

## Resumen

- ❑ Cumplimentar el IHS4 es **tedioso**, se calcula de forma **manual**, presenta una **alta variabilidad interobservador** y depende de la experiencia del especialista.
- ❑ Presentamos el **AIHS4**, un algoritmo de deep learning que **automatiza del IHS4**. A partir de una **fotografía**, detecta lesiones y **calcula el IHS4 de forma automática**.
- ❑ Para crear el **AIHS4**, hemos desarrollado un **algoritmo auxiliar de unificación de conocimiento clínico**, que **minimiza el impacto de la subjetividad** y **genera un consenso clínico robusto** de distintos doctores para optimizar el entrenamiento de algoritmos.
- ❑ El **AIHS4** se puede incorporar a un sistema DAO para **apoyar a los médicos en su práctica clínica** y servir como una **nueva métrica en ensayos clínicos**.



Prueba cómo funciona  
<https://www.legit.health>

## Objetivo

Desarrollo e integración de una herramienta de análisis de imagen para la evaluación y seguimiento de la hidradenitis supurativa (HS) por medio de algoritmos de aprendizaje profundo.

## Materiales y métodos

Un total de 221 imágenes de HS fueron etiquetadas por un equipo de 6 médicos con una experiencia en la patología de entre 3 y 7 años, que documentaron y delimitaron todas las lesiones presentes en cada imagen (abscesos, nódulos y túneles).

Doctor	Lesiones etiquetadas			IHS4	
	Abscesos	Túneles	Nódulos	Media	Máx.
1	93	183	144	4.81	36
2	103	217	297	6.2	28
3	82	210	319	5.99	24
4	244	247	640	9.57	62
5	45	236	405	6.51	49
6	64	256	337	6.74	33

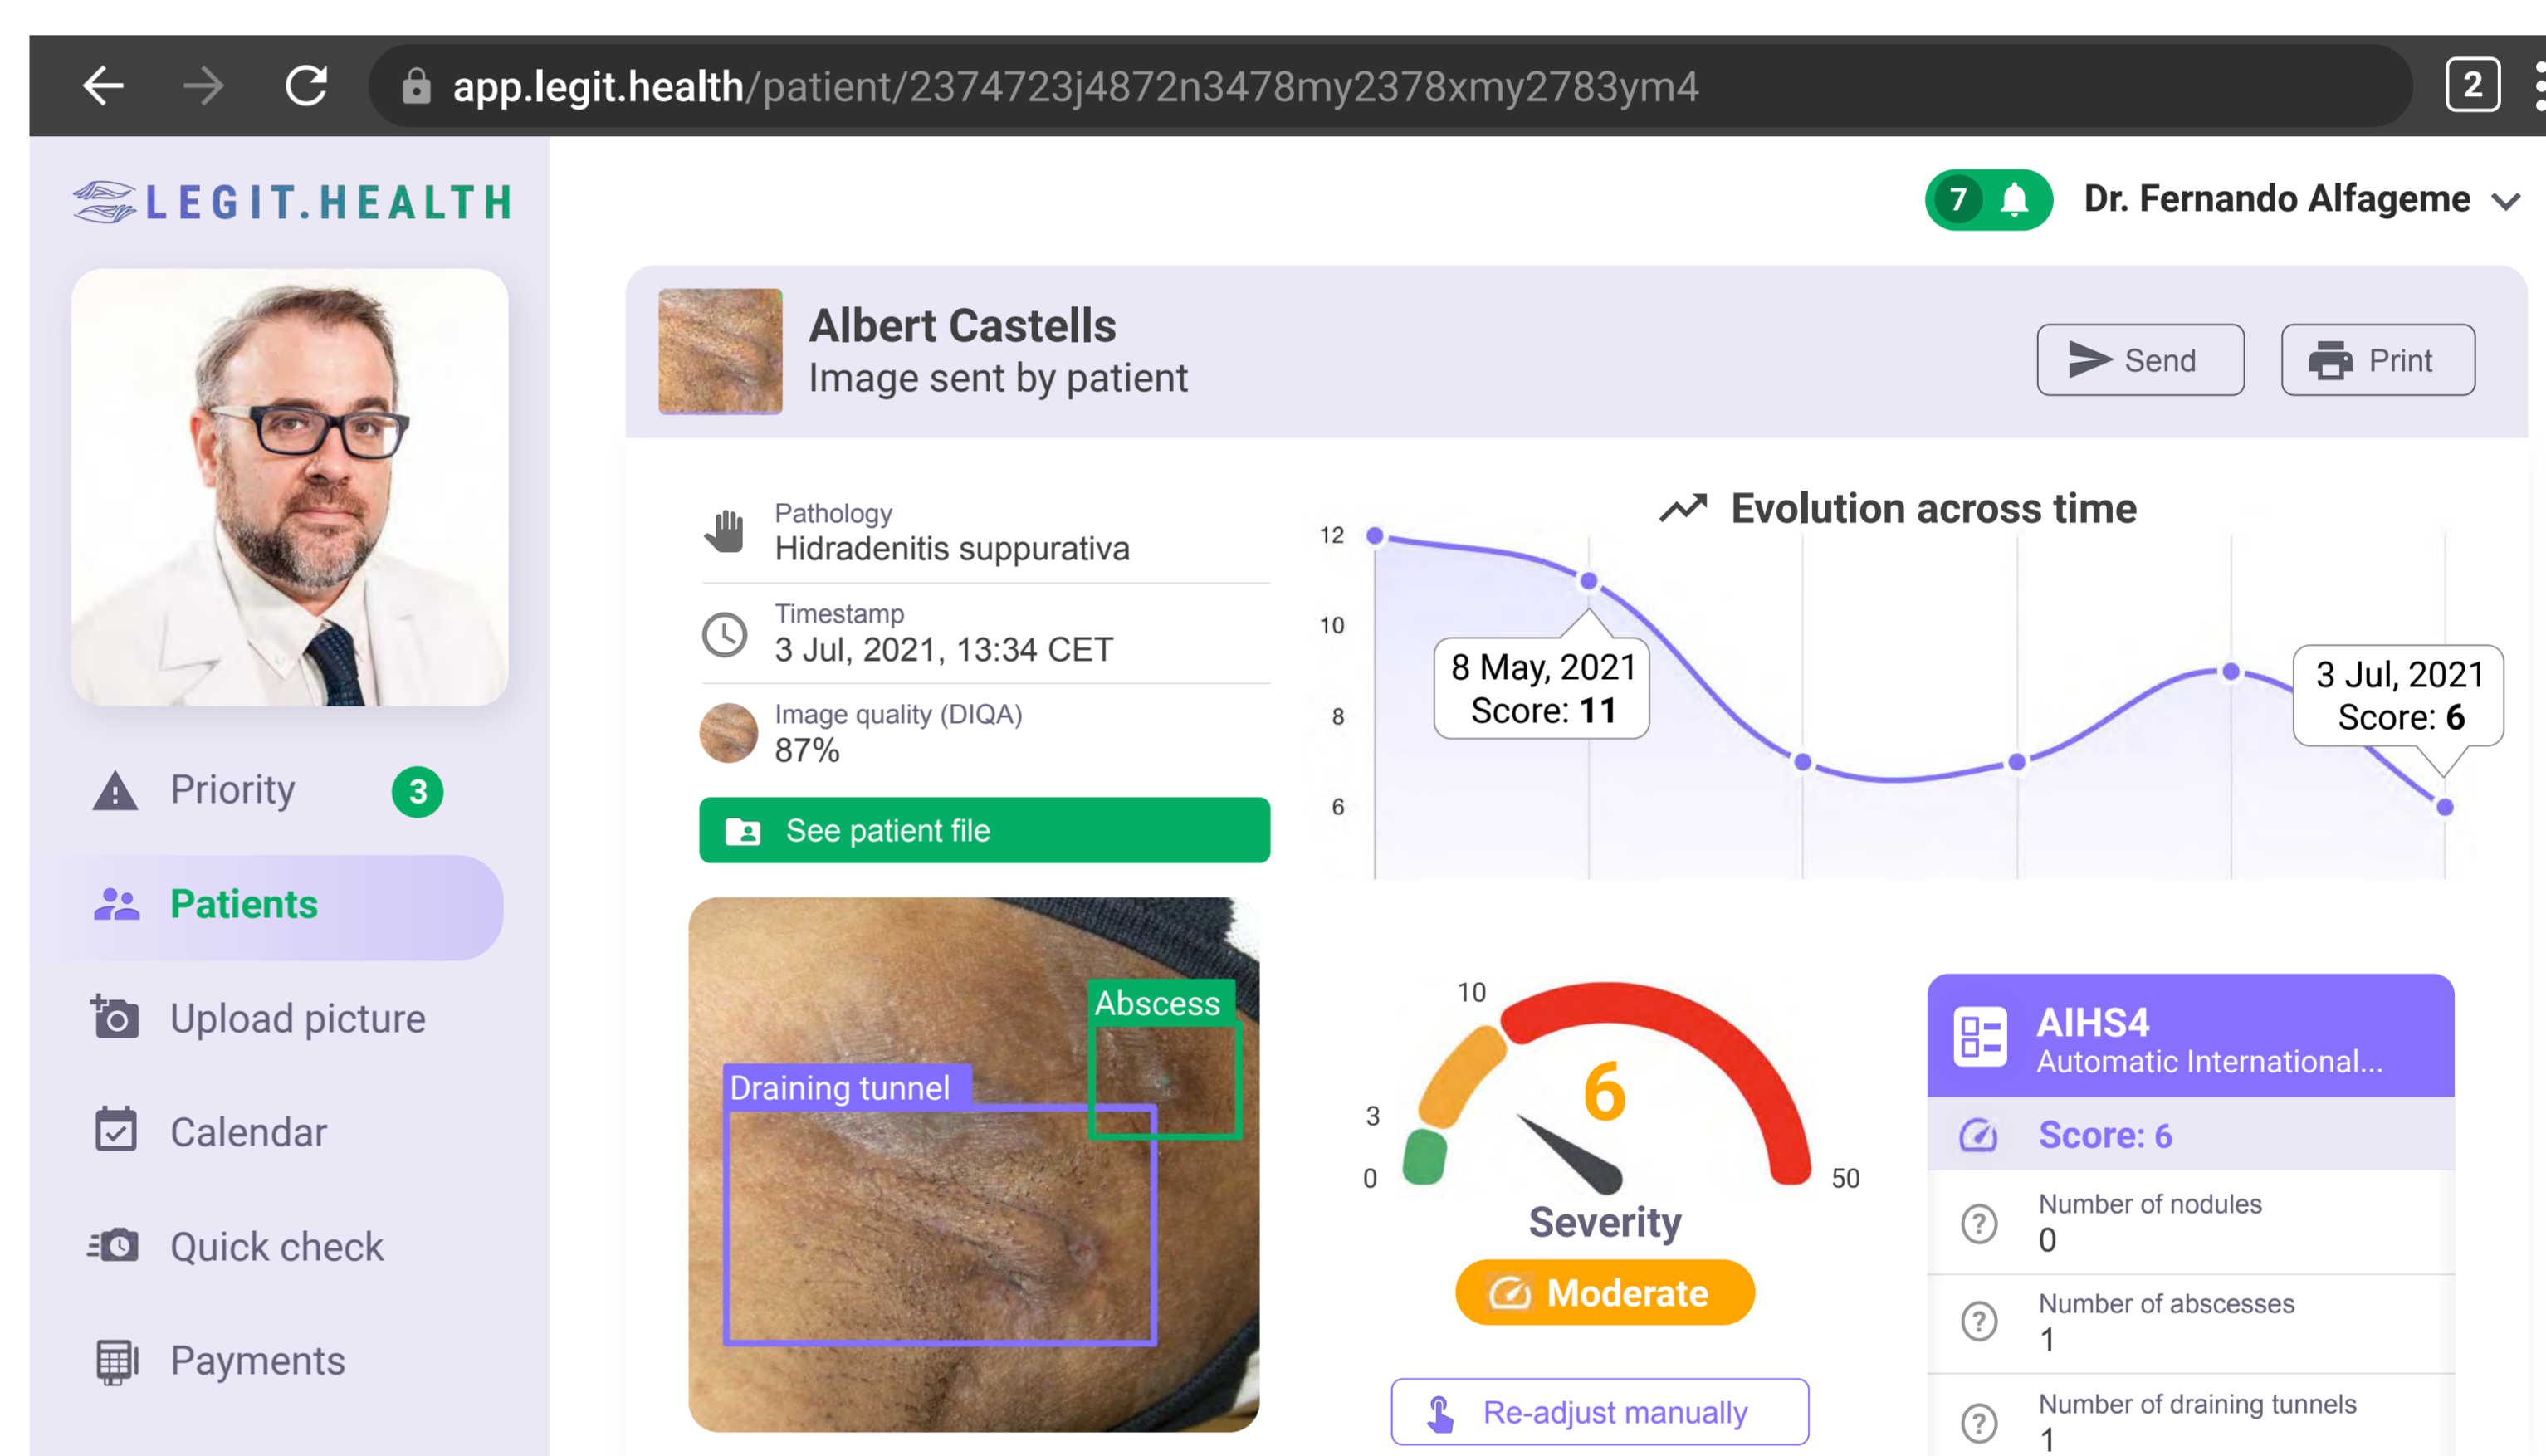
Debido a la alta variabilidad en sus respuestas, se desarrolló un algoritmo de **unificación de conocimiento** consistente en una agregación automática de etiquetas basada en un sistema de votación. Dicho algoritmo permitió alcanzar el consenso clínico necesario para entrenar modelos de aprendizaje automático.

Una vez fusionadas las respuestas, se elaboró un *dataset* con el que se entrenó una familia de modelos de aprendizaje profundo. En este estudio se entrenó un modelo de detección de lesiones, llamado **Legit.Health-IHS4net**, a partir de la arquitectura **YOLOv5**. A partir del número y tipo de lesiones detectadas, se obtuvo el IHS4 indicado por el algoritmo (**AIHS4**).

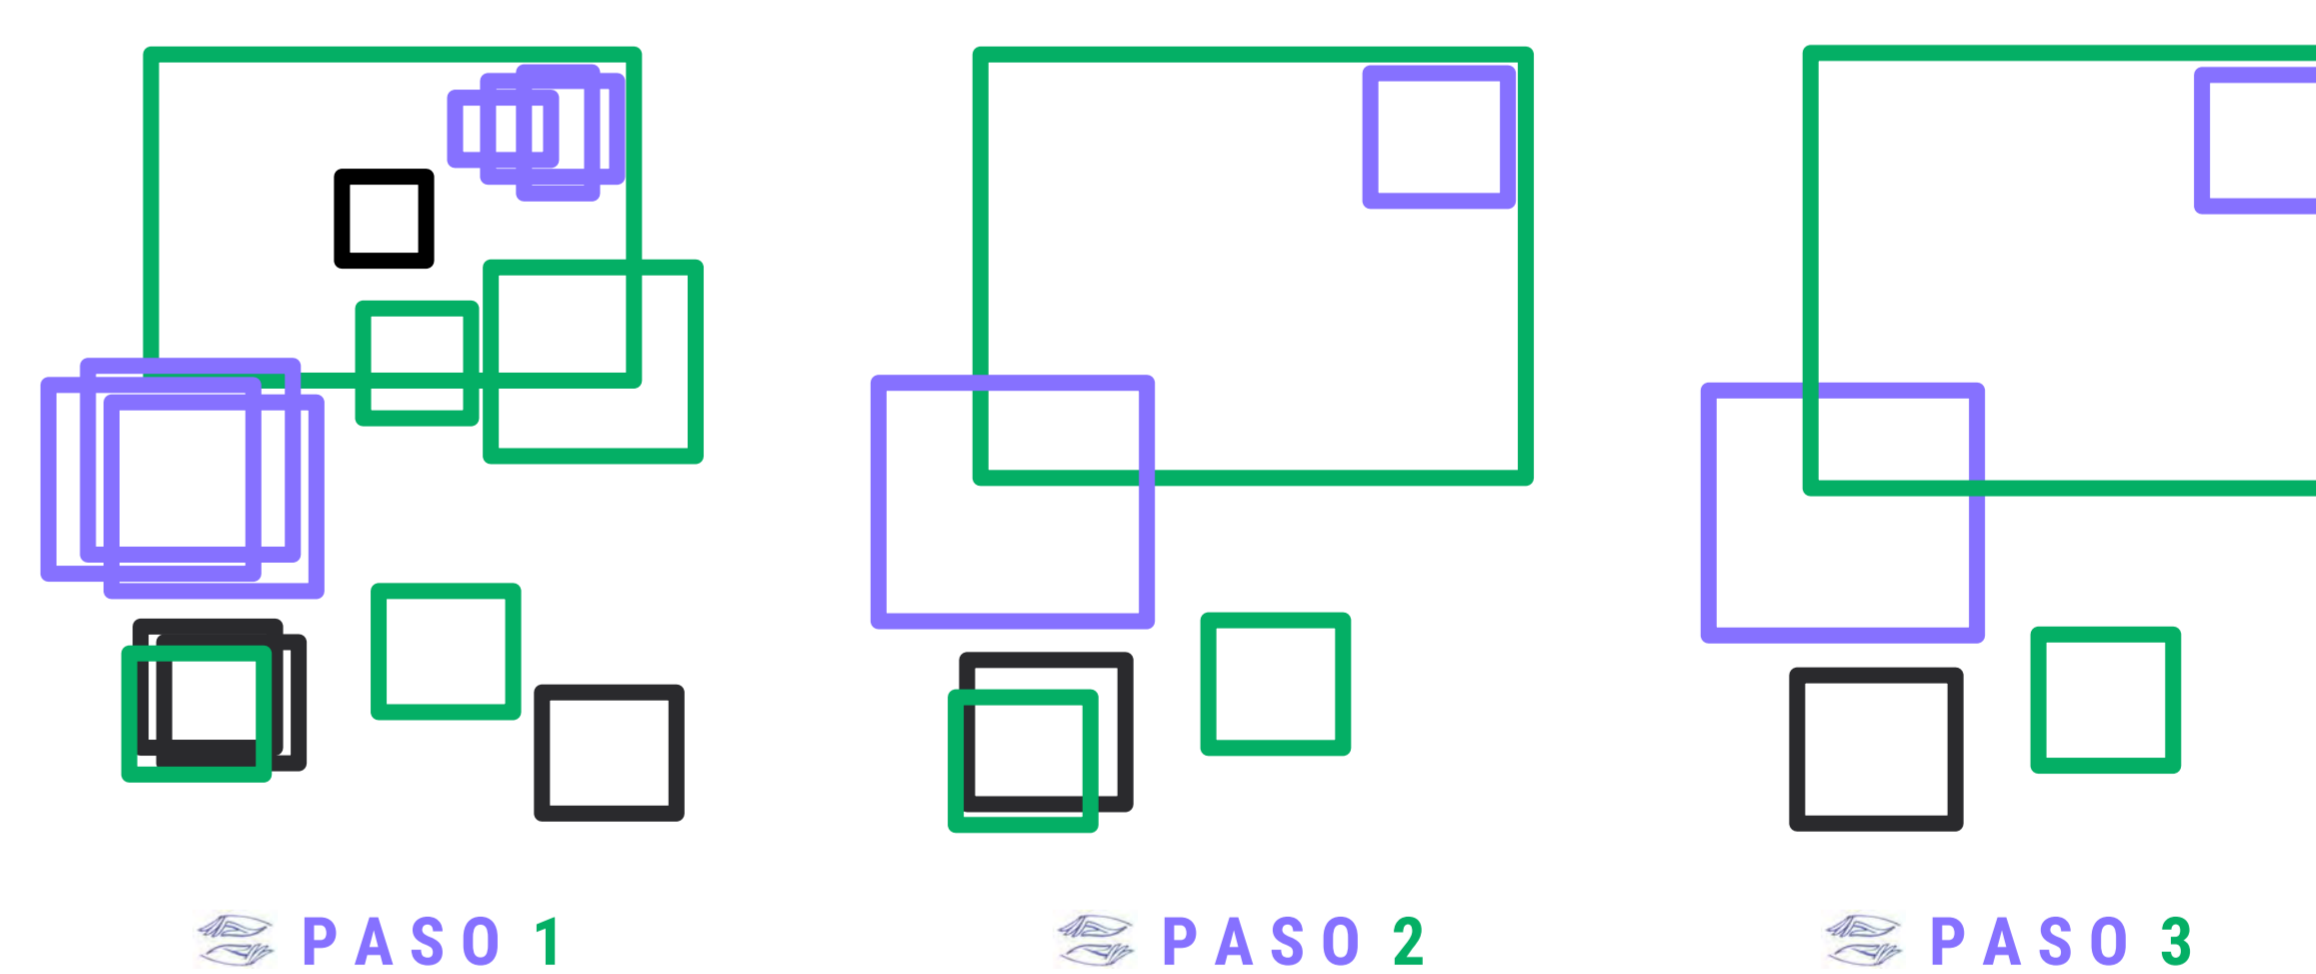
## Resultados

El rendimiento de los algoritmos se midió con el error absoluto medio (MAE), entre otras métricas. El MAE permite cuantificar el desvío entre el IHS4 sugerido por cada modelo y cada dermatólogo y el **AIHS4** generado por el algoritmo de unificación de conocimiento clínico.

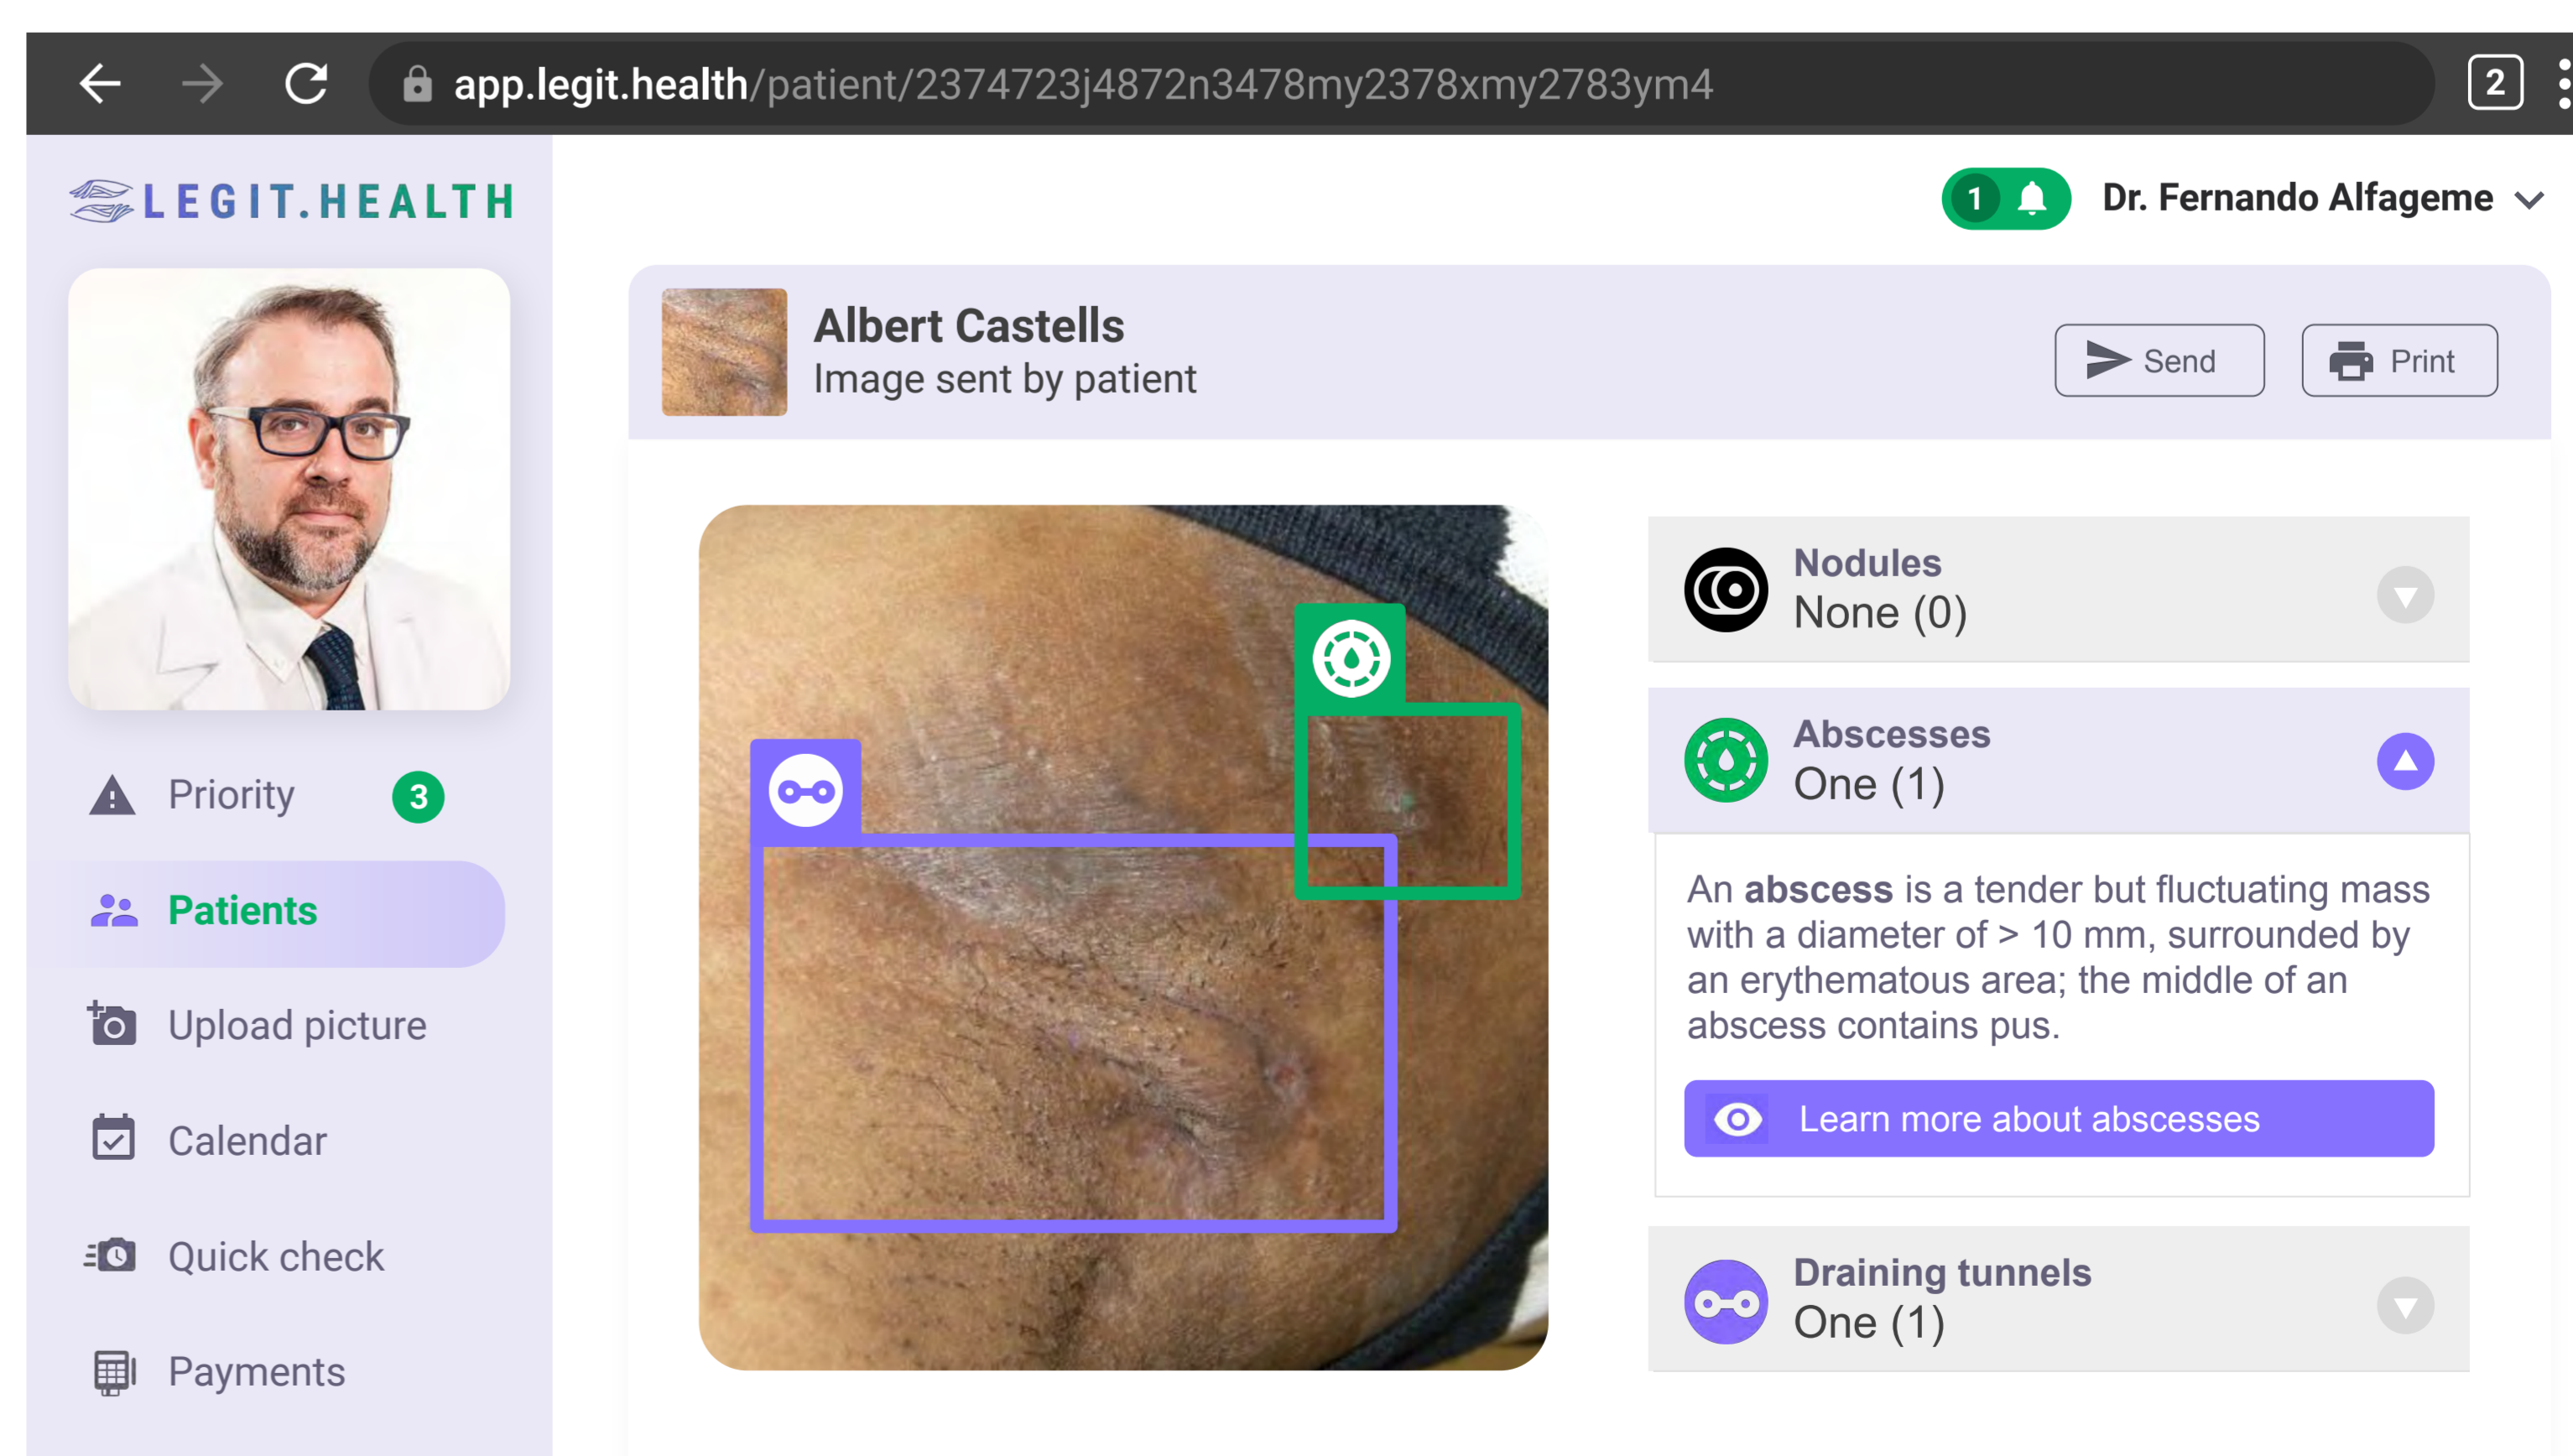
	Error absoluto medio (MAE)		
	HS Leve	HS Moderada	HS Severa
<b>Dermatólogos</b>	2.04	3.01	4.88
YOLOv5 (s)	2.49	3.62	5.35
YOLOv5 (m)	2.21	3.22	6.17
YOLOv5 (l)	2.8	3.72	5.52
YOLOv5 (x)	2.16	3.37	5.26



El algoritmo **Legit.Health-IHS4net** se puede integrar en herramientas de Diagnóstico Asistido por Ordenador (DAO) para dar soporte a la decisión clínica.



Ejemplo de fusión de etiquetas (izquierda a derecha) con nuestro algoritmo de unificación de conocimiento clínico.



La herramienta muestra información adicional sobre las lesiones detectadas.

