








PRUEBA DE CONCEPTO

# Integración de grandes modelos lingüísticos en los sistemas de ayuda a la toma de decisiones clínicas: Un enfoque novedoso para el diagnóstico y el tratamiento de las infecciones urinarias

Manoj Jain, MD<sup>1</sup> ; Hiren Pokharna, MD<sup>2</sup> ; Sridhar Sunkara, MS<sup>3</sup> ; Sanjeev Bora, MCA<sup>4</sup> ; Kiran Ponamgi, BS<sup>5</sup> ; Rohan Dang Sharma, BS<sup>6</sup> ; Amar Gupta, PhD<sup>(7)</sup> 

<sup>1</sup>Profesor adjunto, Departamento de Política y Gestión Sanitarias, Facultad de Salud Pública Rollins, Universidad Emory, Atlanta Georgia, EE.UU.; <sup>2</sup>Médico de Enfermedades Infecciosas, Centro de Ciencias de la Salud, Universidad de Tennessee, Memphis, Tennessee, EE.UU.; <sup>3</sup>Director Ejecutivo, eBiz Solutions, LLC., Memphis, Tennessee, EE.UU.; <sup>(4)</sup>Director de Pensamiento, eBiz Solutions, LLC., Memphis, Tennessee, EE.UU.; <sup>5</sup>Becario de investigación, Laboratorio de Ciencias de la Computación e Inteligencia Artificial (CSAIL), Instituto Tecnológico de Massachusetts, Cambridge, Massachusetts, EE.UU.; <sup>6</sup>Científico de investigación, Laboratorio de Ciencias de la Computación e Inteligencia Artificial (CSAIL), Instituto Tecnológico de Massachusetts, Cambridge, Massachusetts, EE.UU.

Autor correspondiente: Manoj Jain, Correo electrónico: mjainmd1@gmail.com

DOI: <https://doi.org/10.30953/thmt.v10.554>

Palabras clave: inteligencia artificial, sistemas de ayuda a la decisión clínica, diagnóstico, grandes modelos lingüísticos, infecciones urinarias

## Resumen

**Antecedentes:** Las infecciones del tracto urinario (ITU) se encuentran entre las infecciones bacterianas más comunes en todo el mundo, lo que conlleva importantes gastos sanitarios y frecuentes diagnósticos erróneos. En Estados Unidos, las ITU representan aproximadamente 380.600 hospitalizaciones prevenibles de adultos al año, con un coste de 2.550 millones de dólares (2.260 millones de euros). Los actuales sistemas de ayuda a la toma de decisiones clínicas (SADC) suelen ser estáticos, carecen de recomendaciones personalizadas y no incorporan información clínica en tiempo real. Los CDSS basados en IA (alternativa), que aprovechan grandes modelos lingüísticos, ofrecen la posibilidad de mejorar la precisión diagnóstica, optimizar el uso de antibióticos y mejorar la eficiencia del flujo de trabajo. **Métodos:** Proponemos un aparato fotográfico automático (3RDI), un marco conceptual para un CDSS impulsado por IA para la gestión de ITU, utilizando la novedosa estructura DETNQ (Diagnóstico, Evidencia, Plan de Tratamiento, Notas, Calidad) para organizar los resultados clínicos. Este marco prevé un sistema que procese datos completos del paciente, como su historial médico, síntomas, resultados de laboratorio y registros de medicación. El diseño de 3RDI incorpora un proceso iterativo diario para una retroalimentación continua, lo que permite a los médicos perfeccionar las recomendaciones del sistema y establecer un entorno colaborativo de toma de decisiones humano-AI.

**Resultados:** Nuestro desarrollo conceptual demuestra la integración de un mecanismo de retroalimentación adaptable e impulsado por el clínico dentro de la arquitectura CDSS. Los prototipos preliminares sugieren el potencial de la presentación estructurada de datos de pacientes mediante el formato DETNQ y la adaptabilidad a contextos clínicos específicos. El marco propuesto aborda las limitaciones clave de los CDSS actuales, especialmente en lo que respecta a la participación del médico, la integración del flujo de trabajo y las capacidades de aprendizaje continuo.

**Interpretación:** El marco conceptual 3RDI ofrece una dirección prometedora para el futuro desarrollo de CDSS, particularmente para el manejo de la IU. Su énfasis en un sistema de aprendizaje continuo y en la retroalimentación del clínico proporciona un modelo para los sistemas de IA que podrían mejorar la precisión diagnóstica al tiempo que se gana la confianza del clínico. El trabajo futuro debería centrarse en la validación empírica mediante estudios controlados y el perfeccionamiento iterativo basado en la aplicación clínica en el mundo real.

## Resumen en lenguaje sencillo

Las infecciones del tracto urinario (ITU) son una de las infecciones más comunes y a menudo conducen a diagnósticos erróneos, pruebas innecesarias y costosas estancias hospitalarias. Las herramientas actuales para la toma de decisiones no actualizan la información nueva de los pacientes ni los comentarios de los clínicos. El objetivo de este estudio era desarrollar un marco conceptual para mejorar el diagnóstico y el tratamiento de las infecciones urinarias.

El equipo de investigación diseñó un marco para un sistema de apoyo a la toma de decisiones clínicas basado en IA (inteligencia artificial), es decir, programas informáticos que ayudan a los médicos a tomar decisiones clínicas. El marco incluye un mecanismo para que el sistema aprenda y mejore en función de los comentarios de los médicos, de modo que pueda adaptarse a las necesidades clínicas del mundo real. Los investigadores demostraron que un sistema de este tipo sería técnicamente viable y podría proporcionar información valiosa a los profesionales sanitarios.

Recibido: 27 de enero de 2025; Aceptado: 1 de mayo de 2025; Publicado: 2 de julio de 2025

Los sistemas de apoyo a la toma de decisiones clínicas (CDSS, por sus siglas en inglés) son programas informáticos que ayudan a los médicos a tomar decisiones clínicas y proporcionan apoyo para reducir la

Los avances en inteligencia artificial (IA) brindan la oportunidad de mejorar significativamente la oferta de CDSS y son un elemento clave de la última generación de CDSS.<sup>(2)</sup> La integración de algoritmos de aprendizaje automático (ML), procesamiento del lenguaje natural (NLP), aprendizaje profundo y grandes modelos de lenguaje (LLM) permite un procesamiento de datos más rápido, personalización y mayor precisión en los CDSS.<sup>3,4</sup> Una posible aplicación de un CDSS basado en IA es para el diagnóstico y tratamiento de infecciones del tracto urinario (ITU).

Infecciones del tracto urinario Infecciones bacterianas comunes que afectan al sistema urinario.<sup>(5)</sup> Los síntomas incluyen ganas frecuentes de orinar, dolor al orinar, orina turbia o con mal olor y dolor pélvico. El diagnóstico suele implicar el análisis de muestras de orina para detectar la presencia de bacterias y leucocitos. En los laboratorios de diagnóstico de microbiología clínica, las ITU son la enfermedad infecciosa más común que se somete a prueba.<sup>(6)</sup> Como consecuencia, son responsables de un gasto significativo en los sistemas sanitarios de todo el mundo.<sup>6</sup> También suelen diagnosticarse erróneamente.<sup>7</sup> En 2017, las ITU causaron 380.600 hospitalizaciones prevenibles en adultos, que costaron al sistema sanitario estadounidense 2.550 millones de dólares (2.260 millones de euros). Esto representó el 10,8% de todas las estancias hospitalarias potencialmente prevenibles y el 14,2% de las estancias hospitalarias pediátricas.<sup>(8)</sup> El gasto excesivo, las estancias hospitalarias prevenibles y los diagnósticos erróneos podrían reducirse aprovechando los CDSS basados en IA para diagnosticar y tratar las ITU.<sup>9</sup>

### Evolución de los CDSS y estado actual de la tecnología

Los CDSS han evolucionado considerablemente en las últimas décadas. Los primeros sistemas se basaban principalmente en reglas y utilizaban la lógica "si-entonces" para ofrecer recomendaciones.<sup>(10)</sup> La segunda generación incorporó enfoques probabilísticos y bayesianos, lo que permitió un apoyo más matizado a la toma de decisiones.<sup>11</sup> En la Tabla 1 se resume la historia de los enfoques de los SADC que emplean diversas técnicas de ML.

Varios estudios exploraron el potencial de la IA y los modelos de ML para diagnosticar afecciones médicas, algunos de los cuales se centraron específicamente en las ITU. Los actuales SADC basados en IA se construyen utilizando algoritmos de ML como redes neuronales, algoritmos de árboles de decisión, máquinas de vectores soporte (SVM), redes bayesianas y métodos de aprendizaje conjunto<sup>4</sup>, que proporcionan análisis predictivos y recomendaciones de decisiones basadas en datos de entrada. Por ejemplo, investigadores de la Universidad de Cardiff utilizaron un modelo clasificador Random Forest para diagnosticar infecciones urinarias a partir del recuento de glóbulos blancos, el recuento bacteriano, el recuento de glóbulos rojos y el recuento de células epiteliales, y obtuvieron una sensibilidad de clasificación superior al 95%.<sup>(9)</sup>

Del mismo modo, de Vires et al.<sup>12</sup> desarrollaron un sistema de CDSS semisupervisado para la predicción de ITU utilizando el método RESSEL (reliable semi-supervised ensemble learning method), que superó a los tradicionales análisis de orina y urocultivos en la identificación de ITU. Su estudio puso de relieve que la incorporación de los resultados del análisis de orina junto con la tinción de Gram y otros parámetros fácilmente disponibles permitía a los clínicos tomar decisiones mejor informadas sin recurrir prematuramente a los antibióticos.<sup>(12)</sup> Este sistema predijo las ITU con mayor precisión y ayudó a reducir el uso excesivo de antibióticos al aplazar las prescripciones hasta que estuvieran disponibles los resultados de los cultivos, apoyando así un componente clave de la administración de antibióticos.

Además, los CDSS también pueden construirse utilizando PLN, lo que permite el análisis de texto clínico no estructurado, como notas del médico, resúmenes de alta y literatura médica.<sup>(4)</sup> El aprendizaje profundo también permite CDSS más inteligentes, utilizando redes neuronales convolucionales para extraer patrones complejos de datos médicos heterogéneos y multimodales.<sup>(4)</sup> Los LLM -una forma de IA- no han sido tan probados como los modelos de alta calidad de código abierto, que solo han estado disponibles recientemente. Por ejemplo, los LLM han demostrado su potencial para mejorar la precisión diagnóstica de enfermedades comunes, como destacaron Gupta et al., quienes señalaron que los LLM como GPT-4 y Gemini son prometedores para mejorar la eficiencia y la precisión diagnóstica en entornos sanitarios.<sup>(13)</sup>

Un grupo de investigadores que desarrollaba CDSS mediante LLMs aplicó técnicas de generación de (RAG) de recuperación aumentada.<sup>(14)</sup> Este enfoque, diseñado para ayudar a los farmacéuticos a abordar los problemas relacionados con los medicamentos (PRM), utilizaba la clasificación de la Red Europea de Atención Farmacéutica (PCNE) para estructurar sus resultados. El marco RAG permitió la recuperación efectiva y la integración contextual de la información farmacéutica, incorporando herramientas para indexar y recuperar datos relacionados con los medicamentos para mejorar su relevancia. La investigación puso de relieve el potencial de los LLM en los CDSS, demostrando que los farmacéuticos que trabajaban con el sistema basado en RAG podían reducir significativamente los PRM.<sup>(14)</sup> Liu et al.<sup>15</sup> también ilustraron cómo las recomendaciones generadas por IA a partir de ChatGPT pueden mejorar la lógica de la toma de decisiones clínicas, subrayando el papel de la IA en el perfeccionamiento de los flujos de trabajo de los médicos al proporcionar nuevas perspectivas y sugerencias que complementan el juicio humano.

### Las limitaciones de los enfoques actuales de CDSS y el valor único de la IA para el tratamiento de la IU

A pesar de estos avances, los sistemas actuales basados en IA se enfrentan a varias limitaciones significativas (Tabla 2). Estos factores demuestran colectivamente por qué los enfoques de CDSS basados en IA están en una posición única para abordar los retos en la gestión de la IU que otros enfoques no han logrado resolver de forma eficaz.

Tabla 1. Evolución de los enfoques de CDSS. Evolución de los enfoques de CDSS.

Generación	Tecnologías principales	Principales limitaciones	Ejemplos de sistemas
Primera generación (1970-1990)	Lógica basada en reglas, sistemas expertos	Base estática de conocimientos, vías binarias de decisión	MYCIN, HELP
Segunda generación (1990-2010)	Redes bayesianas, razonamiento basado en casos	Adaptabilidad limitada, requiere entradas estructuradas	DXplain, Isabel
Tercera generación (2010s-Present)	Algoritmos de aprendizaje automático, redes neuronales	Falta de explicabilidad, Sesgos en los datos de entrenamiento	GeneGuide de la Clínica Mayo, AiCure
Cuarta generación emergente	Grandes modelos lingüísticos, IA multimodal	Retos normativos aún en evolución	Sistemas experimentales

IA: inteligencia artificial; AiCure: plataforma de participación del paciente impulsada por IA que utiliza visión por ordenador, chat y análisis para mejorar los procesos de los ensayos clínicos y la participación del paciente; CDSS: sistema de apoyo a las decisiones clínicas; DXplain: formato interactivo para recopilar información clínica, que utiliza una forma modificada de lógica bayesiana para derivar interpretaciones clínicas; Gene Guide: una experiencia de pruebas genéticas impulsada por Helix; "HELP": (asistencia en atención sanitaria); Isabel: convierte los signos y síntomas de un paciente en una lista de enfermedades relevantes; MYCIN: un sistema experto de encadenamiento hacia atrás que utilizó IA para identificar bacterias causantes de infecciones graves.

Tabla 2. Las limitaciones y los retos de la gestión de las infecciones urinarias ofrecen una oportunidad única para las soluciones de SADC basadas en IA.

Limitaciones	Ejemplos
Falta de aprendizaje continuo	La mayor parte del software de decisión clínica basado en el aprendizaje automático que existe actualmente en el mercado es un software "bloqueado", en el que el algoritmo, tras haber sido entrenado en un conjunto de datos inicial y probado, no aprende continuamente ni se adapta automáticamente a partir de entonces <sup>(16)</sup> . Esta limitación impide que los sistemas mejoren con el uso en el mundo real.
Integración limitada de los comentarios de los médicos	Pocos sistemas incorporan de forma eficaz las aportaciones iterativas de los médicos y los ciclos continuos de retroalimentación para impulsar mejoras significativas <sup>(17)</sup> . Esta carencia disminuye el potencial de personalización y adaptación a prácticas institucionales específicas.
Problemas de integración del flujo de trabajo	Muchos SADC no se integran perfectamente en los flujos de trabajo clínicos, lo que supone una carga adicional en lugar de reducir la carga cognitiva <sup>(18)</sup> .
Problemas de transparencia y confianza	La naturaleza de "caja negra" de muchos modelos de IA limita la confianza y la adopción por parte de los clínicos, ya que los proveedores no pueden comprender fácilmente el razonamiento que subyace a las recomendaciones. <sup>19</sup>
Procesamiento limitado del contexto del paciente	Muchos modelos existentes aún no integran plenamente una amplia gama de factores específicos del paciente, como la edad, el historial médico, la medicación y las comorbilidades, que son esenciales para una atención personalizada. <sup>20</sup>
<b>Retos</b>	
Reconocimiento de patrones en múltiples puntos de datos	El diagnóstico de una ITU implica sintetizar la información procedente de los síntomas, los valores de laboratorio, los antecedentes del paciente y las comorbilidades, una tarea en la que destacan los algoritmos de ML. Estudios recientes demuestran que entre el 30 y el 40% de los diagnósticos erróneos de ITU se deben a errores de reconocimiento de patrones en presentaciones complejas de los pacientes. Los enfoques clínicos tradicionales a menudo tienen dificultades con esta complejidad, especialmente en pacientes con presentaciones atípicas o múltiples condiciones confusas.
Integración de patrones dinámicos de resistencia a los antibióticos	La selección de los antibióticos adecuados requiere integrar factores específicos del paciente con patrones locales de resistencia a los antibióticos en constante evolución. Las vías clínicas tradicionales han demostrado una eficacia limitada en la reducción de las hospitalizaciones evitables porque a menudo no pueden adaptarse rápidamente a los cambiantes patrones de resistencia. Los sistemas de IA pueden actualizar continuamente las recomendaciones de tratamiento basándose en los datos de susceptibilidad en tiempo real de los laboratorios hospitalarios, algo que las directrices estáticas no pueden lograr.
Reducción de la carga cognitiva en patologías de gran volumen	La alta prevalencia de las infecciones urinarias las convierte en un candidato ideal para el aumento de la IA, ya que los médicos se enfrentan a la fatiga de decisión cuando evalúan repetidamente casos similares. Estudios comparativos revelan que los procesos de diagnóstico de enfermedades infecciosas mejorados con IA pueden lograr una reducción del 22% en errores de diagnóstico en comparación con las vías clínicas estándar y una mejora del 17% en comparación con los CDSS sin IA.
Estandarización con personalización	Los enfoques actuales del tratamiento de las infecciones urinarias oscilan a menudo entre protocolos excesivamente rígidos que ignoran la especificidad del paciente o una atención muy variable que depende en gran medida de los conocimientos de cada médico. Los sistemas basados en IA pueden mantener la estandarización al tiempo que ofrecen recomendaciones personalizadas basadas en factores individuales del paciente.

IA: inteligencia artificial; CDSS: sistema de apoyo a las decisiones clínicas; ML: aprendizaje automático; ITU: infección del tracto urinario.

## El marco propuesto para los aparatos fotográficos automáticos

Este artículo presenta el "aparato fotográfico automático (3RDI)", un marco conceptual para un CDSS impulsado por LLM diseñado para abordar las limitaciones identificadas anteriormente y avanzar en el campo del apoyo a la toma de decisiones clínicas para el diagnóstico y el tratamiento de la IU. El marco 3RDI se centra en varias innovaciones clave. Estas incluyen (1) un proceso iterativo diario que se alinea con los flujos de trabajo clínicos y permite que tanto los profesionales como el sistema de IA aprendan y se adapten con el tiempo, (2) una novedosa estructura DETNQ (Diagnóstico, Evidencia, Plan de Tratamiento, Notas, Calidad) para organizar la información clínica, un sistema de aprendizaje continuo (CLS) que incorpora la retroalimentación del médico para mejorar las recomendaciones, y (3) la integración de una amplia gama de datos del paciente, incluyendo datos demográficos, historial médico, medicamentos, síntomas y resultados de laboratorio.

El marco propuesto prevé un sistema basado en IA que proporcione resultados claros y escritos, útiles tanto para los profesionales sanitarios como para los pacientes. Al evaluar de forma holística todos los elementos de la situación de un paciente, este sistema podría ofrecer diagnósticos y tratamientos más personalizados y, al mismo tiempo, apoyar la toma de decisiones del médico en lugar de sustituirla.

Es importante destacar que 3RDI está diseñado como una herramienta de apoyo a la toma de decisiones clínicas y no como un dispositivo médico. Como tal, funciona dentro del marco normativo que distingue el software de apoyo a la toma de decisiones clínicas de los dispositivos médicos, lo que permite la revisión independiente y la toma de decisiones finales por parte de los profesionales sanitarios. Todas las recomendaciones generadas por el sistema deben ser revisadas y aprobadas por médicos cualificados, de modo que el profesional sanitario sigue siendo el responsable último de la toma de decisiones en el proceso de diagnóstico y tratamiento.

### Diseño del marco conceptual

El marco 3RDI prevé una arquitectura de sistema diseñada para equilibrar las capacidades avanzadas de la IA con la integración clínica práctica. Esta sección describe los componentes clave de este marco conceptual, incluyendo el manejo de datos, los enfoques de procesamiento, la estructuración de los resultados y los mecanismos de retroalimentación.

#### Arquitectura de datos de entrada y población destinataria

El marco 3RDI propuesto procesaría datos completos de pacientes estructurados en formatos estandarizados

como XML (eXtensible Markup Language) o JSON (JavaScript Object Notation). Para obtener un cuadro clínico completo, el sistema incorporaría las categorías de información que se enumeran en la Tabla 3. Estos elementos se seleccionaron a partir de las aportaciones de los usuarios.

Estos elementos se seleccionaron a partir de las aportaciones de profesionales médicos con experiencia en el diagnóstico y tratamiento de infecciones urinarias. Los apéndices A y B ilustran ejemplos de cómo estructurar la historia clínica y los registros diarios en formato XML para su procesamiento por el sistema.

El marco también prevé capacidades de integración con sistemas de historiales médicos electrónicos (EMR) como Epic, lo que permitirá recuperar los datos de los pacientes directamente de los sistemas clínicos existentes en lugar de tener que introducirlos manualmente.

#### Población destinataria

El marco 3RDI está diseñado para ayudar a poblaciones específicas de pacientes y profesionales sanitarios:

#### Pacientes

Los pacientes adultos que presentan síntomas sugestivos de ITU en pacientes hospitalizados y ambulatorios son los destinatarios del sistema. El marco sería especialmente valioso para casos complejos con comorbilidades, infecciones recurrentes o presentaciones atípicas en las que la incertidumbre diagnóstica es mayor. Aunque el marco conceptual inicial se centra en los pacientes adultos, las futuras iteraciones podrían adaptarse a las poblaciones pediátricas con las modificaciones apropiadas para tener en cuenta las diferentes presentaciones clínicas, criterios diagnósticos y consideraciones de tratamiento en los niños.

Los principales usuarios del sistema 3RDI serían los profesionales sanitarios implicados en el diagnóstico y tratamiento de las ITU, incluidos los médicos de atención primaria, los médicos de urgencias, los hospitalistas, los especialistas en enfermedades infecciosas y los urólogos. El marco de trabajo está diseñado para ser más valioso para los proveedores con grandes volúmenes de pacientes o los que ejercen en entornos sin acceso inmediato a la consulta de especialistas, donde el apoyo a la toma de decisiones podría ayudar a estandarizar la atención de acuerdo con las mejores prácticas.

#### Enfoque de procesamiento de IA propuesto

El marco conceptual de la 3RDI propone el uso de un LLM especializado, entrenado y perfeccionado para aplicaciones médicas, en particular para el diagnóstico y tratamiento de infecciones urinarias.

Tabla 3. Categorías que capturan un cuadro clínico completo. Categorías que capturan un cuadro clínico completo.

Categoría	Información recogida
Datos demográficos del paciente	Información general como nombre, sexo, edad y etnia
Historial médico	Resumen de enfermedades, medicación, antecedentes quirúrgicos y alergias
Registros diarios	Registros secuenciales de los síntomas, los medicamentos que se están tomando, los resultados de laboratorio y los signos vitales.

**Tabla 4.** Ventajas teóricas del marco conceptual 3RDI utilizando un modelo de lenguaje especializado de gran tamaño.

Ventajas	Aplicaciones
Comprensión del lenguaje natural	Capacidad para procesar datos clínicos estructurados y no estructurados, incluidas las notas fisiológicas.
Razonamiento contextual	Capacidad para tener en cuenta múltiples factores simultáneamente a la hora de hacer recomendaciones.
Resultados probabilísticos	Capacidad de expresar niveles de confianza en distintas posibilidades de diagnóstico
Capacidad explicativa	Capacidad de razonar las recomendaciones en lenguaje natural.

3RDI: aparato fotográfico automático.

Este enfoque ofrece varias ventajas teóricas (Tabla 4).

Para el desarrollo inicial de este marco, se utilizarían datos sintéticos de pacientes con IU en lugar de registros de pacientes reales. Este enfoque minimiza las preocupaciones éticas relacionadas con la privacidad de los pacientes, al tiempo que permite una rápida creación de prototipos y mejoras iterativas. El marco prevé un proceso de desarrollo en el que los datos sintéticos de entrenamiento se curarían en colaboración con expertos en la materia -incluidos médicos y profesionales de la medicina- para garantizar la relevancia y precisión clínicas.

El desarrollo del prototipo incluiría la creación de perfiles sintéticos estructurados de pacientes basados en presentaciones clínicas, síntomas y vías de tratamiento habituales de las infecciones urinarias. Un panel de médicos experimentados revisaría y perfeccionaría estos ejemplos para garantizar su alineación con las prácticas médicas del mundo real, lo que daría como resultado un conjunto de datos que reflejaría fielmente los escenarios clínicos del mundo real.

Los datos de los pacientes se almacenarían en un formato estandarizado, lo que permitiría al modelo reconocer patrones en los síntomas de los pacientes, los resultados de laboratorio y otros detalles del historial médico, generando en última instancia sugerencias fiables de diagnóstico y tratamiento. Tras el entrenamiento inicial, el modelo se perfeccionaría utilizando bibliografía médica validada sobre infecciones urinarias, protocolos de tratamiento y directrices clínicas.

### El marco de resultados del DETNQ

Una innovación fundamental en el marco conceptual de 3RDI es la estructura DETNQ para organizar los resultados clínicos. Este marco está diseñado para transformar datos médicos complejos en decisiones clínicas procesables, al tiempo que aborda las limitaciones clave de los resultados tradicionales de los CDSS. En la Tabla 5 se compara el marco DETNQ con otras estructuras de resultados habituales de los CDSS.

#### Diagnóstico

En este segmento se presentarían los diagnósticos primarios y diferenciales por orden de probabilidad, delimitando claramente

entre enfermedades confirmadas y sospechosas. Integraría los códigos pertinentes de la Clasificación Internacional de Enfermedades, 10ª Revisión (CIE-10) para una documentación precisa y destacaría los hallazgos críticos que requieren atención inmediata.

#### Evidencia

El componente Evidencia ofrecería una presentación jerárquica previa de los datos clínicos de apoyo, vinculando síntomas, resultados de laboratorio y conclusiones diagnósticas. Identificaría patrones de coincidencia con casos históricos, realizaría análisis cuantitativos de confianza diagnóstica basados en los datos disponibles e integraría directrices clínicas y buenas prácticas pertinentes. La figura 1 muestra un ejemplo conceptual del componente Evidencia.

#### Plan de tratamiento

Esta sección proporcionaría recomendaciones de intervención priorizadas, incluidas sugerencias de medicación con consideraciones de dosificación y opciones de tratamiento alternativas basadas en factores específicos del paciente. Emitiría advertencias sobre contraindicaciones, alertas sobre interacciones farmacológicas y plazos para la mejora clínica esperada, al tiempo que establecería criterios para la modificación o intensificación del tratamiento. En el Apéndice C se ilustra una propuesta de plan de tratamiento.

#### Notas

La sección Notas incluiría perlas y consideraciones clínicas específicas del contexto, orientación sobre la documentación para el cumplimiento de la facturación, resultados relevantes de la investigación y datos de ensayos clínicos, materiales educativos para el paciente, instrucciones para el alta, recomendaciones de seguimiento y parámetros de monitorización. El Apéndice D muestra un ejemplo de cómo podría aparecer la sección Notas.

#### Calidad

Por último, el segmento Calidad garantizaría la alineación con las medidas de calidad pertinentes, como el Conjunto de Datos e Información sobre la Eficacia de la Asistencia Sanitaria (HEDIS) y el Sistema de Pago de Incentivos en función del Mérito (MIPS), evaluaría la integridad de la documentación, supervisaría las métricas de cumplimiento de la tutela antibiótica, calcularía las puntuaciones de estratificación del riesgo y proporcionaría recomendaciones de coordinación de la atención. En el apéndice E figura un ejemplo conceptual de los resultados del componente de calidad.

Este proceso iterativo diario estaría diseñado para alinearse con la gestión clínica de los pacientes, reflejando el flujo de trabajo de las rondas clínicas diarias. Al imitar la evaluación clínica de los pacientes y presentar la información en una estructura familiar, el marco pretende aumentar la aceptación potencial por parte de los médicos. El enfoque DETNQ podría ayudar a abordar la interrupción del flujo de trabajo y la falta de compromiso clínico, que son los principales factores disuasorios para la adopción de los SADC por parte de los médicos<sup>(21)</sup>.

Tabla 5. Comparación exhaustiva de los marcos de salida de los CDSS.

Características del marco	CDSS tradicional basado en reglas	CDSS predictivo basado en ML	CDSS basado en LLM existente	Marco DETNQ
Organización de la información	Alertas binarias o listas de control	Puntuaciones y probabilidades de riesgo	Narrativas de texto libre	Resultados estructurados y categorizados con flujo lógico
Capacidad de personalización	Limitación a normas predefinidas	Adaptación mínima tras la implantación	Cierta adaptación a patrones locales	Personalización continua mediante retroalimentación iterativa
Presentación de pruebas	Referencias fijas a directrices	Intervalos de confianza estadísticos	Citas de la bibliografía pertinente	Pre-presentación jerárquica de la evidencia con razonamiento transparente
Medición de la calidad	Sistemas separados de las recomendaciones clínicas	Integración limitada o nula de métricas de calidad	Rara vez se incorporan	Métricas de calidad integradas y alineación normativa
Integración del flujo de trabajo	Alertas basadas en interrupciones	Requiere una sesión de revisión independiente	Patrones de integración variables	Diseñado para reflejar el proceso de pensamiento clínico y las rondas
Mecanismo de aprendizaje	Requiere actualizaciones manuales	Ciclos de reciclaje periódicos	Varía según la aplicación	Incorporación y adaptación de información en tiempo real
Formato de salida	Alta estandarización, baja flexibilidad	Normalización moderada	Estandarización baja, flexibilidad alta	Estandarización equilibrada con flexibilidad contextual
Utilización del contexto clínico	Limitada a elementos de datos estructurados	Principalmente datos estructurados con algo de texto	Utilización variable del contexto clínico	Integración completa de datos estructurados y no estructurados
Explicabilidad	Lógica transparente basada en reglas	Elementos de "caja negra" variables	Explicaciones en lenguaje natural de fiabilidad variable	Explicaciones estructuradas con jerarquías de pruebas
Integración con medidas de calidad	Integración mínima con métricas de calidad	Algunas funciones de elaboración de informes de calidad	Integración limitada del marco de calidad	Amplia incorporación de medidas de calidad
Apoyo a la administración de antibióticos	Control básico del cumplimiento de las directrices	Análisis de patrones de resistencia	Características variables de la custodia	Apoyo multifacético a la administración con adaptación local

CDSS: Clinical Decision Support Systems; DETNQ: Diagnosis, Evidence, Treatment Plan, Notes, Quality; LLM: large language models; ML: machine learning.

El marco DETNQ se mejoraría con un sistema de puntuación de la confianza, que asignaría métricas numéricas a cada recomendación. Este sistema de puntuación funcionaría en una escala de 0 a 100, en la que 100 representaría las recomendaciones de mayor confianza y 0 las de menor. La puntuación de confianza proporcionaría un contexto adicional a los clínicos a la hora de evaluar las recomendaciones, ayudándoles a determinar cuándo podría estar justificada una revisión adicional o enfoques alternativos.

### Aprendizaje continuo y comentarios de los médicos

Una innovación fundamental del marco 3RDI es su propuesta de aprendizaje continuo a través de la retroalimentación clínica. A diferencia de los SADC estáticos que permanecen inalterados tras su implantación, 3RDI incorporaría un circuito estructurado de retroalimentación para garantizar la mejora continua y la adaptación a la realidad clínica. El mecanismo de retroalimentación previsto se presenta en la Tabla 6.

La Figura 1 ilustra una interfaz de usuario conceptual para este mecanismo de retroalimentación, mostrando cómo los clínicos podrían editar la salida del modelo para mejorar la precisión.

Este enfoque no sólo permitiría a los expertos en la materia corregir los resultados imprecisos, sino que también brindaría la oportunidad de personalizar el modelo según las especificaciones de los distintos grupos de usuarios o instituciones. Por ejemplo, algunos hospitales o médicos podrían preferir prescribir cefepime en lugar de ceftazidime para pacientes con infecciones urinarias. El modelo 3RDI estaría diseñado para reconocer estos patrones a lo largo del tiempo y realizar ajustes para grupos de usuarios específicos.

El recorrido completo del usuario, desde el inicio de sesión hasta la recepción de recomendaciones asistidas por IA, se conceptualiza en la Figura 2, que visualiza un proceso de nueve pasos desde la página de inicio de sesión de la plataforma hasta la recepción de la respuesta del modelo en formato DETNQ para un nuevo paciente.

### Posibles innovaciones, ventajas y limitaciones

El marco conceptual 3RDI introduce varias innovaciones potenciales que podrían abordar los retos existentes en los CDSS, en particular para el diagnóstico y tratamiento de las ITU. Esta sección explora los beneficios teóricos y las limitaciones prácticas de la implementación de dicho marco en entornos clínicos reales.

## Edit Draft

Fig. 1. Ejemplo conceptual del componente Evidencia en el marco de resultados DETNQ. DETNQ: Diagnóstico, Evidencia, Plan de tratamiento, Notas, Calidad.

Tabla 6. El mecanismo de retroalimentación previsto funcionaría de la siguiente manera.

Factor	Mecanismo de retroalimentación
Recomendaciones generadas por IA	El sistema mostraría explicaciones y puntuaciones de confianza.
Clínicos	Revisan cada sugerencia y deciden aceptarla o modificarla.
Anulación manual	Cuando sea necesario, se sugerirá a los médicos que anulen manualmente cualquier diagnóstico o tratamiento proporcionando una decisión clínica alternativa basada en su experiencia. Las anulaciones se registrarán y almacenarán, lo que permitiría al sistema hacer un seguimiento de las discrepancias y mejorar las respuestas futuras.

IA: inteligencia artificial.

#### Enfoque iterativo diario

Este enfoque se alinearía con el flujo de trabajo natural de las rondas diarias de pacientes, permitiendo potencialmente ajustes dinámicos del tratamiento basados en las respuestas de los pacientes y reduciendo la carga cognitiva al presentar la información en patrones clínicos familiares.

#### Adaptación clínica en tiempo real

Un sistema de este tipo podría ajustarse automáticamente a las preferencias institucionales en materia de antibióticos, aprender de los patrones locales de resistencia y adaptar las recomendaciones a poblaciones específicas de pacientes.

pacientes. Al adaptarse a la disponibilidad de recursos, las capacidades de las instalaciones y las directrices sanitarias regionales, el marco podría aplicarse en diversos entornos clínicos.

#### Sistema de aprendizaje continuo

Como CLS, 3RDI incorporaría actualizaciones del modelo en tiempo real basadas en la retroalimentación clínica, lo que lo haría potencialmente adaptable a los conocimientos y patrones clínicos en evolución. Los CLS de la atención sanitaria permiten a los modelos adaptarse y mejorar, lo que podría aumentar la precisión del diagnóstico.<sup>(22)</sup> La capacidad de incorporar automáticamente nuevas pruebas médicas y ajustarse dinámicamente a los patrones clínicos cambiantes podría ayudar a garantizar que el proceso de diagnóstico siga siendo preciso y fiable.

#### Colaboración entre humanos e inteligencia artificial

La integración de la experiencia humana con los sistemas basados en IA ofrece una sinergia potencialmente poderosa que podría maximizar la precisión en el diagnóstico y la toma de decisiones. Se ha demostrado que el uso de los SADC basados en IA junto con la experiencia humana reduce la carga de trabajo de los laboratorios y disminuye la necesidad de realizar cultivos de orina y prescripciones de antibióticos innecesarios.<sup>(23)</sup> Mientras que los clínicos humanos aportan comprensión contextual, intuición y experiencia, los sistemas de IA destacan en el procesamiento de grandes cantidades de datos y en la identificación de patrones que pueden ser difíciles de detectar para los humanos.

#### Métricas de confianza clínica

La inclusión de métricas de confianza, como el sistema de puntuación de perplejidad propuesto, podría proporcionar transparencia en la toma de decisiones de la IA, ayudando potencialmente a los médicos a priorizar los casos para su revisión, estratificar el riesgo en escenarios complejos y determinar cuándo intensificar la atención.

#### Beneficios potenciales para el sistema sanitario

Si se implementa con éxito, el marco 3RDI podría ofrecer potencialmente varias mejoras en todo el sistema:

##### Optimización del flujo de trabajo

Un sistema correctamente diseñado podría reducir el tiempo dedicado al diagnóstico y la documentación de las ITU, agilizar la toma de decisiones clínicas, mejorar la comunicación del equipo asistencial, reducir las cargas administrativas y mejorar la eficiencia de la documentación clínica.

##### Mejoras en la asignación de recursos

Los beneficios teóricos podrían incluir una reducción de las pruebas de laboratorio, la optimización de los patrones de uso de antibióticos, una mejor utilización de las consultas a especialistas, menos visitas a urgencias y un uso más eficiente de los recursos de enfermería.

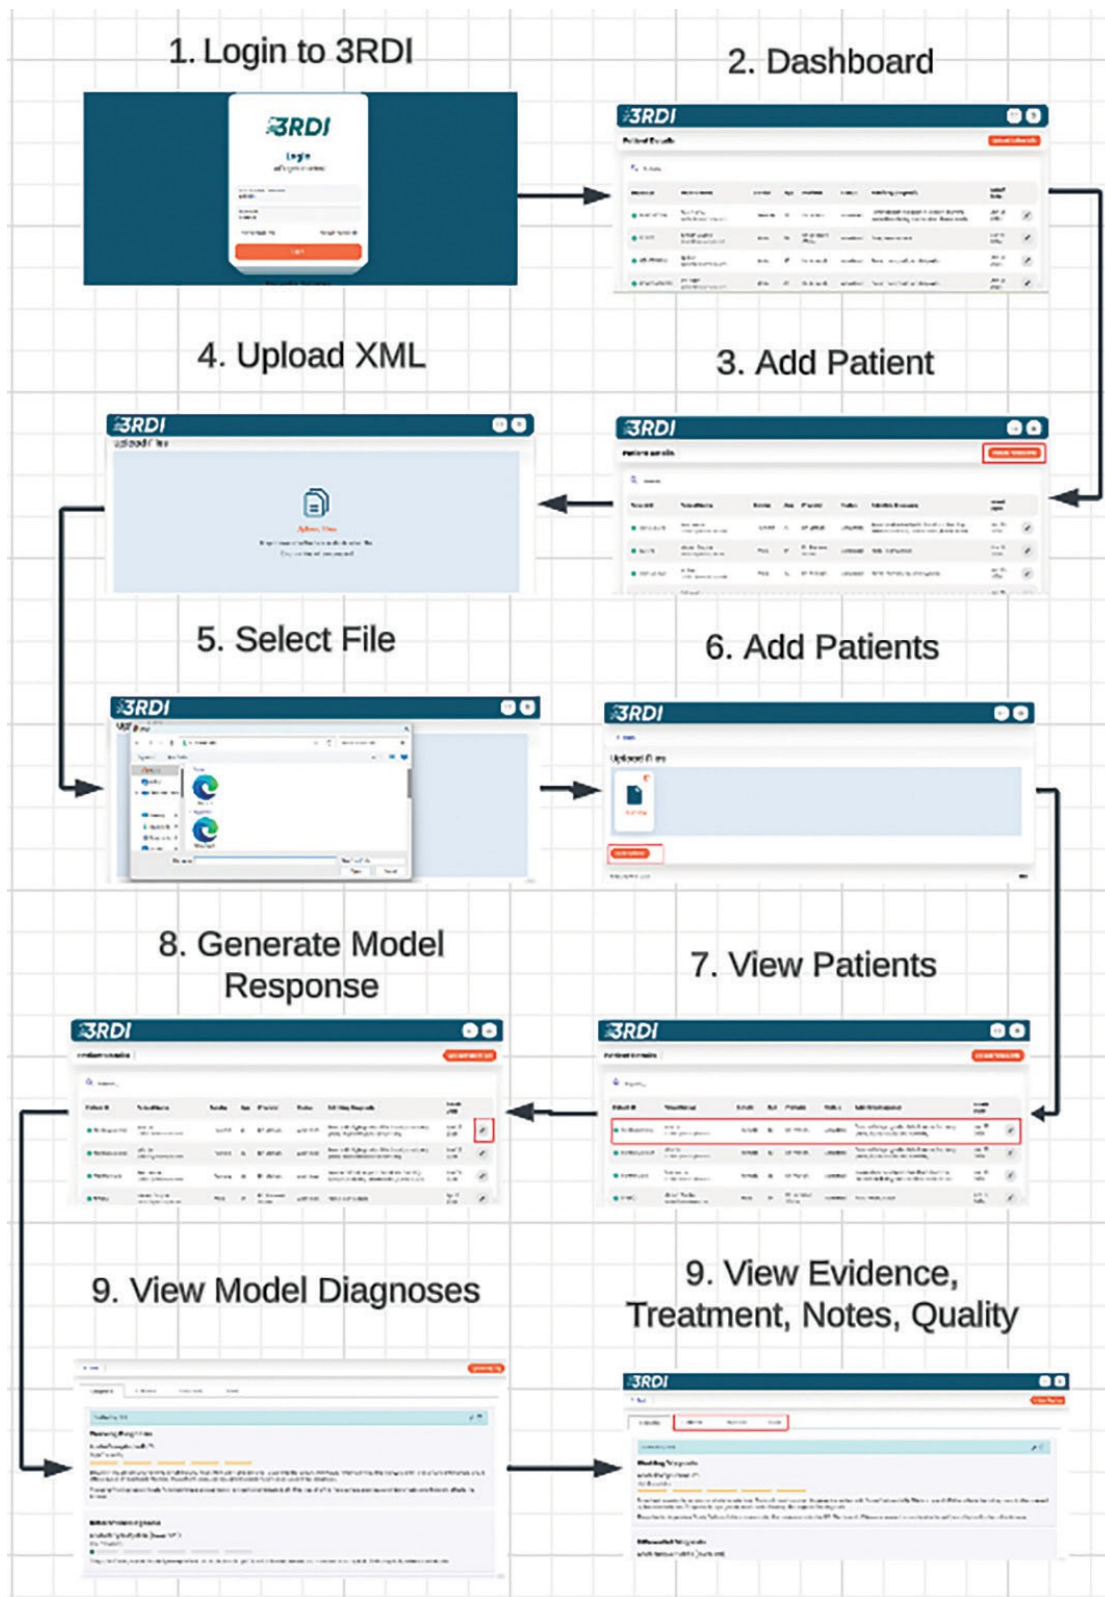


Fig. 2. Proceso de nueve pasos desde la página de inicio de sesión de la plataforma hasta la recepción de la respuesta modelo en formato DETNQ para un nuevo paciente. 3RDI: aparato fotográfico automático; DETNQ: Diagnóstico, Evidencia, Plan de Tratamiento, Notas, Calidad; XML: eXtensible Markup Language.

**Reducción de costes gracias a la precisión**

Los posibles beneficios económicos podrían incluir la disminución de las hospitalizaciones prevenibles relacionadas con infecciones urinarias, la reducción de la duración de la estancia de los pacientes ingresados, la reducción de las tasas de readmisión, la disminución de los costes relacionados con la resistencia a los antibióticos y la mejora de los reembolsos gracias a una mejor documentación.

**Mejoras en la calidad y la seguridad**

Un sistema de este tipo podría reducir los errores en la prescripción de antibióticos, mejorar el cumplimiento de las directrices clínicas, mejorar el cumplimiento de las medidas de calidad, aumentar la satisfacción de los pacientes y reducir el riesgo médico-legal mediante una documentación estandarizada.

**Dificultades de aplicación**

La aplicación práctica del marco 3RDI se enfrentaría a varios retos importantes:

**Integración técnica**

La integración con los sistemas de historia clínica electrónica (HCE) existentes sigue siendo compleja y requiere un cuidadoso desarrollo de API, mapeo de datos y análisis del flujo de trabajo. Las distintas instituciones sanitarias utilizan diversas plataformas de HCE con diferentes estructuras de datos, lo que requiere enfoques de integración flexibles.

**Requisitos informáticos**

Aunque las opciones de despliegue basadas en la nube podrían mitigar las limitaciones de hardware, garantizar un rendimiento fiable y de baja latencia en diversos entornos sanitarios requeriría una planificación cuidadosa de la arquitectura y la asignación de recursos.

**Diversidad de datos de entrenamiento**

Para garantizar que el sistema funcione de forma equitativa en distintas poblaciones de pacientes, habría que prestar especial atención a la composición de los datos de entrenamiento. Los sesgos en los datos de entrenamiento podrían provocar un rendimiento dispar entre los distintos grupos demográficos.

**Navegación normativa**

Las herramientas de apoyo a la toma de decisiones clínicas basadas en IA se enfrentan a requisitos normativos en constante evolución. El marco tendría que implementarse con vías claras para el cumplimiento normativo, incluidos estudios de validación y documentación adecuados.

**Gestión del cambio**

Quizá lo más difícil sea gestionar el cambio cultural necesario para la adopción por parte de los médicos. La resistencia a las herramientas asistidas por IA sigue siendo común, por lo que se requieren estrategias de implementación bien pensadas que hagan hincapié en el aumento y no en la sustitución del juicio clínico.

**Limitaciones del marco propuesto**

Hay que reconocer varias limitaciones importantes en el marco conceptual de la 3RDI:

**Alucinación e incertidumbre de la IA**

Como todos los LLM, cualquier implementación de este marco podría generar respuestas basadas en datos de entrada incompletos o ambiguos. Para mitigar esto, la puntuación de confianza y los mecanismos de supervisión clínica serían componentes esenciales de cualquier implementación.

**Necesidad de validación clínica**

El marco sigue siendo teórico y requeriría una amplia validación clínica antes de su implantación. Las futuras implementaciones necesitarían estudios prospectivos y ensayos controlados aleatorizados para garantizar la solidez y seguridad de cualquier recomendación.

**Retos para la adopción y la confianza de los proveedores**

Los médicos pueden dudar a la hora de confiar en las recomendaciones generadas por la IA, por temor a interpretaciones erróneas o sesgos en la toma de decisiones. Cualquier implementación tendría que incorporar el aprendizaje del médico en el bucle, permitiendo a los pro-vidores modificar los resultados y mejorar la precisión del modelo con el tiempo.

**Situación reglamentaria**

El 3RDI se concibe como una herramienta de decisión clínica más que como un dispositivo médico, lo que significa que sirve para aumentar el juicio clínico más que para sustituirlo. Todas las recomendaciones deben ser revisadas y aprobadas por profesionales sanitarios cualificados, de modo que el médico es el responsable último de la toma de decisiones en el proceso de diagnóstico y tratamiento. Este enfoque de diseño se ajusta a las actuales distinciones normativas entre los CDSS y los dispositivos médicos.

**Requisitos de privacidad y seguridad**

El tratamiento de datos sensibles de los pacientes exigiría medidas de seguridad estrictas y el cumplimiento de normativas como la HIPAA. Cualquier implementación requeriría un diseño cuidadoso de los mecanismos de protección de datos, controles de acceso y registros de auditoría.

El potencial de los sistemas de IA para perpetuar o amplificar las disparidades existentes en la atención sanitaria representa una preocupación ética significativa que debe abordarse de forma proactiva en cualquier implementación del marco 3RDI. Aunque nuestro diseño conceptual incluye la opinión de los médicos como mecanismo para corregir los resultados del modelo, reconocemos que este enfoque por sí solo es insuficiente para garantizar un rendimiento equitativo en diversas poblaciones de pacientes.

Un enfoque integral para la mitigación de sesgos requeriría múltiples estrategias implementadas a lo largo del proceso de desarrollo y despliegue (Tabla 7).

El marco también incluiría un "tablero de equidad" que supervisara continuamente el rendimiento del sistema en diferentes poblaciones de pacientes, señalando cualquier disparidad emergente para su atención inmediata. Este enfoque multicapa reconoce que abordar la equidad sanitaria en los sistemas de IA requiere elecciones de diseño intencionadas en cada fase del desarrollo y la implantación, en lugar de depender únicamente de correcciones a posteriori por parte de los médicos.

### **Futuras líneas de investigación y consideraciones sobre la implementación técnica**

El marco conceptual 3RDI presenta varias posibilidades para la investigación y el desarrollo futuros. El trabajo futuro debería incluir una validación rigurosa utilizando enfoques retrospectivos y prospectivos. Inicialmente, la validación retrospectiva con datos anónimos de pacientes reales proporcionaría información sobre el rendimiento potencial del marco. A continuación, se realizarían ensayos clínicos prospectivos en los que se compararían el diagnóstico y el tratamiento asistidos por IA con los métodos de atención estándar. En el Apéndice F se muestra la implementación técnica propuesta.

Este pseudocódigo representa un enfoque de implementación de alto nivel que podría convertirse en un prototipo de trabajo para estudios de validación. La implementación real requeriría un diseño cuidadoso de cada componente, en particular:

#### *Enfoque de ingeniería de avisos*

Métodos para construir indicaciones médicas efectivas que provoquen un razonamiento estructurado del LLM, manteniendo al mismo tiempo la relevancia clínica. Esto incluye el diseño de instrucciones que animen al modelo a seguir la estructura DETNQ, incorporando al mismo tiempo conocimientos médicos relevantes.

#### *Gestión de ventanas contextuales*

Técnicas para procesar con eficacia historiales completos de pacientes dentro de las limitadas ventanas de contexto de los actuales LLM. Esto incluye algoritmos de priorización para seleccionar la información más relevante del paciente cuando se trata de casos complejos.

#### *Cálculo de la puntuación de confianza*

Enfoques matemáticos para cuantificar la confianza basándose en la perplejidad del modelo, la coherencia del razonamiento y la solidez de las pruebas. Esto incluiría el desarrollo de métricas que se correlacionen con la precisión clínica.

#### *Mecanismos de integración de la información*

Enfoques técnicos para procesar la retroalimentación del clínico e incorporarla a la mejora del modelo, tanto para el refinamiento inmediato de la respuesta como para el aprendizaje a largo plazo.

### *Ampliación del marco*

Aunque inicialmente se centró en las infecciones urinarias, la arquitectura subyacente podría extenderse potencialmente a otras enfermedades infecciosas y condiciones clínicas. La investigación sobre la transferibilidad de la estructura DETNQ y los mecanismos de retroalimentación a otros dominios sería valiosa. La figura 2 muestra la arquitectura del sistema propuesta con los flujos de datos entre los componentes, proporcionando una representación visual de cómo interactuarían los distintos elementos del marco en una posible implementación.

#### *Desarrollo de la metodología de validación*

Establecer metodologías estandarizadas para evaluar los SADC basados en IA sigue siendo un reto. La investigación futura debe centrarse en el desarrollo de protocolos de validación específicos que evalúen tanto las métricas de rendimiento técnico (como la precisión diagnóstica y la adecuación del tratamiento) como las medidas de utilidad clínica (como la integración del flujo de trabajo, la satisfacción del usuario y el impacto en los resultados del paciente).

Dichos protocolos podrían incluir (1) pruebas comparativas de rendimiento (ensayos multiarmados que comparen el diagnóstico asistido por IA con las vías clínicas tradicionales y otras herramientas de apoyo a la toma de decisiones), (2) estudios de simulación (que utilicen casos sintéticos de pacientes con una verdad básica conocida para evaluar la precisión diagnóstica en diversas presentaciones), (3) evaluación de la experiencia del usuario (evaluaciones estructuradas de los patrones de interacción del médico, la carga cognitiva y la satisfacción con los resultados del sistema) y (4) evaluación del impacto a largo plazo (estudios longitudinales que evalúen los cambios en los patrones de la práctica clínica, las métricas de administración de antibióticos y los resultados de los pacientes tras la implementación del sistema).

#### *Mejora de la explicabilidad de los modelos*

El desarrollo de métodos mejorados para hacer que el razonamiento de la IA sea transparente y comprensible para los médicos representa una importante dirección de investigación. Esto podría incluir explicaciones visuales del razonamiento diagnóstico y la ponderación de las pruebas. El trabajo futuro podría explorar:

El trabajo futuro podría explorar (1) herramientas de visualización de pruebas (representaciones gráficas de la relación entre síntomas, valores de laboratorio y conclusiones diagnósticas), (2) atribución de confianza (métodos para comunicar qué elementos de datos específicos influyeron más en las recomendaciones del sistema), (3) análisis de escenarios alternativos (herramientas que permiten a los médicos explorar cómo diferentes hallazgos clínicos podrían afectar a las recomendaciones) y, por último, (4) vías de razonamiento diagnóstico (representación visual de los pasos lógicos desde los datos hasta la conclusión).

### **Estrategias de mitigación de sesgos**

La investigación de técnicas específicas para identificar y mitigar los sesgos en los sistemas de IA clínica reforzaría la aplicación de este marco. Esto incluye tanto enfoques técnicos para la detección de sesgos como mejoras en el proceso de desarrollo y validación de modelos.

Tabla 7. Un enfoque global de la mitigación de sesgos aplicado a lo largo del proceso de desarrollo y despliegue.

Estrategias	Procesos
Desarrollo y conservación del conjunto de datos	<ul style="list-style-type: none"> <li>• Garantizar el equilibrio demográfico entre raza, etnia, edad, sexo, género y estatus socioeconómico.</li> <li>• Sobremuestreo de poblaciones históricamente infrarrepresentadas para abordar la posible escasez de datos.</li> <li>• Incluir diversas presentaciones clínicas y casos extremos en todos los grupos de población.</li> <li>• Auditoría periódica de los datos de formación para detectar sesgos implícitos.</li> </ul>
Enfoques de desarrollo de modelos	<ul style="list-style-type: none"> <li>• Aplicar restricciones técnicas de equidad durante el entrenamiento del modelo.</li> <li>• Llevar a cabo análisis periódicos de desagregación del rendimiento entre subgrupos demográficos.</li> <li>• Emplear métodos de detección de sesgos específicos para aplicaciones sanitarias.</li> <li>• Establecer requisitos mínimos de rendimiento para todos los grupos demográficos.</li> </ul>
Gobernanza y supervisión	<ul style="list-style-type: none"> <li>• Crear diversos paneles de expertos para la evaluación del modelo que incluyan especialistas en equidad sanitaria.</li> <li>• Implicar a defensores de los pacientes de diversas comunidades en el diseño y la evaluación del sistema.</li> <li>• Establecer sistemas de supervisión continua para hacer un seguimiento de los resultados en las distintas poblaciones de pacientes.</li> <li>• Desarrollar protocolos explícitos para identificar y abordar las disparidades de rendimiento.</li> </ul>

Entre las áreas de investigación prioritarias se encuentran la auditoría del rendimiento demográfico (métodos para evaluar sistemáticamente el rendimiento del sistema en diferentes poblaciones de pacientes), las técnicas de formación que tienen en cuenta la equidad (enfoques algorítmicos que equilibran la precisión con un rendimiento equitativo en todos los grupos), la generación de datos sintéticos (técnicas para aumentar los datos de formación con el fin de mejorar la representación de los grupos infrarrepresentados) y los marcos de supervisión continua (métodos para detectar sesgos emergentes a medida que evoluciona el rendimiento del sistema).

### Conclusión

El marco conceptual 3RDI representa un enfoque con visión de futuro de los SADC basados en IA para enfermedades como las ITU. Al proponer la integración de LLM, algoritmos de ML y bucles de retroalimentación iterativos, este marco prevé sistemas que podrían mejorar el proceso de diagnóstico, ofreciendo recomendaciones personalizadas en tiempo real que se ajusten al perfil médico único de cada paciente.

El enfoque iterativo diario propuesto en el marco de trabajo refleja el flujo de trabajo natural de las rondas clínicas, permitiendo potencialmente actualizaciones dinámicas de los diagnósticos y planes de tratamiento a medida que se dispone de nuevos datos del paciente. Este enfoque de procesamiento temporal representa un avance conceptual significativo con respecto a los modelos tradicionales de SADC estáticos, y sugiere una vía hacia una respuesta continua y adaptable a la naturaleza evolutiva de la atención al paciente.

Una innovación clave radica en el concepto CLS del marco, que incorpora información clínica en tiempo real para perfeccionar los algoritmos. A diferencia de los CDSS tradicionales que requieren actualizaciones manuales periódicas, este bucle de retroalimentación podría facilitar la mejora inmediata del modelo y la personalización específica de la institución, abordando las limitaciones de las recomendaciones estandarizadas y no adaptables. Esta dinámica de colaboración entre la IA y los médicos podría reforzar la precisión clínica y mejorar la eficiencia en la toma de decisiones.

Además, la estructura DETNQ introducida por el marco proporciona un formato de salida organizado que apoyaría la toma de decisiones clínicas al tiempo que garantiza el cumplimiento de las medidas de calidad. La inclusión de la puntuación de confianza, las métricas de calidad y la guía de documentación estandarizada representa un avance conceptual sobre los resultados de los CDSS existentes, abordando las necesidades críticas de transparencia, evaluación de la confianza y alineación normativa.

Los beneficios potenciales de la implementación del marco 3RDI se extienden más allá de la gestión de las ITU, con posibilidades de racionalizar los flujos de trabajo clínicos mediante la reducción de pruebas de laboratorio y prescripciones de antibióticos innecesarias, apoyando así la administración de antibióticos. Si se implementan y validan con éxito, estos sistemas podrían extenderse a otras enfermedades infecciosas, estableciendo un enfoque escalable para un CDSS integral basado en IA.

Al proponer una visión de la medicina de precisión a través de la sinergia evolutiva de la IA y la experiencia humana, el marco 3RDI propone una dirección para los sistemas de asistencia sanitaria inteligentes y con capacidad de respuesta que podrían optimizar los recursos al tiempo que mejoran los resultados de los pacientes. Sin embargo, aún queda mucho por hacer en materia de investigación, validación e implementación antes de que estos beneficios teóricos puedan materializarse en la práctica clínica.

Nuestro enfoque reconoce explícitamente la importancia de abordar las consideraciones relativas a la equidad sanitaria y la mitigación de los sesgos mediante estrategias integrales que van más allá de basarse simplemente en los comentarios de los médicos. Al incorporar enfoques técnicos y de gobernanza rigurosos para garantizar un rendimiento justo en poblaciones diversas, el marco pretende promover la equidad sanitaria junto con la eficiencia y la precisión clínicas.

De cara al futuro, el marco 3RDI ofrece un modelo de cómo la IA y la experiencia humana pueden trabajar juntas para mejorar la atención sanitaria de una de las enfermedades más comunes de la medicina. Los conceptos aquí expuestos pueden ayudar a orientar el desarrollo de la próxima generación de SADC

que no sólo sean más inteligentes, sino también más adaptables, transparentes y equitativos que los enfoques actuales.

Las directrices pueden incluir que la investigación no implique más que un riesgo mínimo para los sujetos, que no pueda llevarse a cabo en la práctica sin la dispensa o alteración solicitada, y que implique el uso de información privada identificable o bioespecímenes identificables, que la investigación no pueda llevarse a cabo en la práctica sin utilizar dicha información o bioespecímenes en un formato identificable. Además, la renuncia o alteración no afectará negativamente a los derechos y el bienestar de los sujetos y, cuando proceda, se proporcionará a los sujetos o a sus representantes legalmente autorizados información adicional pertinente después de la participación.

### Conflictos de intereses

El autor, Dr. Amar Gupta, es miembro del Consejo Editorial de THMT. Se ha descalificado a sí mismo de la revisión por pares y del proceso de toma de decisiones.

### Colaboradores

Manoj Jain: Conceptualización, metodología, redacción, revisión, edición, supervisión, administración del proyecto. Hiren Pokharna: Metodología, curación de datos. Sridhar Sunkara: Software, validación, análisis formal, conservación de datos. Sanjeev Bora: Software, validación, análisis formal, visualización, revisión, edición. Kiran Ponamgi: Software, validación, conservación de datos, visualización. Rohan Dang Sharma: Investigación, recursos, redacción, revisión, edición. Amar Gupta: Conceptualización, supervisión, administración del proyecto, revisión y edición. Todos los autores han leído y aceptado la versión publicada del manuscrito.

### Declaración de disponibilidad de datos (DAS), intercambio de datos, reproducibilidad y repositorios de datos

Los datos que respaldan las conclusiones de este estudio están disponibles a través del autor correspondiente, Manoj Jain, previa solicitud razonable.

### Aplicación de texto generado por IA o tecnología relacionada

Se utilizó IA para ayudar a crear el resumen y el resumen en lenguaje sencillo.

### Agradecimientos

Ninguno

### Referencias

1. Mebrahtu TF, Skyrme S, Randell R, Keenan A-M, Bloor K, Yang H, et al. Effects of computerised clinical decision support systems (CDSS) on nursing and allied health professional performance and patient outcomes: a systematic review of experimental and observational studies. *BMJ Open*. 2021;11(12):e053886. <https://doi.org/10.1136/bmjopen-2021-053886>
2. Zhao C, Liang N, Zhang H, Li H, Yang Y, Zong X, et al. Harnessing the power of clinical decision support systems: challenges and opportunities. *Open Heart*. 2023;10(2):e002432. <https://doi.org/10.1136/openhrt-2023-002432>
3. Ozkan IA, Koklu M, Sert IU. Diagnosis of urinary tract infection based on artificial intelligence methods. *Comput Methods Programs Biomed*. 2018;166:51-59. <https://doi.org/10.1016/j.cmpb.2018.10.007>
4. Elhaddad M, Hamam S. AI-driven clinical decision support systems: an ongoing pursuit of potential. *Cureus*. 2024;16(4):e57728. <https://doi.org/10.7759/cureus.57728>
5. Naik N, Talyshinskii A, Shetty DK, Hameed BMZ, Zhankina R, Somani BK. Smart diagnosis of urinary tract infections: is artificial intelligence the fast-lane solution? *Curr Urol Rep*. 2023;25(1):37-47. <https://doi.org/10.1007/s11934-023-01192-3>
6. Xu R, Deebel N, Casals R, Dutta R, Mirzazadeh M. A new gold rush: a review of current and developing diagnostic tools for urinary tract infections. *Diagnostics*. 2021;11(3):479. <https://doi.org/10.3390/diagnostics11030479>
7. Hojat LS, Saade EA, Hernandez AV, Donskey CJ, Deshpande A. ¿Pueden los sistemas electrónicos de apoyo a las decisiones clínicas mejorar el diagnóstico de las infecciones urinarias? A systematic review and meta-analysis. *Open Forum Infect Dis*. 2022;10(1):ofac691. <https://doi.org/10.1093/ofid/ofac691>
8. McDermott KW, Jiang HJ. Características y costes de las estancias hospitalarias potencialmente evitables, 2017. Rockville, MD: Agency for Healthcare Research and Quality (US); 2006.
9. Burton RJ, Albur M, Eberl M, Cuff SM. Using artificial intelligence to reduce diagnostic workload without compromising detection of urinary tract infections. *BMC Med Inform Decis Mak*. 2019;19(1):171. <https://doi.org/10.1186/s12911-019-0878-9>
10. Consultas médicas basadas en ordenador: MYCIN. En: Eduardo H. Shortliffe editores. New York: Elsevier; 1976. 286 pp. ISBN-10: 0444569693. ISBN-13: 978-0444569691
11. Berner ES. Clinical decision support systems: theory and practice. Springer Science & Business Media; (2<sup>nd</sup>ed.). New York: Springer Verlag; 2007.
12. de Vries S, Doesschate TT, Totté JEE, Heutz JW, Loeffen YGT, Oosterheert JJ, et al. A semi-supervised decision support system to facilitate antibiotic stewardship for urinary tract infections. *Comp Biol Med*. 2022;146:105621. <https://doi.org/10.1016/j.combiomed.2022.105621>
13. Gupta GK, Singh A, Manikandan SV, Ehtesham A. Digital diagnostics: the potential of large language models in recognizing symptoms of common illnesses. *AI*. 2025;6(1):13. <https://doi.org/10.3390/ai6010013>
14. Ong JCL, Jin L, Elangovan K, Lim GYS, Lim DYZ, Sng GGR, et al. Development and testing of a novel large language model-based clinical decision support systems for medication safety in 12 clinical specialties. *arXiv preprint arXiv:2402.01741*, 2024 [arxiv.org](https://arxiv.org/abs/2402.01741).
15. Liu S, Wright AP, Patterson BL, Wanderer JP, Turer RW, Nelson SD, et al. Using AI-generated suggestions from ChatGPT to optimize clinical decision support. *J Am Med Inform Assoc*. 2023;30(7):1237-45. <https://doi.org/10.1093/jamia/ocad072>
16. Silcox C, Dentzer S, Bates DW. AI-enabled clinical decision support software: a "trust and value checklist" for clinicians. *NEJM Catalyst*. 2020;1(6). <https://doi.org/10.1056/cat.20.0212>
17. Sutton RT, Pincock D, Baumgart DC, Sadowski DC, Fedorak RN, Kroeker KI. An overview of clinical decision support systems: benefits, risks, and strategies for success. *NPJ Digit Med*. 2020;3:17. <https://doi.org/10.1038/s41746-020-0221-y>

18. Richardson C, Robb KA, O'Connor RC. A systematic review of suicidal behaviour in men: A narrative synthesis of risk factors. *Soc Sci Med.* 2021;276:113831. <https://doi.org/10.1016/j.socscimed.2021.113831>
19. Wang L, Zhang Z, Wang D, Cao W, Zhou X, Zhang P, et al. Human-centered design and evaluation of AI-empowered clinical decision support systems: a systematic review. *Front Comput Sci.* 2023;5:1187299. <https://doi.org/10.3389/fcomp.2023.1187299>
20. Gómez-Cabello CA, Borna S, Pressman S, Haider SA, Haider CR, Forte AJ. Artificial-intelligence-based clinical decision support systems in primary care: a scoping review of current clinical implementations. *Eur J Investig Health Psychol Educ.* 2024;14(3):685-98. <https://doi.org/10.3390/ejihpe14030045>
21. Laka M, Milazzo A, Merlin T. Factors that impact the adoption of clinical decision support systems (CDSS) for antibiotic management. *Int J Environ Res Public Health.* 2021;18(4):1901. <https://doi.org/10.3390/ijerph18041901>
22. Flores E, Martínez-Racaj L, Blasco Á, Diaz E, Esteban P, López-Garrigós M, et al. A step forward in the diagnosis of urinary tract infections: from machine learning to clinical practice. *Comput Struct Biotechnol J.* 2024;24:533-41. <https://doi.org/10.1016/j.csbj.2024.07.018>
23. Sahiner B, Friedman B, Linville C, Ipach C, Montgomery E, Alexander ES, et al. Perspectives and best practices for artificial intelligence and continuously learning systems in health care. Cincinnati, OH: Biblioteca de la Universidad Xavier; 2018.
24. Talyshinskii A, Naik N, Hameed BMZ, Juliebo-Jones P, Somani BK. Potential of AI-driven chatbots in urology: revolutionizing patient care through artificial intelligence. *Curr Urol Rep.* 2024;25(1):9-18. <https://doi.org/10.1007/s11934-023-01184-3>
25. Labkoff S, Oladimeji B, Kannry J, Solomonides A, Leftwich R, Koski E, et al. Toward a responsible future: recommendations for AI-enabled clinical decision support. *J Am Med Inform Assoc.* 2024;31(11):2730-9. <https://doi.org/10.1093/jamia/ocae209>

**Propiedad intelectual:** Este es un artículo de acceso abierto distribuido de acuerdo con la licencia Creative Commons Attribution Non-Comercial (CC BY-NC 4.0), que permite a otros distribuir, adaptar, mejorar este trabajo de forma no comercial, y licenciar sus trabajos derivados en diferentes términos, siempre que el trabajo original se cite adecuadamente y el uso no sea comercial. Véase <http://creativecommons.org/licenses/by-nc/4.0>. Los autores de este artículo poseen los derechos de autor.

## Apéndice

```

<MedicalHistory>
  <ChronicConditions>
    <Condition>
      <Name>Diabetes</Name><OnsetDate>2015-09-01</OnsetDate><Severity>Poorly Controlled</Severity><Treatments>
        <Treatment><Medication>Metformin</Medication><Dosage>1000mg twice daily</Dosage></Treatment>
        <Treatment><Medication>Insulin Glargine</Medication><Dosage>50 units daily</Dosage></Treatment>
      </Treatments>
      <LastVisit>2023-06-30</LastVisit>
    </Condition>
    <Condition>
      <Name>Atrial Fibrillation</Name><OnsetDate>2018-04-01</OnsetDate><Severity>Persistent</Severity>
      <Treatments>
        <Treatment><Medication>Metoprolol</Medication><Dosage>100mg twice daily</Dosage></Treatment>
      </Treatments>
      <LastVisit>2023-07-25</LastVisit>
    </Condition>
  </ChronicConditions>
  <SurgicalHistory>
    <Procedure>
      <Name>Prostatectomy</Name>
      <SurgeryDate>2020-03-30</SurgeryDate>
      <Surgeon>Dr. John Smith</Surgeon>
      <Hospital>University Hospital</Hospital>
      <Outcome>Successful</Outcome></Procedure>
    <Procedure>
      <Name>Prostatectomy</Name>
      <SurgeryDate>2020-03-30</SurgeryDate>
      <Surgeon>Dr. John Smith</Surgeon>
      <Hospital>University Hospital</Hospital>
      <Outcome>Successful</Outcome>
    </Procedure>
  </SurgicalHistory>
  <MedicationHistory>
    <Medication><Name>Lisinopril</Name><Dosage>20mg daily</Dosage><StartDate>2010-03-15</StartDate></Medication>
    <Medication><Name>Metformin</Name><Dosage>1000mg twice daily</Dosage><StartDate>2015-09-01</StartDate></Medication>
  </MedicationHistory>
  <AllergyHistory>
    <Allergy><Name>Penicillin</Name><Reaction>Hives</Reaction></Allergy>
  </AllergyHistory>
</MedicalHistory>

```

Apéndice A. Un ejemplo de historia clínica XML (eXtensible Markup Language).

```

<DailyLogs>
  <Day index="1">
    <Date>2024-06-30</Date>
    <Symptoms>
      <Symptom><Name>Hematuria</Name><Onset>2023-08-04</Onset><Severity>Moderate</Severity><Duration>2 days</Duration></Symptom>
      <Symptom><Name>Dysuria</Name><Onset>2023-08-05</Onset><Severity>Severe</Severity><Duration>1 day</Duration></Symptom>
    </Symptoms>
    <Vitals>
      <Vital><Name>Temperature</Name><Value>98.3</Value><Unit>Fahrenheit</Unit><TimeCollected>2023-08-06T08:00</TimeCollected></Vital>
      <Vital><Name>Pulse</Name><Value>101</Value><Unit>bpm</Unit><TimeCollected>2023-08-06T08:00</TimeCollected></Vital>
    </Vitals>
    <LabResults>
      <LabTest>
        <Name>WBC</Name>
        <Value>15.3</Value>
        <Unit>x10^9/L</Unit>
        <ReferenceRange><Low>4.0</Low><High>10.0</High></ReferenceRange>
        <Interpretation>Elevated</Interpretation>
        <CollectionTime>2023-08-06T07:30</CollectionTime>
      </LabTest>
      <LabTest>
        <Name>Hemoglobin</Name>
        <Value>12.2</Value>
        <Unit>g/dL</Unit>
        <ReferenceRange><Low>13.5</Low><High>17.5</High></ReferenceRange>
        <Interpretation>Low</Interpretation>
        <CollectionTime>2023-08-06T07:30</CollectionTime>
      </LabTest>
    </LabResults>
    <MedicationHistory>
      <Medication><Name>Lisinopril</Name><Dosage>20mg daily</Dosage><StartDate>2010-03-15</StartDate></Medication>
      <Medication><Name>Metformin</Name><Dosage>1000mg twice daily</Dosage><StartDate>2015-09-01</StartDate></Medication>
    </MedicationHistory>
    <ProgressNotes>Patient showing significant improvement, consider transition to oral antibiotics</ProgressNotes>
  </Day>
  <DischargeSummary>
    <DischargeDate>2024-05-14</DischargeDate>
    <ProceduresPerformed>No</ProceduresPerformed>
    <PatientConditionAtDischarge>The patient is stable with resolved symptoms of pyelonephritis. No signs of fever, chills, or flank pain noted at discharge.</PatientConditionAtDischarge>
    <FollowUpInstructions>
      Complete the full course of prescribed antibiotics. Drink plenty of fluids. Follow up with primary care physician in 1 week.
    </FollowUpInstructions>
    <DischargeSummaryNotes>
      The patient was admitted with symptoms of pyelonephritis including severe flank pain, fever, and chills. Treatment included a course of IV antibiotics and supportive care. The patient's symptoms resolved, and lab tests confirmed recovery at the time of discharge. Patient education on UTI prevention and symptom recognition was provided.
    </DischargeSummaryNotes>
  </DischargeSummary>
</DailyLogs>

```

Apéndice B. Ejemplo de registro diario XML (eXtensible Markup Language).

The screenshot displays a medical dashboard interface for 3RDI. At the top, there is a navigation bar with the 3RDI logo, a back button, and an 'Upload Day Log' button. Below the navigation bar, there are tabs for 'Diagnosis', 'Evidence', 'Treatment', 'Notes', and 'Quality Measures'. The 'Diagnosis' tab is active, showing a draft by 3RDI. The main content area is divided into three sections: 'Working Diagnosis', 'Differential Diagnosis', and 'Renal Abscess'. Each section includes a title, a probability level, a progress bar, and a detailed explanation of the diagnosis based on patient symptoms and laboratory results.

**3RDI**

← Back | Upload Day Log

Diagnosis | Evidence | Treatment | Notes | Quality Measures

Drafted by 3RDI

**Working Diagnosis**

**Acute Complicated UTI**  
High Probability

Based on the patient's symptoms, medical history, and laboratory results, it appears that the patient has a Urinary Tract Infection (UTI). The patient's symptoms include abdominal pain, back pain, and urosepsis, which are all indicative of a UTI. The patient's laboratory results, including the elevated WBC count and the presence of pyuria, also support this diagnosis.

The patient's symptoms and laboratory results suggest that they have an acute complicated UTI, which is a severe and potentially life-threatening infection. The patient requires prompt treatment with antibiotics and close monitoring to prevent complications.

**Differential Diagnosis**

**Acute Simple Cystitis (Lower UTI)**  
Low Probability

The patient's symptoms and laboratory results do not suggest that they have an acute simple cystitis, which is a milder and more common form of UTI. The patient's symptoms are more severe, and the laboratory results indicate a more complicated infection.

**Renal Abscess**  
Low Probability

The patient's symptoms and laboratory results do not suggest that they have a renal abscess, which is a rare and severe complication of a UTI. The patient's symptoms are more consistent with a UTI, and the laboratory results do not indicate a renal abscess.

In conclusion, based on the patient's symptoms, medical history, and laboratory results, it appears that the patient has an acute complicated UTI. The patient should be treated with a combination of antibiotics, and their medical history and allergy should be taken into consideration.

Drafted by 3RDI on 12/20/2024 14:16

Apéndice C. Ejemplo de cómo podría aparecer el componente Diagnóstico en el sistema propuesto.

3RDI

← Back Upload Day Log

Diagnosis Evidence **Treatment** Notes Quality Measures

Drafted by 3RDI

### Suggested Medication

Based on the diagnosis of a UTI, the patient should be prescribed antibiotics. The recommended treatment is a combination of Ciprofloxacin (500mg twice daily for 7-10 days) and Metronidazole (500mg three times daily for 7-10 days). The patient's medical history, including their allergy to Acetaminophen, should be taken into consideration when selecting a medication. In this case, Ciprofloxacin and Metronidazole are good options because they are not contraindicated by the patient's allergy.

Drafted by 3RDI on 12/20/2024 14:16

Edit Approve

Apéndice D. Propuesta de plan de tratamiento.

3RDI

← Back Upload Day Log

Diagnosis Evidence Treatment **Notes** Quality Measures

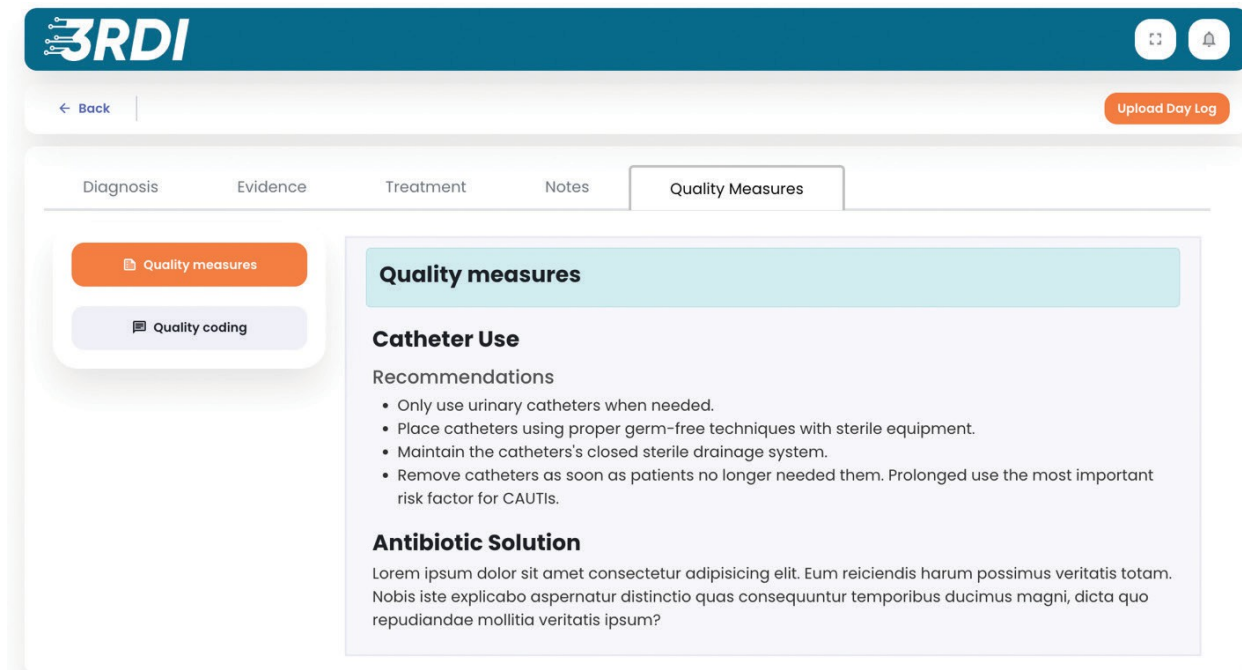
Drafted by 3RDI

The patient's medical history, including their chronic conditions of abdominal pain and back pain, should be taken into consideration when treating their UTI. The patient's allergy to Acetaminophen should also be considered when selecting a medication. It is important to monitor the patient's symptoms and laboratory results closely to ensure that the infection is clearing and to adjust treatment as necessary.

Note Drafted by 3RDI

Edit Approve

Apéndice E. Un ejemplo de cómo podría aparecer la sección Notas.



Anexo F. Un ejemplo conceptual de la salida del componente Calidad.