Living Review. JMIR Res Protoc. 2024 Apr 12;13:e52612.
34. Tortum F, Kasali K. Exploring the potential of artificial intelligence models for triaje in the emergency department. Postgrad Med. 2024 Nov;136(8):841-846.
35. Friedman AB, Delgado MK, Weissman GE. Artificial Intelligence for Emergency Care Triaje-Much Promise, but Still Much to Learn. JAMA Netw Open. 2024 May 1;7(5):e248857.
36. Cheng R, Aggarwal A, Chakraborty A, Harish V, McGowan M, Roy A, Szulewski A, Nolan B. Implementation considerations for the adoption of artificial intelligence in the emergency department. Am J Emerg Med. 2024 Aug;82:75-81.
37. Stewart J, Innes M, Goudie A. The potential impact of artificial intelligence on emergency department overcrowding and access block. Emerg Med Australas. 2024 Aug;36(4):632-634.
38. Almulihi QA, Alquraini AA, Almulihi FAA, Alzahid AA, Al Qahtani SSAJ, Almulhim M, Alqhtani SHS, Alnafea FMN, Mushni SAS, Alaqil NA, Assiri MIF, Maghraby NH. Applications of Artificial Intelligence and Machine Learning in Emergency Medicine Triaje - A Systematic Review. Med Arch. 2024;78(3):198-206.

11.

CONCLUSIÓN

Hemos llegado al final de esta actualización. La incorporación de la inteligencia artificial en el ámbito de la medicina de urgencias representa, sin duda, una de las innovaciones más prometedoras en la transformación de los sistemas sanitarios contemporáneos. Su capacidad para mejorar la atención clínica —ya sea a través del apoyo en la toma de decisiones diagnósticas y terapéuticas, la gestión más eficiente de los recursos disponibles o la reducción de tiempos críticos en el triaje y la atención inicial— ha sido respaldada por múltiples experiencias y líneas de investigación. En consecuencia, la IA no debe ser concebida como una herramienta futura en fase de exploración, sino como una tecnología en evolución que ya está trazando un cambio de paradigma en la práctica de la medicina de emergencias.

No obstante, esta integración se enfrenta aún a limitaciones relevantes. Los retos técnicos, como el acceso a datos de calidad, se combinan con preocupaciones regulatorias sobre responsabilidad legal, equidad y transparencia de los modelos. A ello se suma la dimensión social, donde emergen resistencias culturales, temores vinculados a la pérdida de la importancia de la presencia humana en la relación médico-paciente y la necesidad de formación específica para los profesionales sanitarios. Estos desafíos, lejos de constituir un freno, deben ser entendidos como áreas de oportunidad para la consolidación de una IA que no solo sea eficaz, sino también ética, justa y confiable. De cara al futuro, resulta fundamental promover un marco normativo flexible y actualizado, en el que innovación y seguridad sean elementos complementarios. La colaboración multidisciplinar entre desarrolladores de tecnología, clínicos, gestores sanitarios y legisladores será un requisito indispensable para garantizar que la inteligencia artificial se integre de manera armónica en los servicios de urgencias. Asimismo, será clave priorizar la investigación aplicada y rigurosa que permita generar evidencia sólida sobre la efectividad real de estas herramientas, reforzando la confianza social y profesional.

En definitiva, la IA es un aliado estratégico que potencia la capacidad de respuesta en situaciones críticas. Si se logra superar los retos actuales con enfoques éticos, participativos y centrados en el paciente, estas tecnologías se consolidarán como pilares esenciales para el futuro de la emergencia médica, garantizando no solo mayor eficiencia operativa, sino también un cuidado más equitativo, seguro y humano.

Y como en cada libro al final hay una precisión clara como mensaje para llevar a casa: "**La inteligencia artificial puede potenciar nuestras capacidades de razonamiento; sin embargo, en algunas personas existe el riesgo de que termine sustituyéndolo, lo que debilita el pensamiento crítico.**