

# ¿Influye la especialidad médica en las respuestas de ChatGPT? Un análisis sobre el diagnóstico del dolor lumbar

Annika Nack<sup>1</sup>, Xabier Michelena<sup>2</sup>, Pol Maymó-Paituvi<sup>3</sup>, Cristina Calomarde-Gómez<sup>1</sup>, David Lobo-Prat<sup>4</sup>, Asier García-Alija<sup>5</sup>, Raquel Ugena-García<sup>1</sup>, Maria Aparicio<sup>1</sup>, Paola Vidal-Montal<sup>3</sup>, Diego Benavent<sup>3</sup>

<sup>1</sup> Servei de Reumatologia, Hospital Universitari Germans Trias i Pujol; <sup>2</sup> Servei Català de Salut i Hospital Universitari de la Vall d'Hebron; <sup>3</sup> Hospital Universitari de Bellvitge; <sup>4</sup> Hospital Universitari Doctor Josep Trueta; <sup>5</sup> Hospital Universitari de la Santa Creu i Sant Pau

## Introducción

El **dolor lumbar (DL)** es una causa frecuente de consulta y puede tener orígenes **reumatológicos, mecánicos, neurológicos o sistémicos**. Su evaluación requiere, a menudo, la participación de **varias especialidades médicas**.

La **inteligencia artificial (IA)**, en particular herramientas de **procesamiento de lenguaje natural** tiene un creciente potencial para **apoyar el diagnóstico diferencial** en este contexto.

Sin embargo, se desconoce si su rendimiento puede **verse influido por el encuadre clínico** (es decir, la especialidad médica simulada en la consulta).


## Objetivos

- Evaluar si las **respuestas de ChatGPT varían según la especialidad médica simulada** (reumatología, neurología, traumatología, medicina interna o rehabilitación) en el abordaje del **dolor lumbar**.
- Comparar la **precisión y sensibilidad diagnóstica de ChatGPT con la de especialistas en reumatología** ante casos clínicos simulados.

## Métodos

- Se escogieron **10 casos clínicos reales** de DL, extraídos de **exámenes oficiales para reumatología en España** (5 casos de DL de causa reumatológica y 5 no reumatológica).
- Participaron **10 médicos especialistas en enfermedades reumatológicas y musculoesqueléticas**, con  $\geq 5$  años de experiencia.
- Cada caso clínico fue respondido por los médicos y por ChatGPT-4o, generando **tres opciones diagnósticas** por participante. En el caso de **ChatGPT**, se le pidió actuar **como si fuera un especialista en reumatología, neurología, medicina interna, rehabilitación o traumatología**, evaluando el caso desde cada uno de estos enfoques.
- Se compararon las respuestas con el **diagnóstico oficial** del examen (estándar de referencia), evaluando:
  - Precisión:** acierto en el diagnóstico principal
  - Sensibilidad:** inclusión del diagnóstico correcto entre los tres primeros
  - Tiempo** de respuesta en contestar todas las preguntas por parte de los médicos y de ChatGPT


## ChatGPT acierta en los diagnósticos clínicos independientemente de la especialidad médica indicada en las instrucciones.



**ChatGPT alcanza mayor precisión y sensibilidad diagnóstica que los médicos, independientemente de la especialidad indicada.**

## Resultados

- Entre los médicos y ChatGPT se generaron un total de **528 diagnósticos**, agrupados en **39 categorías clínicas**.
- En la mayoría de las respuestas generadas por ChatGPT, el diagnóstico correcto se encontraba en las primeras posiciones con una **precisión diagnóstica de ChatGPT** osciló entre el **70 % y 80 %** según la especialidad simulada. La **sensibilidad**, entre el **80 % y 90 %**.
- No hubo **diferencias significativas entre especialidades simuladas** en precisión ( $p = 0,80$ ) ni en sensibilidad ( $p = 0,68$ ).
- Comparado con los médicos:
  - ChatGPT fue más preciso:** 75 % vs. 60 % ( $p < 0,001$ )
  - Mayor sensibilidad:** 85 % vs. 80 % ( $p = 0,02$ )
  - Más rápido:** 2,3 min vs. 12,4 min ( $p < 0,01$ )



**Figura 2. Porcentaje de respuestas correctas para cada participante y cada especialidad simulada.** Las líneas de colores representan a ChatGPT simulando distintas especialidades. Su rendimiento diagnóstico fue similar entre ellas, lo que sugiere que la especialidad indicada no influye en la precisión. Solo en el caso correspondiente a fibromialgia no se obtuvo ningún acierto.

## Conclusiones

**ChatGPT mantiene un rendimiento diagnóstico alto y constante, sin verse influido por la especialidad médica simulada.** En esta serie de casos de dolor lumbar, fue **más preciso, más sensible y más rápido** que los médicos participantes.

