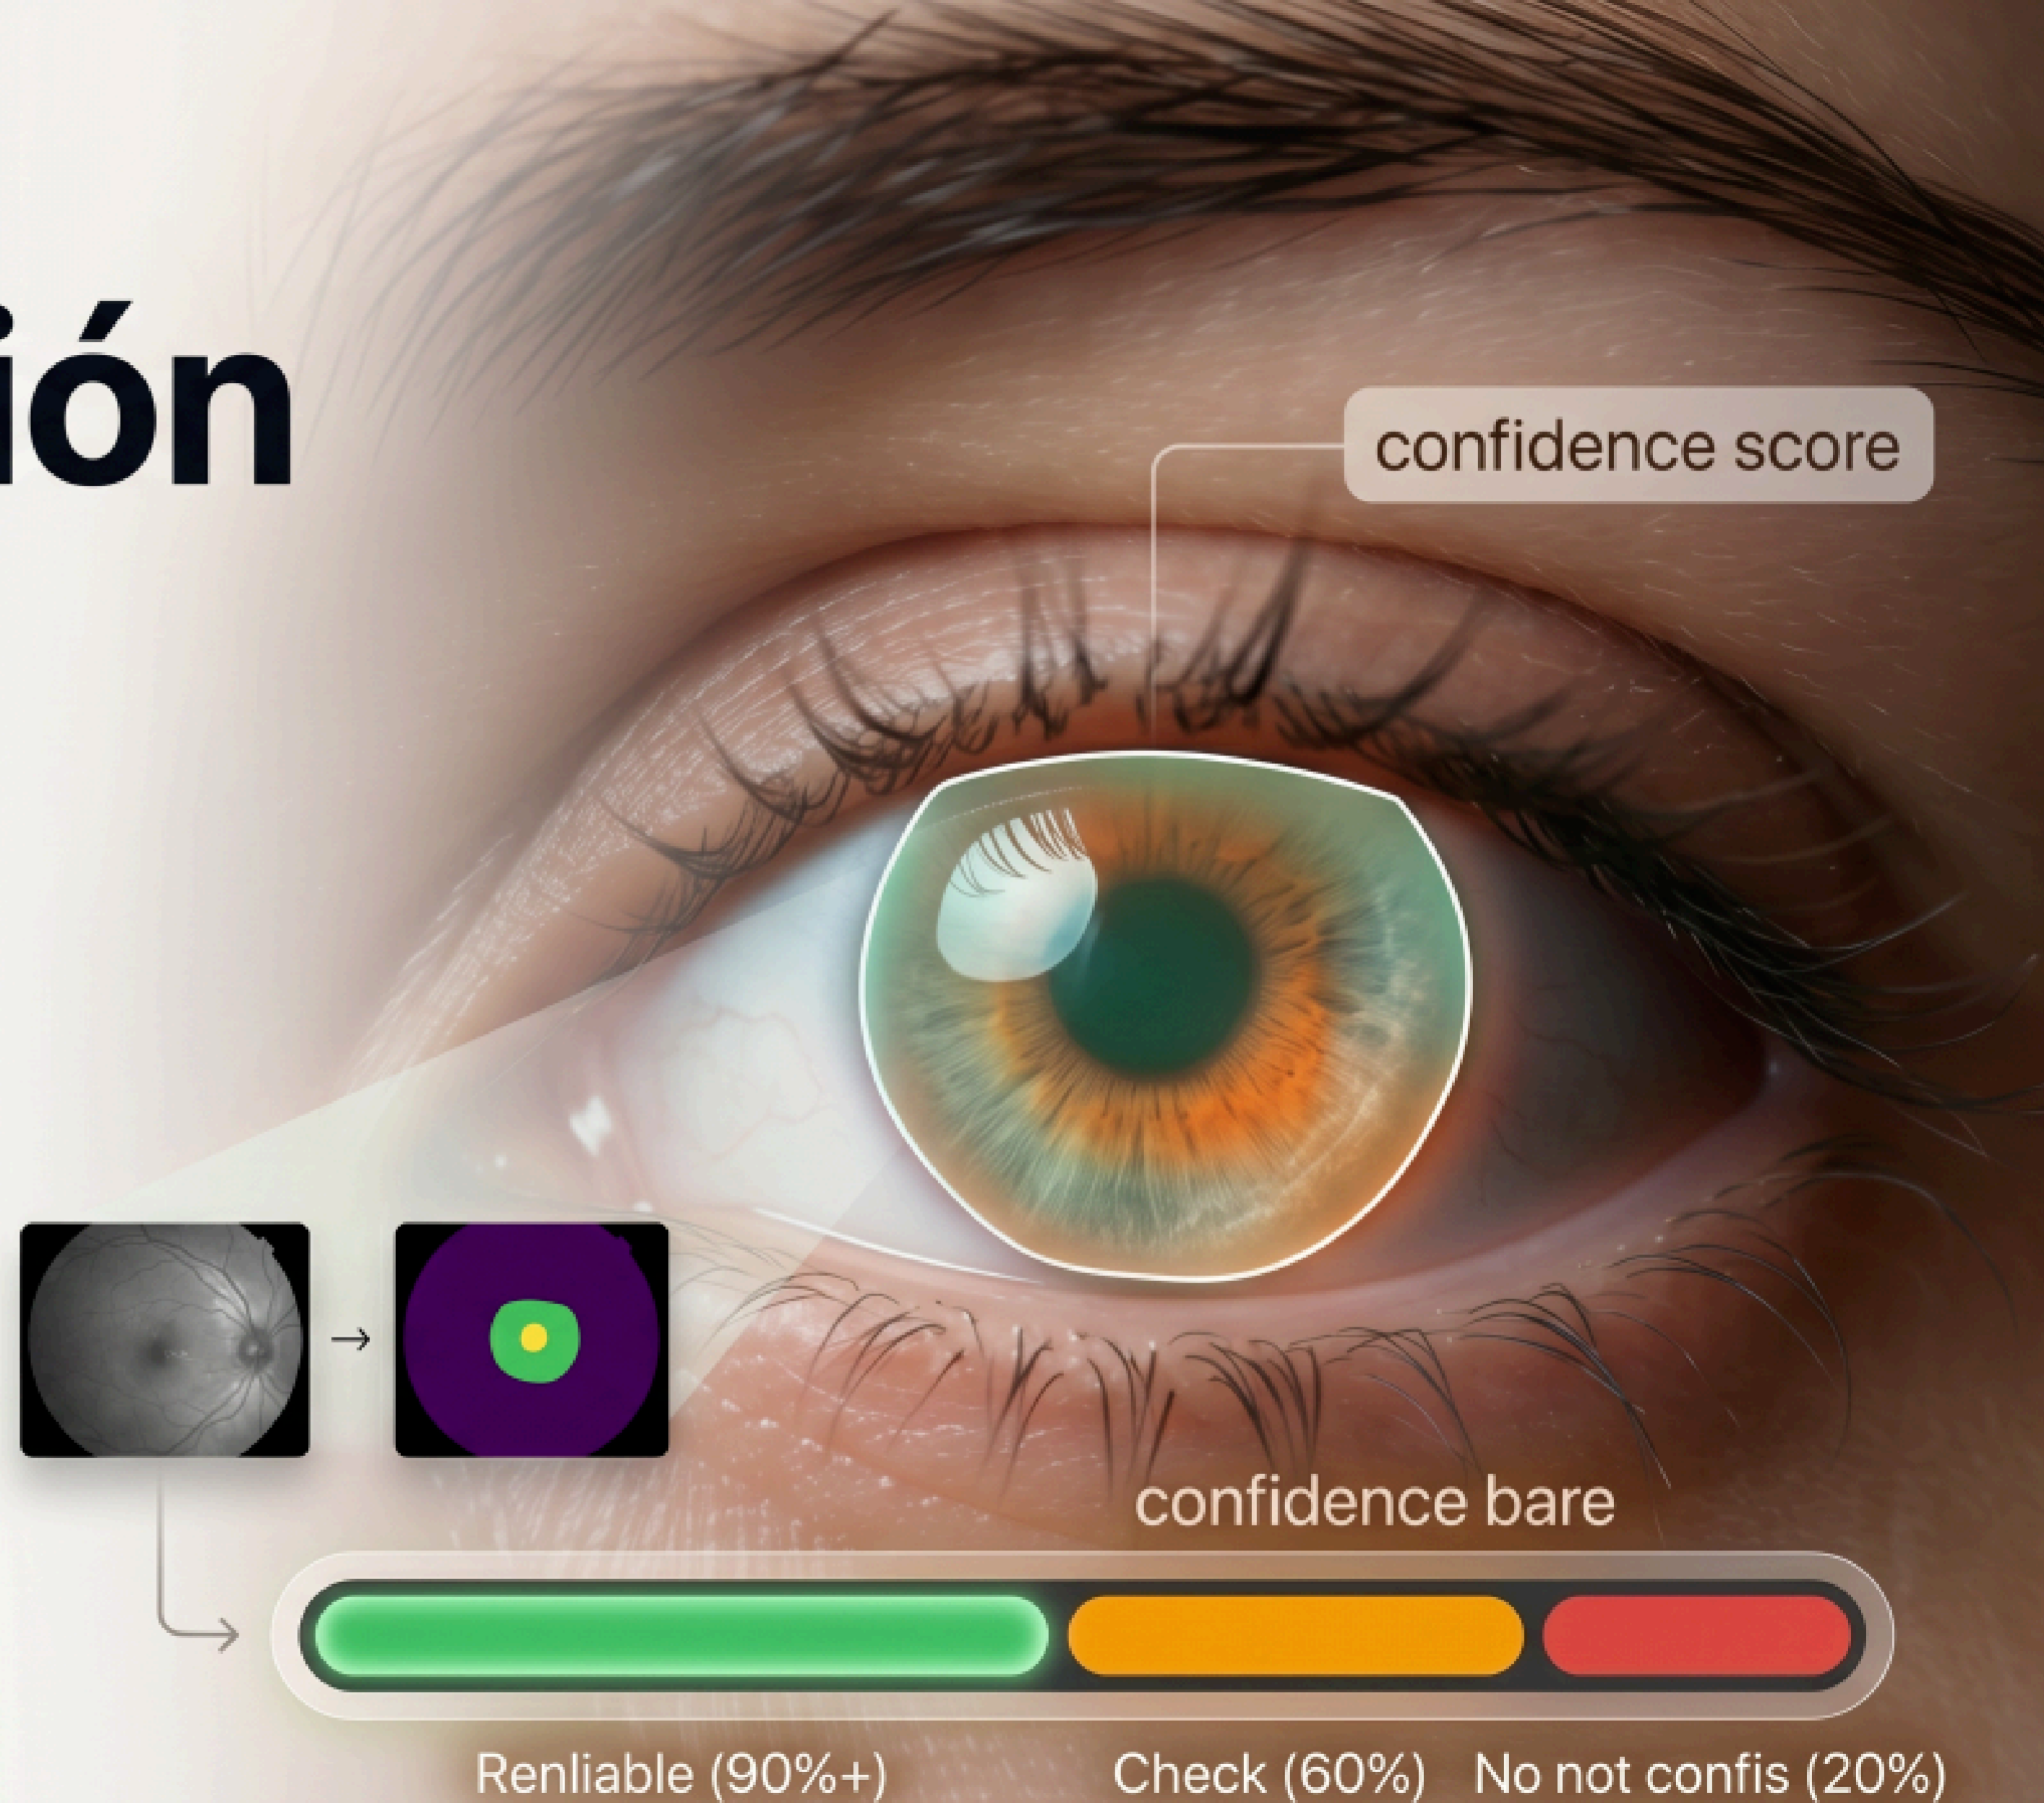


Segmentación Segura en Imágenes Médicas

Hacia una IA Confiable en Incertidumbre, Explicabilidad y Modelos de Segmentación.



La Revolución de la IA en Medicina

De la Imagen a la Decisión Clínica




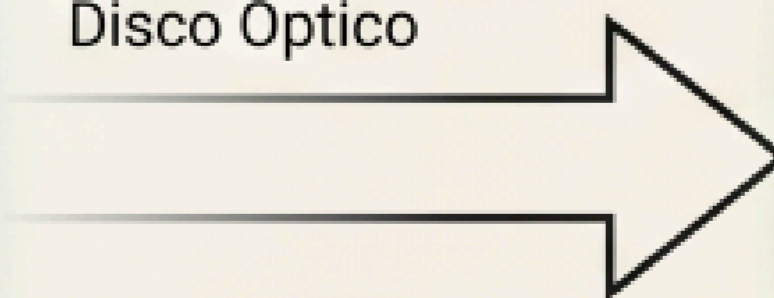


Imagen de entrada



Segmentación

- Contorno Exacto de Tumores, Cataratas, Disco Óptico



Decisión clínica

- Medir
- Diagnosticar
- Planificar Tratamientos


El Riesgo de la IA Caja Negra

Los modelos de deep learning pueden fallar silenciosamente y segmentar de manera incorrecta, dejando patologías reales sin detectar (falso negativo) o creando falsas alertas (falso positivo). Esto conlleva riesgos clínicos directos.

Contextos de alto riesgo:

- Datos de baja calidad (imágenes borrosas)
- Condiciones raras no vistas en el entrenamiento
- Entornos con pocos datos etiquetados


**¿Y si la IA se equivoca
y no lo sabemos? ⚠**



Ejemplos de Fallas Críticas:


Falso Negativo (Catarata Oculta)

Imagen Real



Falso Negativo: La IA no detecta la catarata.

Fallas en la Segmentación




✗ No detectada

Resultado Clínico: Paciente sin tratar

Falso Positivo (Ruido Interpretado)

Imagen Real



Falso Positivo: La IA ve una catarata inexistente.

Fallas en la Segmentación




✗ Falsa Detección

Resultado Clínico: Tratamiento innecesario

¿Qué es la Segmentación Segura?


Precisa

Coincide con la realidad anatómica




Robusta

Funciona en condiciones adversas (pocos datos, baja calidad)



Transparente


Explica su decisión y reporta nivel de confianza



Incertidumbre


Explicabilidad

Precisión




Segmentación Segura

Robustez




Transparencia




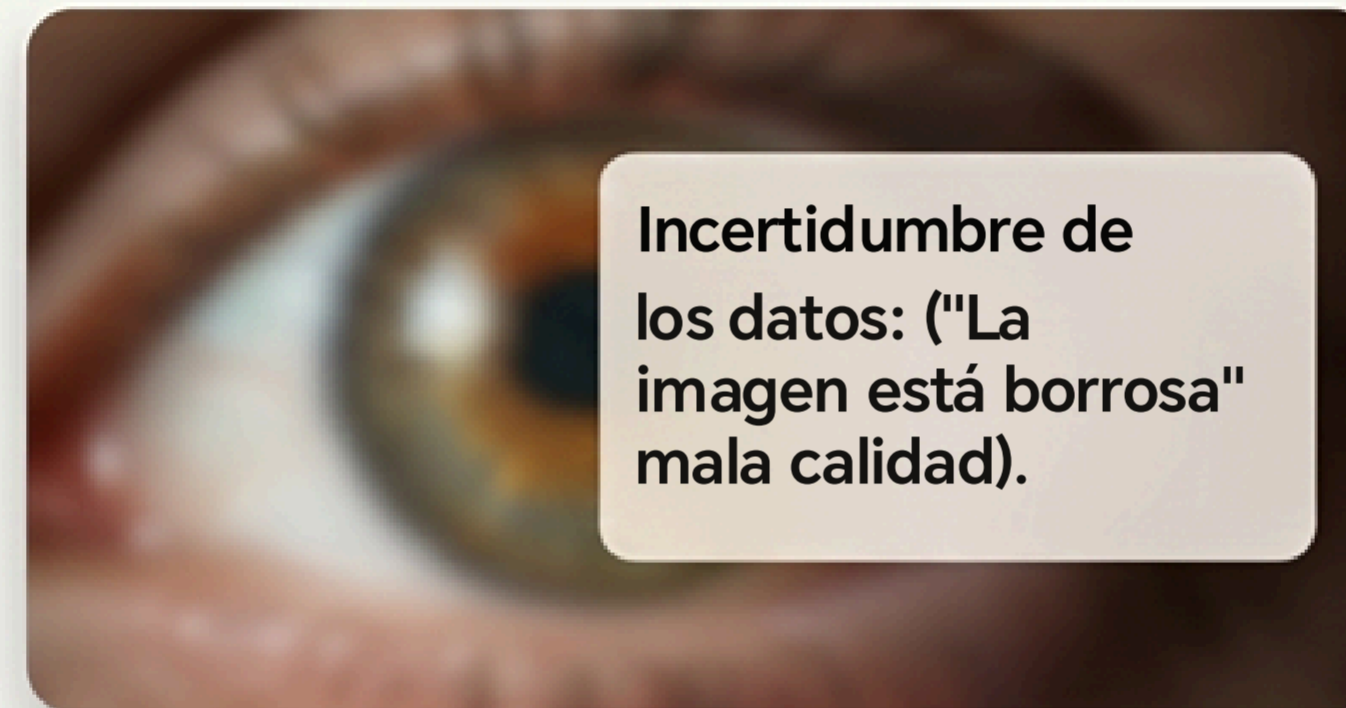
Estimación de Incertidumbre: Qué tan seguro está el modelo?

Introducción


El fundamental concepto es que la IA debe reportar su nivel de confianza: "estoy 95% seguro" o "solo estoy 40% seguro — mejor revisa tú". Es crucial saber cuándo la IA está dudando.



Tipos de Incertidumbre



La Barra de Confianza (Semáforo)




La incertidumbre
no es un bug, es una
característica
de seguridad.

Explicabilidad (XAI): ¿Por qué decidió eso?

Mapas de calor (heatmaps) que resaltan las regiones críticas que determinaron la decisión de la IA.

El médico verifica si la IA se fijó en la catarata real o en un artefacto (reflejo, pestaña, borde).

La explicabilidad convierte la caja negra en cristal — vemos el razonamiento, no solo el resultado.



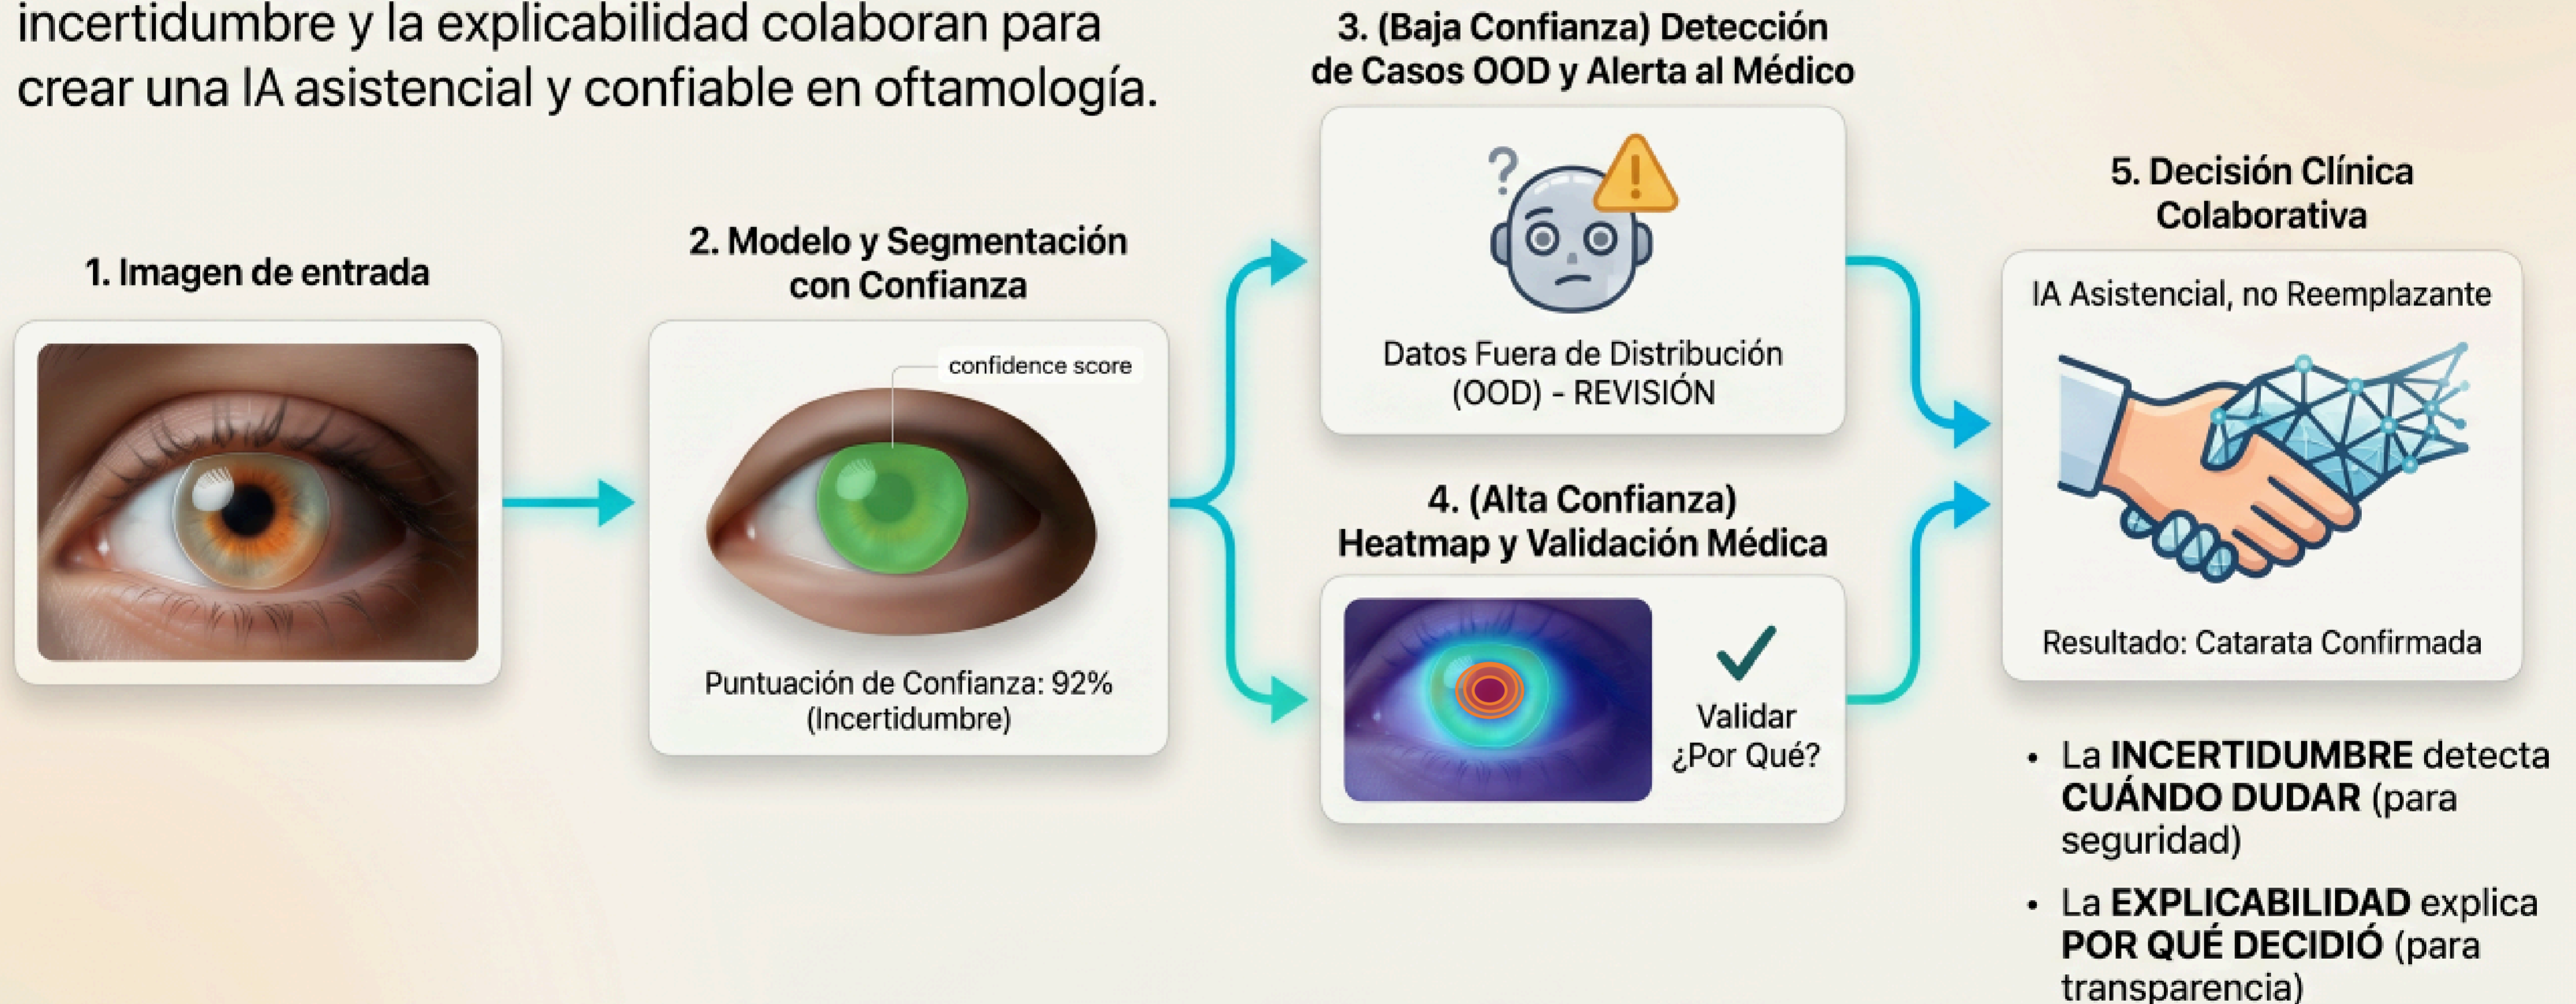
Heatmap Correcto:
Atención sobre la
catarata real



Heatmap Incorrecto:
Atención sobre un
reflejo de flash y borde


Cómo se Combinan: Un Sistema de Confianza

Un flujo de trabajo integrado donde la incertidumbre y la explicabilidad colaboran para crear una IA asistencial y confiable en oftamología.



El Problema: Cataratas y Pocos Datos

- **Catarata:** Principal causa de ceguera reversible (OMS, 94M afectados).
- **Escasez global:** Zonas sin oftalmólogos ni datos etiquetados para entrenar IA.
- **El Reto:** ¿Cómo detectar con pocos ejemplos (Few-Shot)?



El Dataset: Datos Muy Insuficientes

Dataset Cataract-SEG: 719 imágenes

IA Tradicional:
10,000+ datos → Necesita mucho

Nuestro Enfoque (Few-Shot):
3, 6, 9... ejemplos → Usa muy poco




La Solución: Adaptar Modelos Fundacionales

Modelos Fundacionales
(ej. SAM)
→ Ya 'saben' ver



→ Adaptación Few-Shot →

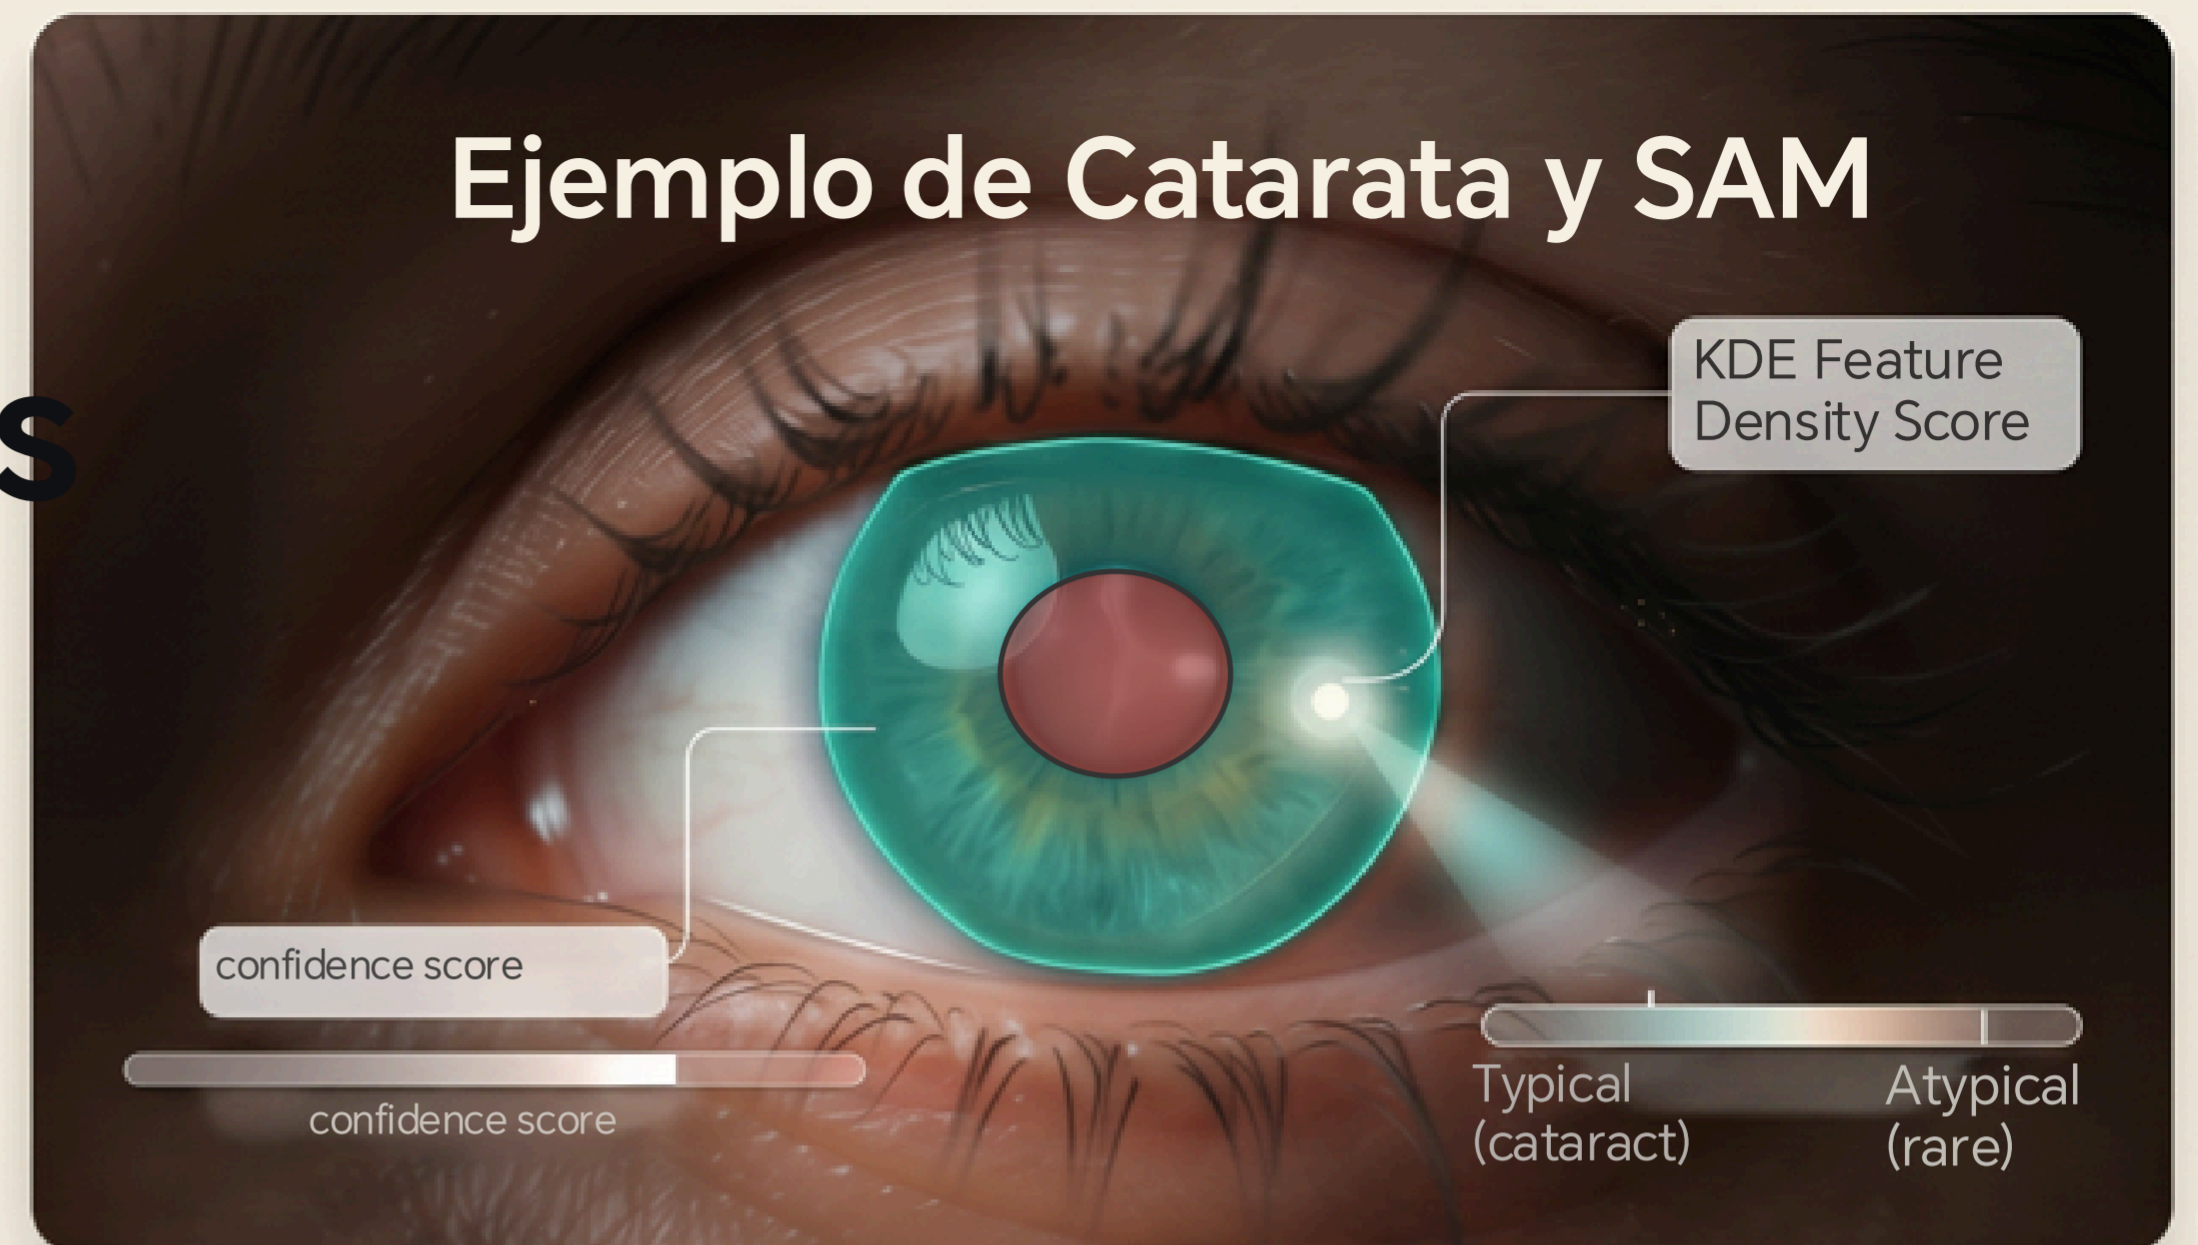
Detección Confiable
(con 'KDE Feature Density'
círculo y 'OOD Threshold'
como en <IMAGE 0>)




Pocos ejemplos, gran conocimiento

Nuestra Propuesta: Densidad de Características

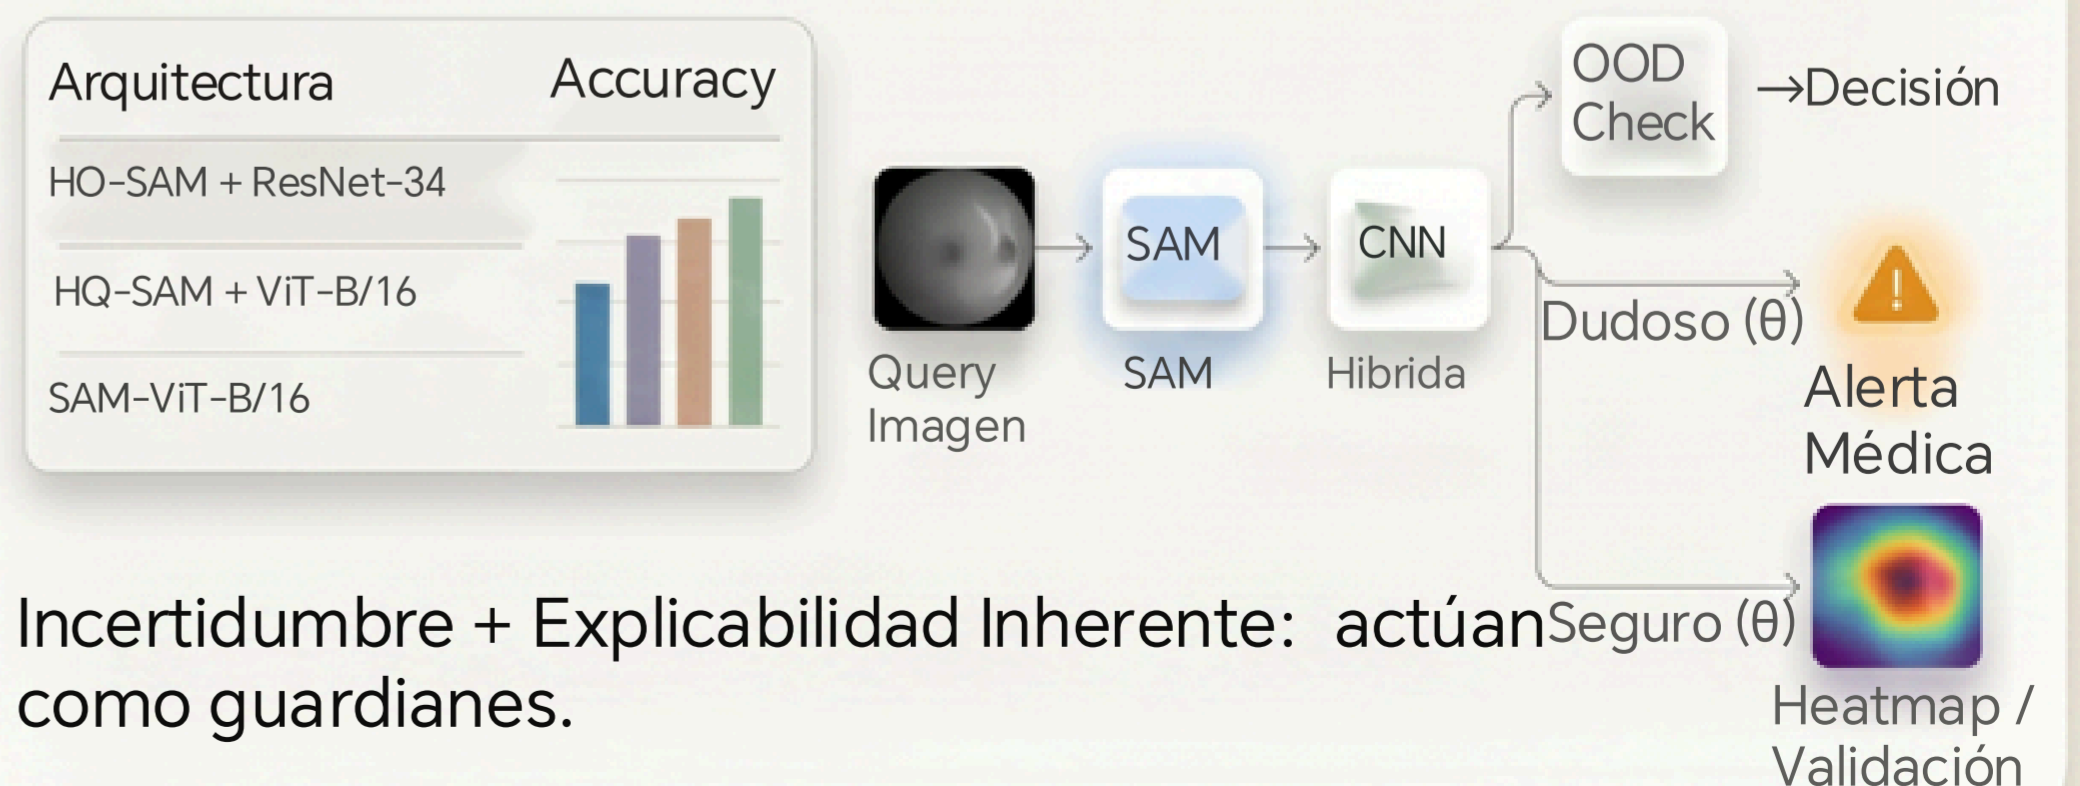
- Pipeline SAM genera máscaras candidatas del ojo.
- Red híbrida (CNN+Transformer) Selecciona la máscara correcta.
- **Novedad:** Modela la representación del conocimiento interno del modelo teniendo en cuenta una imagen nueva.



Intuición: Se parece a una catarata conocida o es algo raro?



**Resultados Clave (Few-Shot):
k=21 es el punto óptimo..HQ-SAM >SAM.**

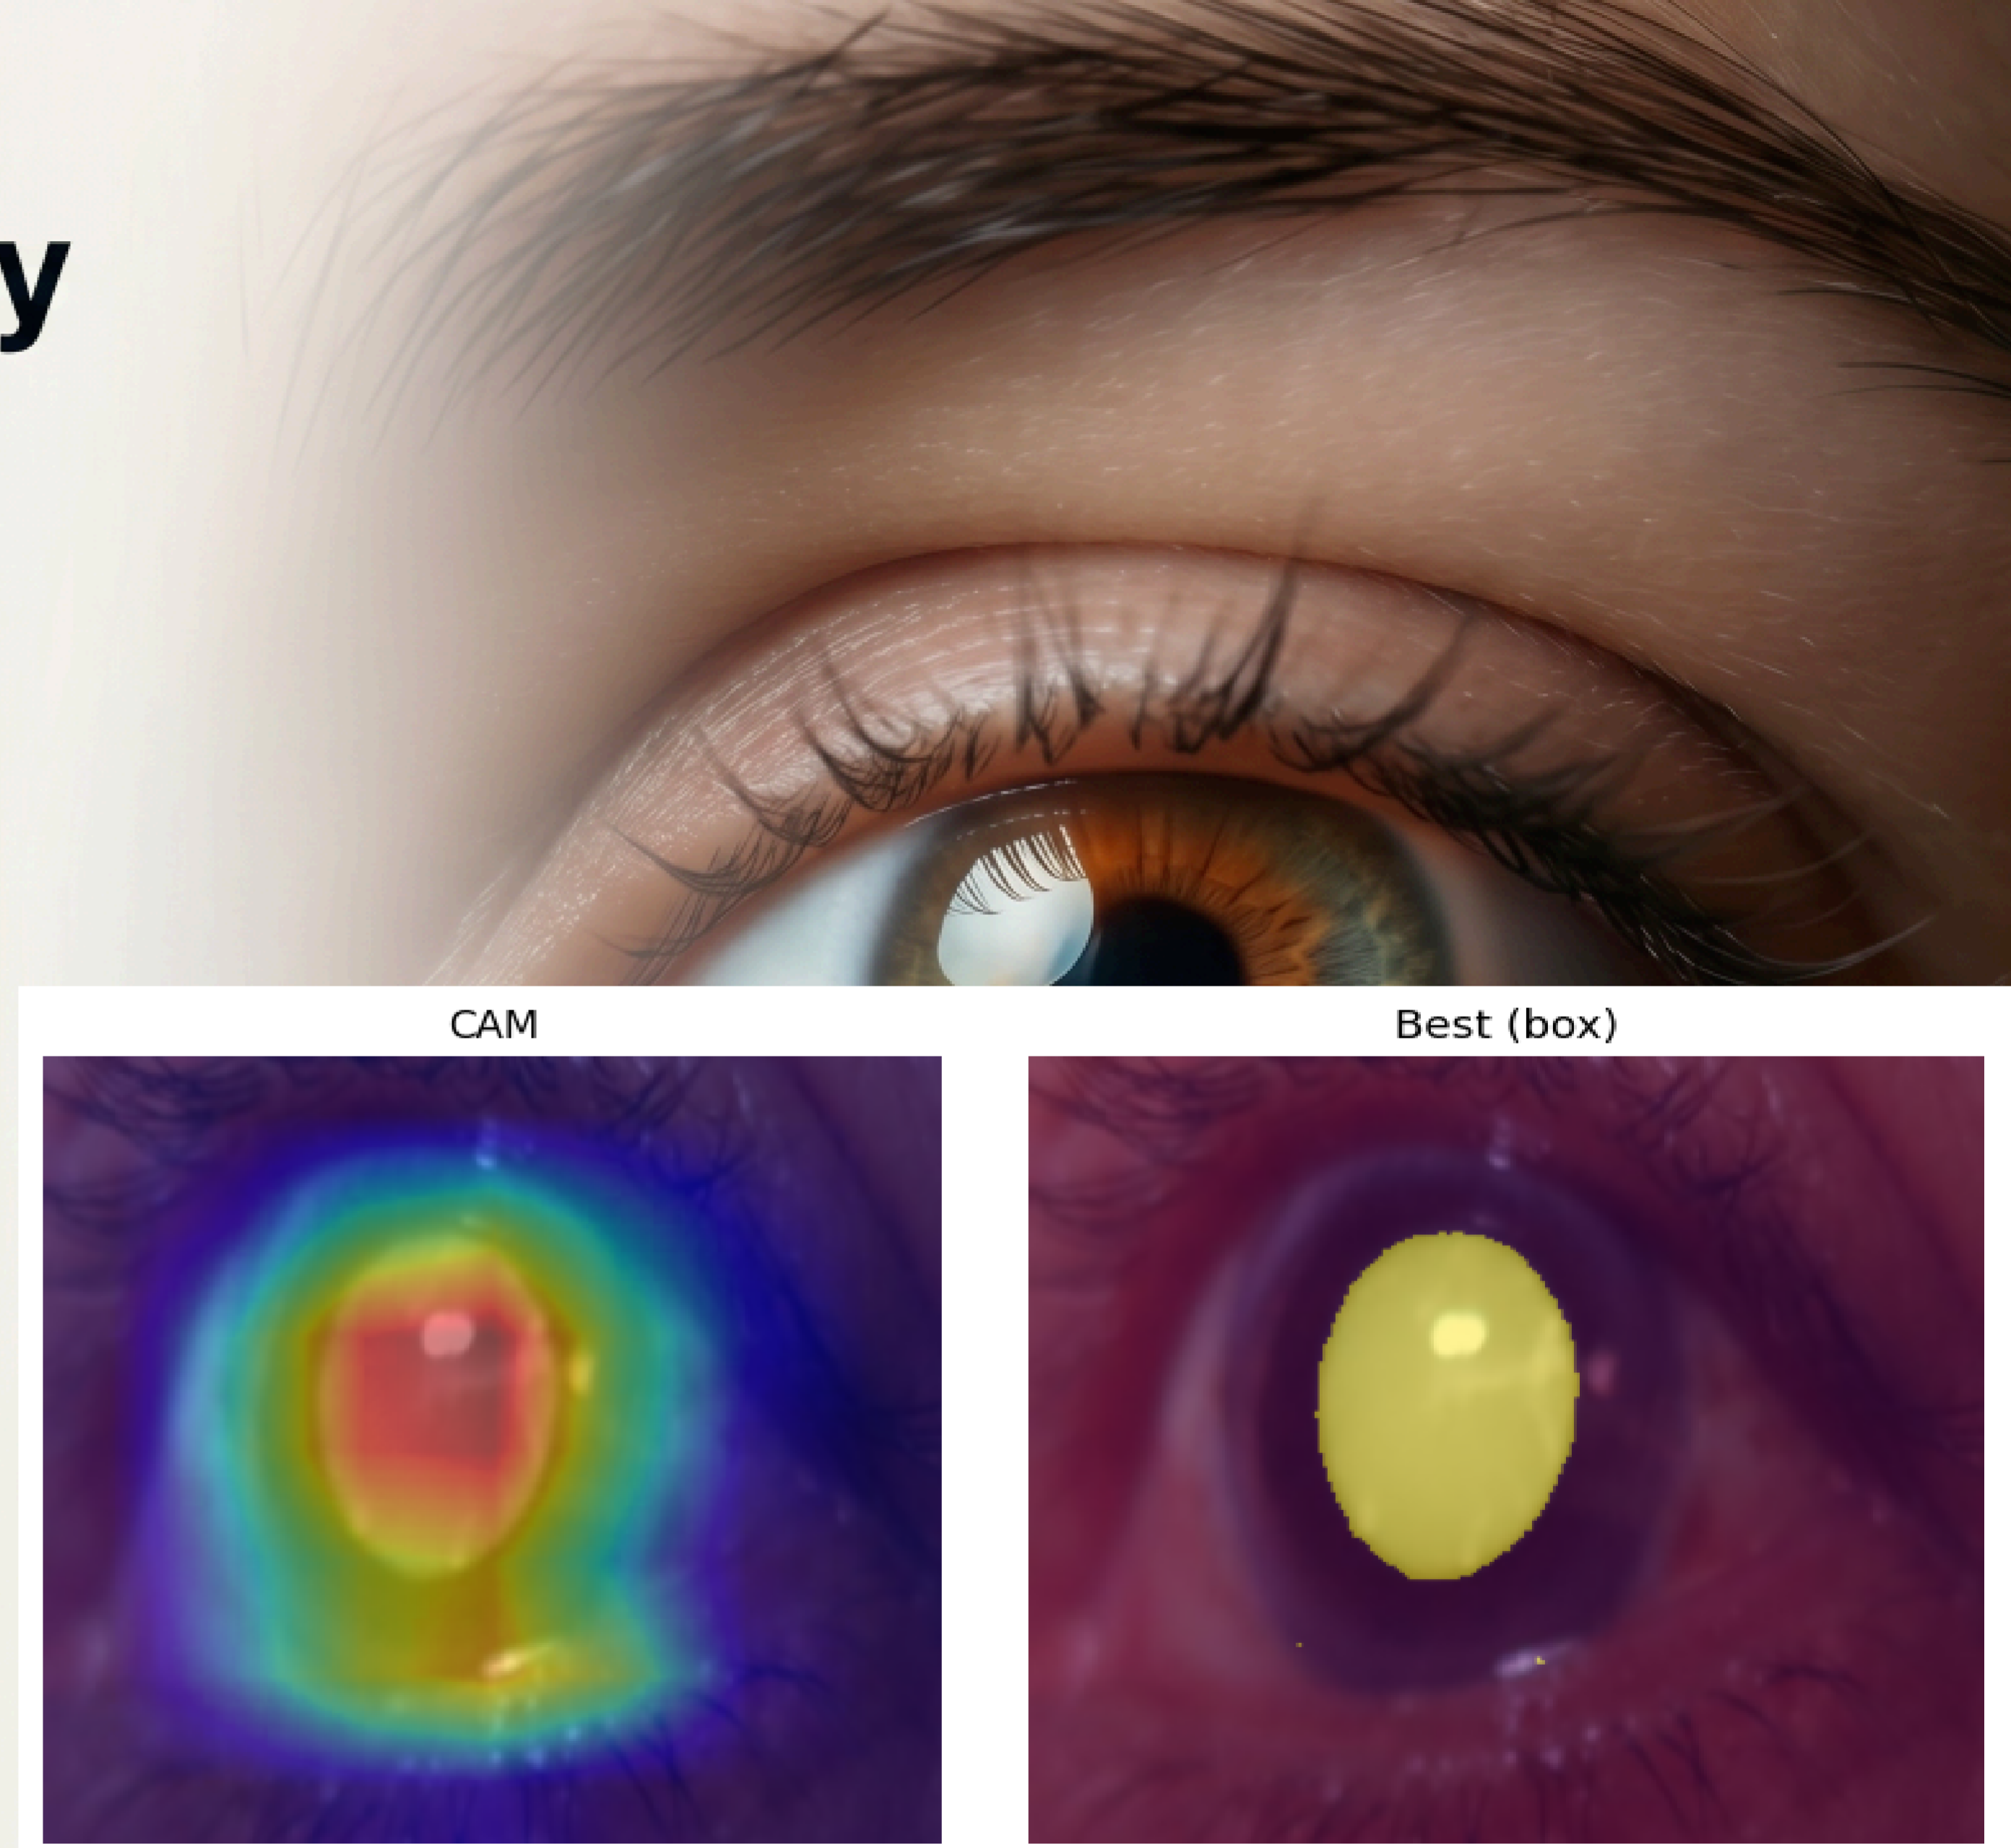


Incertidumbre + Explicabilidad Inherente: actúan como guardianes.

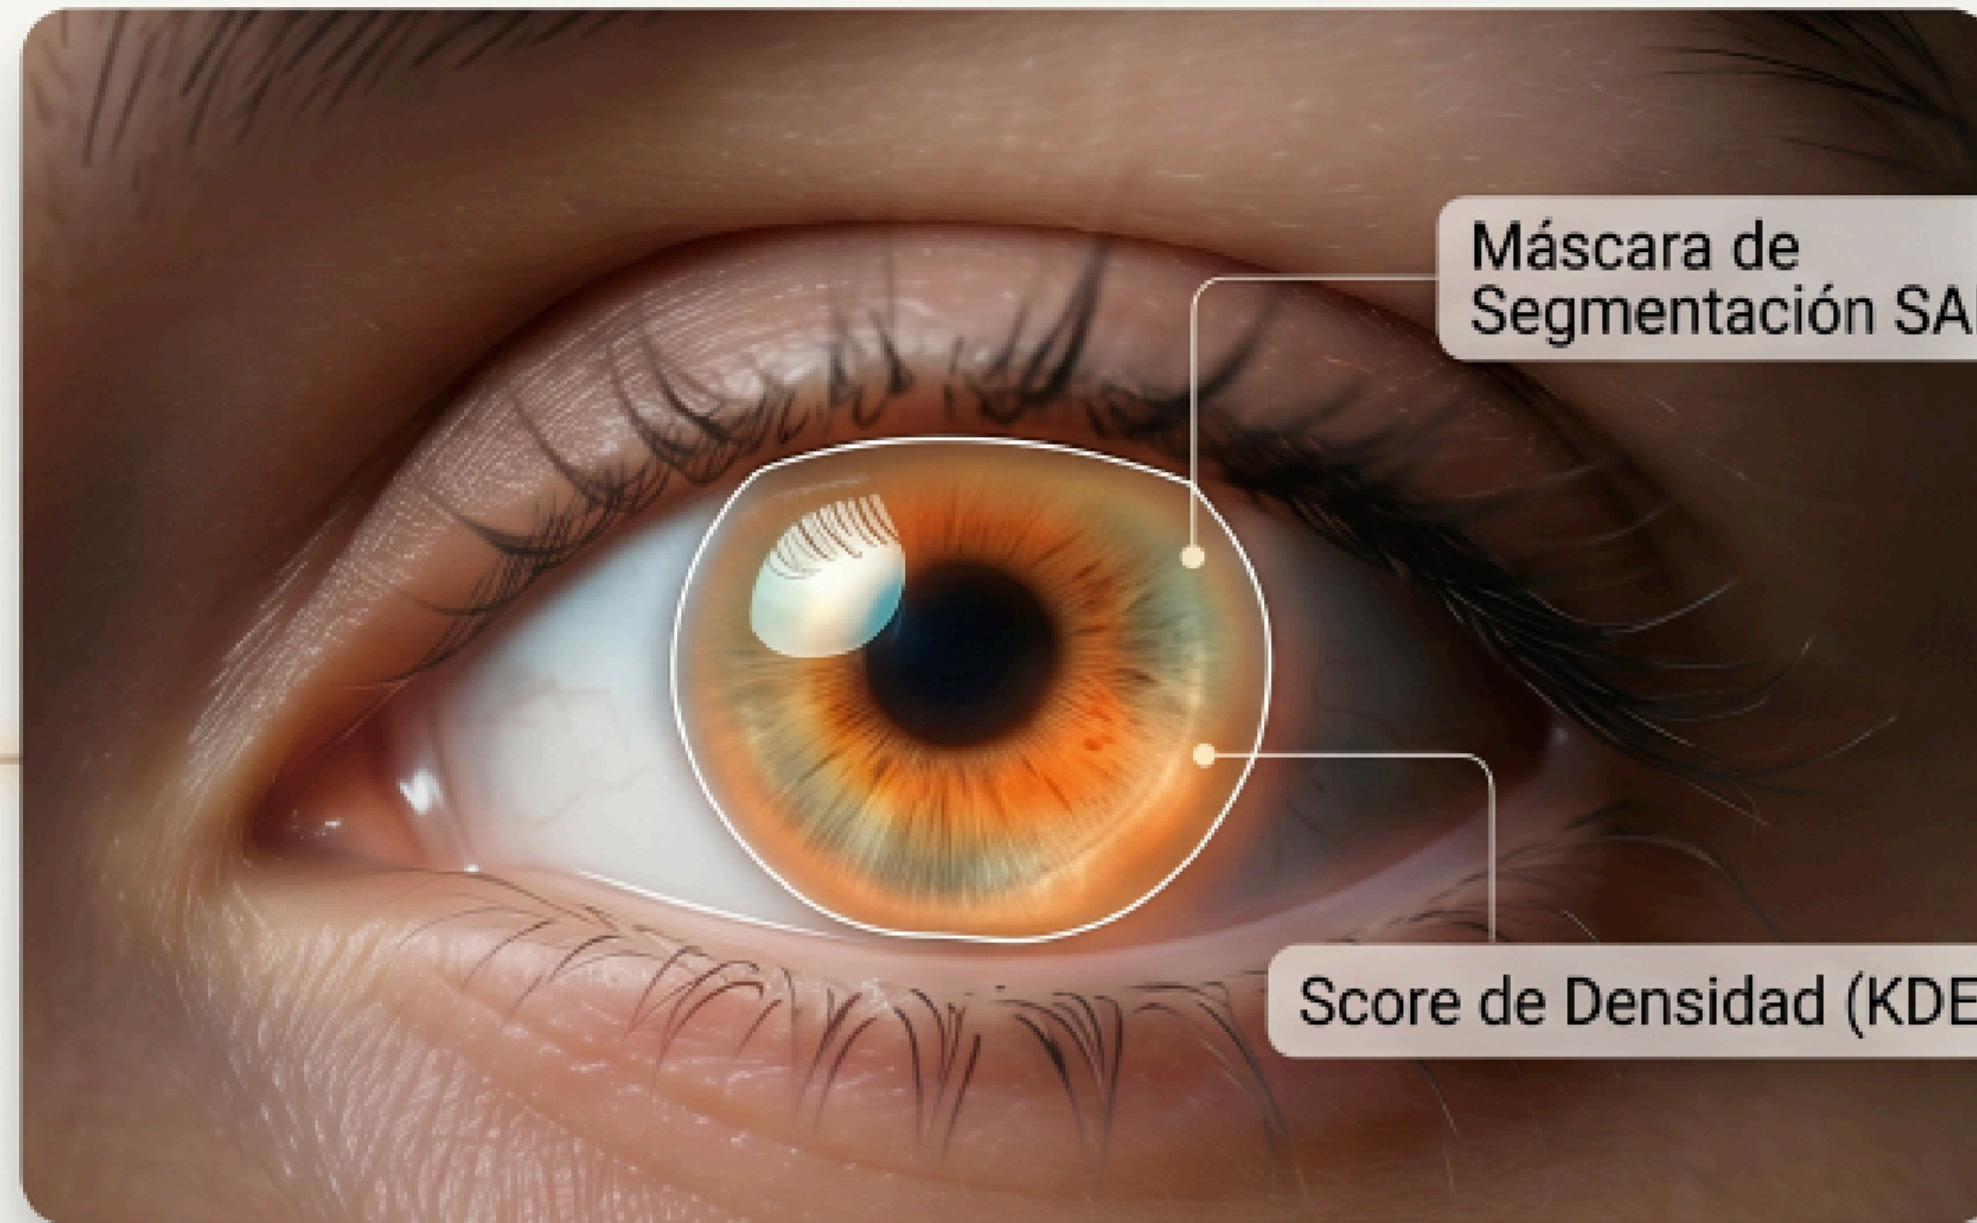
Propuesta de weakly supervised learning

Segmentación con Mínima Supervisión (WSSS)

- 👁️ Reduce la necesidad de costosas máscaras de segmentación píxel a píxel.
- 🏷️ Utiliza etiquetas a nivel de imagen o puntos para entrenar modelos robustos.
- 🎯 WSSS como solución eficiente para conjuntos de datos médicos limitados.



Por Qué Esto es Segmentación Segura



OOD Threshold
(Theta_min, Theta_max)

SCORE DE DENSIDAD ACTUAL

¡ALERTA
OOD!


ALTA
CONFIANZA

CONFIDENCE SCORE

✓ **1. INCERTIDUMBRE INTEGRADA**
Umbral OOD actúa como guardián; sistema dice 'no sé' en vez de inventar.

✓ **2. EXPLICABILIDAD INHERENTE**
Máscaras SAM visibles y score de densidad numérico para auditar.

✓ **3. FEW-SHOT / ROBUSTA**
Reduce barrera de entrada para clínicas sin grandes datasets.




Conclusiones y Visión


La segmentación médica no puede ser solo precisa; debe ser confiable y explicable. Las técnicas de incertidumbre y explicabilidad son el puente entre la IA y la práctica clínica real.

No buscamos IA que reemplace al oftalmólogo. Buscamos IA que sea honesta cuando duda, explique cuando decide, y funcione donde no hay especialistas.


Grad-CAM



SAM AMG



SAM BBox



MedSAM BBox

