



Universidad Nacional (Costa Rica)



Proyecto de graduación

Para optar al título

Maestría en Física Médica

Título del trabajo

Análisis comparativo de estudios sobre adquisición de imagen, segmentación y diseño de modelos 3D utilizados en procedimientos pre-quirúrgicos: Avances, métodos y precisión clínica

Proyecto de graduación para optar al título de **Máster en Física Médica**

Autor:

Lic. Juan Chester Herbacio Z.

Tutor:

Dr. David Chacón Obando

Julio de 2025

Resumen

Este Trabajo Final de Graduación presenta una revisión comparativa de estudios sobre la generación de modelos 3D prequirúrgicos a partir de datos de imagen médica, con el objetivo de evaluar métodos, avances tecnológicos y precisión clínica. Tras aplicar un protocolo PRISMA a 1 235 registros, se incluyeron 30 estudios publicados entre 2014 y 2025. Se analizaron cuatro fases clave: adquisición de imagen (TC, RM, US), segmentación (manual, semi-automática, IA), modelado e impresión (FDM, SLA, SLS, Micro-SLA, bioprinting 4D) y validación clínica (Dice, Hausdorff, errores volumétricos, validación subjetiva).

Los resultados expuestos por otros autores revelan que la segmentación basada en IA (U-Net 3D, Swin-UNet) reduce el tiempo a < 1 h y alcanza Dice de 0.92–0.97, superando ampliamente a métodos manuales (4–6 h; Dice 0.80–0.88). En impresión, SLA, SLS y Micro-SLA ofrecen la mayor precisión (Dice ≥ 0.90) y mejoras clínicas —incluida una reducción de hasta 30 % en tiempo quirúrgico—, aunque a un costo de USD 500–2 000 por modelo. Por su parte, FDM resulta costo-efectivo (USD 50–300) con precisión aceptable (Dice ≈ 0.85) para entornos de recursos limitados. Se identificó una heterogeneidad en la validación clínica: cerca del 40 % de los estudios no cuantifica impactos clínicos, lo que subraya la necesidad de protocolos estandarizados.

En respuesta, se propone el **Protocolo EV-3D**, que unifica criterios de calidad desde la adquisición DICOM hasta la validación clínica, con métricas mínimas (Dice ≥ 0.90 , desviación dimensional ≤ 1 %, puntuación de utilidad $\geq 4/5$) y registro sistemático de tiempos, costos y satisfacción del cirujano. Este protocolo facilita la implementación de modelos 3D seguros y eficientes, promueve la formación multidisciplinaria y sienta las bases para futuros estudios prospectivos en física médica.

Abstract

This Graduation Final Work delivers a comparative review of studies on the creation of pre-operative 3D models from medical imaging data, aiming to assess methods, technological advances, and clinical accuracy. Employing a PRISMA protocol on 1 235 records, 30 studies from 2014 to 2025 were included. The analysis covered four key phases: image acquisition (CT, MRI, US), segmentation (manual, semi-automatic, AI-based), modeling and printing (FDM, SLA, SLS, Micro-SLA, 4D bioprinting), and clinical validation (Dice, Hausdorff, volumetric errors, subjective evaluation).

Other author's findings indicate that AI-based segmentation (U-Net 3D, Swin-UNet) reduces processing time to < 1 h and achieves Dice scores of 0.92–0.97, outperforming manual methods (4–6 h; Dice 0.80–0.88). Regarding printing, SLA, SLS, and Micro-SLA deliver the highest accuracy (Dice \geq 0.90) and clinical benefits—such as up to 30 % reduction in surgical time—but incur costs of USD 500–2 000 per model. Conversely, FDM proves cost-effective (USD 50–300) with acceptable accuracy (Dice \approx 0.85) for resource-constrained settings. A 40 % heterogeneity was noted in clinical validation, highlighting the need for standardized protocols.

To address this, the **EV-3D Protocol** is proposed, integrating quality criteria from DICOM acquisition through clinical validation, with minimum metrics (Dice \geq 0.90, dimensional deviation \leq 1 %, utility score \geq 4/5) and systematic tracking of time, cost, and surgeon satisfaction. This protocol supports the implementation of safe, efficient 3D models, promotes multidisciplinary training, and lays the groundwork for future prospective studies in medical physics.

Índice General

I.	Capítulo I: Introducción.....	1
1.1	Planteamiento del problema.....	1
1.2	Justificación.....	1
1.3	Objetivos.....	3
1.3.1	Objetivo general.....	3
1.3.2	Objetivos específicos.....	3
1.4	Alcances y limitaciones.....	3
1.5	Preguntas de investigación.....	4
II.	Capítulo II: Marco teórico.....	5
2.1	Adquisición de imágenes médicas.....	5
2.1.1	Tomografía Computarizada (TC).....	5
2.1.2	Resonancia Magnética (RM).....	6
2.2	Segmentación de imágenes médicas.....	6
2.2.1	Segmentación manual.....	6
2.2.2	Segmentación semiautomática.....	6
2.2.3	Segmentación automática basada en inteligencia artificial.....	6
2.3	Descripción de los procesos de segmentación automática y semiautomática.....	7
2.4	Modelado 3D e impresión tridimensional.....	11
2.5	Validación clínica y métricas de precisión.....	12
2.5.1	Índice de similitud de Dice (DSC):.....	12
2.5.2	Distancia de Hausdorff:.....	14
2.5.3	Validación subjetiva por expertos clínicos:.....	16
III.	Capítulo III: Metodología.....	17
3.1	Tipo de estudio.....	17
3.2	Estrategia de búsqueda.....	17
3.3	Criterios de inclusión y exclusión.....	18
3.4	Variables analizadas.....	19
3.5	Procedimiento de análisis.....	19

3.6	Consideraciones éticas	20
IV.	Capítulo IV: Resultados y discusión.....	21
4.1	Hallazgos Clave	21
4.2	Comparación de metodologías	21
4.3	Técnicas de segmentación	22
4.4	Validación de precisión y utilidad clínica.....	22
4.5	Matriz comparativa	24
4.6	Tendencias y patrones identificados	30
4.6.1	Automatización en la segmentación	30
4.6.2	Tecnología de impresión y precisión clínica.....	31
4.6.3	Costos, tiempo y accesibilidad	33
4.6.4	Validación clínica heterogénea	33
4.6.5	Patrones por modalidad de imagen	34
4.6.6	Brecha entre Métodos Manuales y Automáticos.....	35
4.6.7	Implicaciones Clínicas	38
4.7	Discusión	39
4.7.1	Interpretación de los hallazgos	39
4.7.2	Implicaciones para la práctica en física médica	40
4.7.3	Limitaciones del estudio	42
V.	Capítulo V: Conclusiones y Recomendaciones	44
5.1	Conclusiones principales	44
5.2	Recomendaciones para investigación futura	45
5.3	Recomendaciones institucionales y clínicas	45
VI.	Referencias.....	47
VII.	Anexo I.....	51

Índice de tablas

<i>Tabla 1</i> Matriz comparativa de 30 estudios.	24
<i>Tabla 2</i> Flujo de trabajo y criterios de control	52

Índice de figuras

<i>Figura 1</i> Pipeline 2D multivista.....	8
<i>Figura 2</i> Diagrama 2D para el DSC.....	13
<i>Figura 3</i> Diagrama PRISMA para selección de estudios.	20
<i>Figura 4</i> Tecnología de impresión.....	32
<i>Figura 5</i> Modalidad de imagen	35
<i>Figura 6</i> Métodos de segmentación	35
<i>Figura 7</i> Tiempo de segmentación	37
<i>Figura 8</i> Índice de Similitud DICE (DSC)	38

Índice de ecuaciones

<i>Ecuación 1.</i> Índice de similitud DICE	12
<i>Ecuación 2.</i> Distancia de Hausdorff.....	14
<i>Ecuación 3.</i> Error volumétrico absoluto.....	15
<i>Ecuación 4.</i> Error volumétrico porcentual	16

I. Capítulo I: Introducción

1.1 Planteamiento del problema

En los últimos años, el uso de modelos tridimensionales (3D) generados a partir de estudios de imagen médica se ha consolidado como una herramienta de gran valor en la planificación quirúrgica. Estos modelos permiten a los equipos médicos visualizar estructuras anatómicas complejas de manera precisa, facilitando la comprensión espacial, la comunicación entre especialidades y la toma de decisiones clínicas (George et al., 2017).

El desarrollo de tecnologías de adquisición de imágenes, como la tomografía computarizada (TC) y la resonancia magnética (RM), junto con avances en segmentación digital y manufactura aditiva, ha permitido la creación de réplicas físicas de órganos, huesos y sistemas vasculares. Sin embargo, la implementación clínica de estos modelos aún enfrenta importantes desafíos. Existen diferencias notables entre estudios en cuanto a los protocolos de adquisición, algoritmos de segmentación, herramientas de diseño y validación clínica, lo que dificulta la comparación directa y la generalización de resultados (Lopez-Lopez et al., 2021; George et al., 2017).

Por otra parte, la validación de estos modelos suele basarse en criterios subjetivos o métricas diversas, lo cual complica la evaluación estandarizada de su precisión y utilidad. A pesar de su creciente adopción, aún no hay consenso sobre las mejores prácticas ni guías clínicas ampliamente aceptadas para su desarrollo y aplicación. Esta situación evidencia la necesidad de una revisión crítica y comparativa que integre los enfoques más efectivos y permita establecer líneas de referencia para futuras investigaciones y desarrollos clínicos (Lopez-Lopez et al., 2021; Ekman et al., 2025).

1.2 Justificación

El uso de modelos 3D impresos con fines clínicos ha demostrado beneficios sustanciales en diversas disciplinas médicas, desde la neurocirugía hasta la cirugía cardiovascular y ortopédica. Estos modelos contribuyen a:

- **Reducir los tiempos operatorios**, al permitir una planificación más precisa.

- **Mejorar la precisión quirúrgica**, gracias a la reproducción fiel de la anatomía del paciente.
- **Facilitar la educación del paciente**, al ofrecerle una visualización tangible de su patología.
- **Permitir simulaciones preoperatorias**, que ayudan a anticipar dificultades técnicas (George et al., 2017; Lopez-Lopez et al., 2021).

Sin embargo, esta tecnología aún es percibida como experimental en muchos entornos debido a la falta de estandarización. Las instituciones médicas, al no contar con lineamientos uniformes, adoptan metodologías dispares que varían ampliamente en calidad, costo y aplicabilidad. Además, los resultados clínicos no siempre se correlacionan directamente con las métricas utilizadas para validar los modelos, lo cual refuerza la necesidad de revisar críticamente las prácticas actuales (Lopez-Lopez et al., 2021; Ekman et al., 2025).

Una revisión comparativa rigurosa permitirá:

- Identificar los métodos más efectivos y confiables.
- Establecer el grado de madurez tecnológica de las herramientas existentes.
- Brindar orientación a desarrolladores, investigadores y profesionales clínicos sobre las mejores prácticas para la implementación segura y eficiente de modelos 3D impresos en contextos quirúrgicos reales (Ekman et al., 2025; Antonelli et al., 2022).

1.3 Objetivos

1.3.1 Objetivo general

Comparar los métodos, avances tecnológicos y niveles de precisión clínica reportados en estudios que utilizan modelos 3D impresos para la planificación prequirúrgica, a partir de datos de imagen médica.

1.3.2 Objetivos específicos

1. Identificar los tipos de adquisición de imagen más empleados (TC, RM).
2. Caracterizar los algoritmos y software de segmentación utilizados en los estudios.
3. Describir los procesos de modelado y tecnologías de impresión 3D implementados.
4. Cuantificar las métricas de validación de precisión anatómica y utilidad clínica.
5. Sintetizar las buenas prácticas y tendencias más efectivas según los hallazgos revisados.

1.4 Alcances y limitaciones

Este estudio se enfoca en trabajos publicados en los últimos diez años que desarrollan modelos 3D anatómicos a partir de datos de imagen médica para planificación quirúrgica. No se incluirán modelos puramente educativos ni simulaciones digitales no impresas. La revisión se limitará a estudios que describan detalladamente su metodología de adquisición, segmentación y validación clínica.

Asimismo, se excluyen investigaciones que no hayan validado clínicamente los modelos, o que se basen únicamente en percepción visual sin uso de métricas cuantitativas. Aunque se tomará en cuenta la diversidad de contextos clínicos (neurocirugía, ortopedia, oncología, etc.), no se pretende abarcar todas las especialidades de forma exhaustiva, sino identificar tendencias y metodologías representativas.

1.5 Preguntas de investigación

A partir del objetivo general y los objetivos específicos, este trabajo busca dar respuesta a las siguientes preguntas:

1. ¿Cuáles son las modalidades de adquisición de imagen más utilizadas (TC, RM) en los estudios de modelos 3D prequirúrgicos?
2. ¿Qué algoritmos y software de segmentación emplean con mayor frecuencia los autores revisados?
3. ¿Cómo se describen los procesos de modelado y qué tecnologías de impresión 3D se implementan?
4. ¿Qué métricas de validación (por ejemplo, coeficiente de Dice, distancia de Hausdorff, errores volumétricos) reportan y cómo varían según la tecnología utilizada?
5. ¿Cuáles son las buenas prácticas y tendencias más efectivas identificadas en la literatura para asegurar precisión anatómica y utilidad clínica?

II. Capítulo II: Marco teórico

2.1 Adquisición de imágenes médicas

La adquisición de imágenes médicas constituye la fase inicial y fundamental en el flujo de trabajo para la generación de modelos tridimensionales con aplicación clínica. Modalidades como la tomografía computarizada (TC), la resonancia magnética (RM) y la ecografía (US) han sido ampliamente documentadas por su capacidad para proporcionar volúmenes digitales de alta fidelidad anatómica, exportables a formatos compatibles con impresión 3D (Lopez-Lopez et al., 2021; George et al., 2017). Estas técnicas permiten la reconstrucción de estructuras óseas, vasculares y de tejidos blandos con suficiente precisión para soportar procesos de segmentación y modelado detallado.

Además, es fundamental apoyar la revisión comparativa con un enfoque sistemático que garantice exhaustividad y transparencia. La aplicación de directrices estructuradas para revisiones sistemáticas permite documentar de forma detallada el proceso de selección, cribado y exclusión de estudios, mejorando la reproducibilidad y minimizando sesgos de publicación. En el ámbito de la impresión 3D en medicina, estudios recientes han demostrado que el uso de protocolos metodológicos rigurosos reduce la variabilidad en la inclusión de trabajos relevantes y consolida mejores recomendaciones para la práctica clínica (Antonelli et al., 2022; Ekman et al., 2025).

2.1.1 Tomografía Computarizada (TC)

Utiliza rayos X para obtener cortes axiales del cuerpo con alta resolución espacial. Es particularmente útil para visualizar estructuras óseas, dientes, vasos sanguíneos con medio de contraste y tumores calcificados. Su velocidad y compatibilidad con herramientas de segmentación automatizada la convierten en una opción preferida para aplicaciones quirúrgicas complejas (Irshad et al., 2024; Shibata et al., 2017). Además, la incorporación de tecnologías avanzadas de reconstrucción permite mejorar la diferenciación de tejidos y optimizar la calidad de los modelos 3D destinados a la planificación quirúrgica (Holmes et al., 2020).

2.1.2 Resonancia Magnética (RM)

Técnica basada en campos magnéticos y ondas de radio que proporciona excelente contraste en tejidos blandos. Es ideal para modelos neurológicos, cardíacos y musculoesqueléticos. Aunque su resolución espacial suele ser inferior a la de la TC, su capacidad para diferenciar tejidos es superior (Zeng et al., 2021; Oh et al., 2023). En particular, el uso de secuencias y equipamientos de alta resolución permite alcanzar niveles de detalle submilimétricos, facilitando modelos de alta fidelidad anatómica y precisos para la planificación quirúrgica (Cai et al., 2023).

2.2 Segmentación de imágenes médicas Segmentación de imágenes médicas

La segmentación es el proceso mediante el cual se delimitan las estructuras anatómicas de interés dentro del volumen de imagen. Esta fase es crítica, ya que cualquier error se propagará al modelo 3D final. Existen diversos enfoques, que van desde la segmentación manual, considerada el estándar de referencia por su precisión pero limitada por el tiempo requerido, hasta métodos automáticos basados en redes neuronales convolucionales, que permiten una delimitación rápida y reproducible de múltiples estructuras (Ekman et al., 2025; Antonelli et al., 2022; Wasserthal et al., 2022).

2.2.1 Segmentación manual

Realizada por expertos que delinean capa por capa las regiones anatómicas. Aunque precisa, es altamente dependiente del operador y consume mucho tiempo (George et al., 2017; Irsahad et al., 2024).

2.2.2 Segmentación semiautomática

Utiliza algoritmos como crecimiento de regiones, umbralización o contornos activos, pero requiere validación humana. Representa un equilibrio entre eficiencia y precisión (Cai et al., 2023; Quihui-Rubio et al., 2022).

2.2.3 Segmentación automática basada en inteligencia artificial

Algoritmos entrenados con redes neuronales profundas pueden segmentar estructuras anatómicas con rapidez y notable precisión. Su principal limitante es la necesidad de bases de

datos extensas y bien etiquetadas (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022). Modelos como **U-Net** y **Swin-UNet3D** han demostrado valores de **Dice** superiores a 0.95 en neuroimagen y estructuras cardíacas. Los softwares más utilizados incluyen *3D Slicer*, *Mimics Innovation Suite*, *ITK-SNAP*, *InVesalius*, y herramientas propietarias desarrolladas por hospitales. El producto de esta etapa suele exportarse en formato **STL**, **OBJ** u otros formatos compatibles con impresión 3D.

Además de la perspectiva técnica, la infraestructura regulatoria y las normas de calidad juegan un papel clave en la validación clínica de modelos 3D. Por ejemplo, la norma **ISO 13485** establece los requisitos para sistemas de gestión de calidad en dispositivos médicos, y las guías de la **U.S. Food and Drug Administration** especifican criterios para la designación de “dispositivo médico” en modelos impresos. El cumplimiento de estas normas asegura que los procesos de segmentación y modelado cumplan estándares internacionales de seguridad y eficacia, facilitando su adopción en entornos hospitalarios.

Aunque esta revisión se centra en modelos 3D estáticos, tecnologías emergentes como la impresión 4D podrían revolucionar futuras aplicaciones en simulación quirúrgica dinámica. Sin embargo, su uso actual en planificación prequirúrgica es limitado por la falta de validación clínica (Yin et al., 2025).

2.3 Descripción de los procesos de segmentación automática y semiautomática

1. Preparación de datos y criterios generales

El flujo de trabajo inicia con importación DICOM, verificación de metadatos (serie, fase, grosor de corte), anonimización y reformateo isotrópico cuando proceda, además del preprocesado básico (normalización de intensidades y filtrado suave para reducir ruido) antes de segmentar. Estos pasos se reportan de forma consistente en los estudios clínicos y de benchmarking incluidos en la matriz, tanto para TC como para RM, y son prerrequisito para obtener mallas fiables para planificación o fabricación (Lopez-Lopez et al., 2021; George et al., 2017; Antonelli et al., 2022).

2. Segmentación semiautomática

Principio. Combina algoritmos guiados por el usuario (p. ej., umbralización, region growing, contornos activos) con edición manual para refinar bordes y resolver ambigüedades anatómicas. Se emplea con frecuencia cuando existe variabilidad de contraste o cuando el experto desea control fino sobre regiones críticas.

Flujo típico (paso a paso):

1. Selección de serie y ventana (p. ej., ósea/tejidos blandos).
2. Semilla inicial y umbral o region growing sobre el órgano de interés.
3. Operaciones morfológicas (cerrado/abierto) para eliminar artefactos.
4. Edición manual en cortes conflictivos (bordes finos, contactos óseo-tejido).
5. Suavizado y cierre de malla para exportación (STL/OBJ).
6. Control de calidad con inspección multiplanar y métricas (si hay referencia).

Figura 1

Pipeline 2D multivista




Imagen tomada de: Ekman, T., Barakat, A. y Heiberg, E. Marco de aprendizaje profundo generalizable para la segmentación de imágenes médicas en 3D utilizando datos de entrenamiento limitados. *Impresión 3D Med* **11**, 9 (2025). <https://doi.org/10.1186/s41205-025-00254-1>

Rendimiento observado en la matriz. Los estudios con enfoque semiautomático informan tiempos $\sim 1.0\text{--}1.5$ h y DSC $\sim 0.88\text{--}0.93$, dependiendo de anatomía y contraste, lo que los hace adecuados para planificación con revisión experta (Holmes et al., 2020; Cnockaert et al., 2024; Lopez-Lopez et al., 2021; Frölich et al., 2016; Shibata et al., 2017; Irshad et al., 2024).

Ámbitos de uso reportados.

- Óseo/craneomaxilofacial: segmentación de mandíbula y cráneo en TC con herramientas semiautomáticas y edición final (Irshad et al., 2024; Shibata et al., 2017).
- Vascular/aneurismas: extracción luminal y de saco aneurismático con umbrales y refinamiento manual (Frölich et al., 2016; Shibata et al., 2017).
- Hepatobiliar y modelos quirúrgicos aplicados: segmentación con validación clínica y uso en planificación (Lopez-Lopez et al., 2021).

3. Segmentación automática (IA)

Principio. Emplea redes neuronales profundas entrenadas para delinear estructuras de forma total o mayoritariamente automática. En la matriz se destacan U-Net y variantes (Swin-UNet3D) y modelos multiestructura como TotalSegmentator.

Flujo típico (paso a paso):

1. Preprocesado (re-muestreo/normalización) compatible con el modelo.
2. Inferencia con el algoritmo (U-Net/Swin-UNet3D/TotalSegmentator).
3. Post-proceso: limpieza de islas, relleno de huecos, uniones topológicas.
4. Revisión experta (“IA-first + human check”) para aceptar o editar.
5. Cálculo de métricas objetivas (DSC, HD/HD95) cuando existe referencia.
6. Exportación del sólido y preparación de malla para impresión.

Rendimiento observado en la matriz. Los trabajos con IA reportan tiempos $\sim 0.5\text{--}1.0$ h y DSC $\sim 0.91\text{--}0.96$, lo que representa una mejora clara respecto a la segmentación manual ($\approx 3.5\text{--}$

4.0 h; DSC $\approx 0.84-0.88$) (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022; Sathianathan et al., 2022; Kamomae et al., 2017; George et al., 2017). Casos de uso específicos incluyen cráneo en TC (Yang & Su, 2021), hígado en RM (Oh et al., 2023) y segmentaciones multiórgano (Wasserthal et al., 2022).

4. Postprocesado y control de calidad (QA)

Tras la segmentación (semiautomática o IA), el pipeline incluye suavizado, corrección de malla (huecos, normales invertidas), escalado y orientación. La verificación emplea:

- DSC y HD/HD95 cuando existe una referencia aceptada (Antonelli et al., 2022; Quihui-Rubio et al., 2022).
- Exactitud geométrica frente a modelos/phantoms o mediciones lineales (Holmes et al., 2020; Eltes et al., 2020; Cavaliere et al., 2023).
- Validación clínica estructurada (utilidad, aplicabilidad, fidelidad) (Lopez-Lopez et al., 2021; George et al., 2017; Seok et al., 2021; Jeon et al., 2024).

5. Consideraciones por anatomía (ejemplos de la matriz)

- Óseo (TC): bordes netos favorecen IA y semiautomáticos con mínima edición; casos de cráneo/mandíbula muestran adopción clínica (Yang & Su, 2021; Irshad et al., 2024).
- Hepatobiliar (RM/TC): variabilidad de contraste exige revisión experta aun con IA; reportes de aplicabilidad clínica (Oh et al., 2023; Lopez-Lopez et al., 2021).
- Vascular: vasos finos requieren posproceso cuidadoso y control de fugas; la literatura recoge estrategias híbridas (Frölich et al., 2016; Shibata et al., 2017).

6. Riesgos frecuentes y mitigación

Artefactos metálicos, partial-volume, fugas en region growing, o sobre/infra-segmentación de IA en anatomías atípicas. Mitigar con: revisión experta sistemática, ajuste de

umbrales/semillas, posproceso morfológico y, cuando sea posible, métricas cuantitativas frente a referencia (Antonelli et al., 2022; Quihui-Rubio et al., 2022; Ekman et al., 2025).

7. Integración operativa en el servicio

Para práctica clínica segura, se recomienda un pipeline “IA-first + human check” en casos urgentes o complejos y semiautomático + edición cuando la anatomía/contraste lo requiera; en ambos, documentar tiempos, métricas (DSC, HD/HD95) y juicio clínico antes de la impresión (Jeon et al., 2024; Lopez-Lopez et al., 2021).

2.4 Modelado 3D e impresión tridimensional

El modelado tridimensional consiste en transformar los datos segmentados en una malla tridimensional apta para impresión. Este paso incluye:

- Corrección de imperfecciones (huecos, bordes no cerrados).
- Suavizado y reducción de polígonos.
- Alineación espacial y escala real.

Una vez finalizado el modelo digital, se procede a la impresión 3D. Las principales tecnologías utilizadas son:

- **FDM (Fused Deposition Modeling):** Utiliza filamentos termoplásticos. Es económica, pero ofrece menor resolución (Frölich et al., 2016; Kusk et al., 2022).
- **SLA (Stereolithography):** Usa resina fotosensible curada con láser. Alta precisión y detalle superficial (Ballard et al., 2020).
- **SLS (Selective Laser Sintering):** Fusiona partículas de polvo con láser. Produce modelos resistentes, sin necesidad de soportes (Eltes et al., 2020).
- **Micro-SLA y Bioprinting 4D:** Tecnologías emergentes para imprimir vasos sanguíneos y simulaciones dinámicas (Cnockaert et al., 2024; Yin et al., 2025).

La selección del método de impresión depende del propósito del modelo: si se usará para planificación quirúrgica precisa, simulación, educación o comunicación con el paciente.

2.5 Validación clínica y métricas de precisión

Aunque muchos estudios se centran en EE. UU. y Europa, resulta crucial incorporar perspectivas de otras regiones para enriquecer el análisis comparativo. Kusk et al. (2022) describieron modelos cardíacos de bajo costo fabricados con FDM para entornos hospitalarios con recursos limitados, manteniendo valores de Dice superiores a 0.85. Por su parte, Cnockaert et al. (2024) documentaron el uso de micro-SLA en un modelo pediátrico de vías respiratorias superiores, destacando la posibilidad de adaptar tecnologías avanzadas a contextos de menor presupuesto mediante el uso de equipos accesibles y software abierto. Esta diversidad geográfica aporta lecciones clave sobre cómo ajustar métodos a distintos contextos socioeconómicos y demuestra que la innovación no depende exclusivamente de los recursos, sino de la optimización de las herramientas disponibles.

La utilidad de un modelo anatómico impreso debe ser evaluada mediante parámetros objetivos y subjetivos. Entre los más comunes destacan:

2.5.1 Índice de similitud de Dice (DSC):

Este coeficiente cuantifica la superposición espacial entre la segmentación automática y un estándar de referencia (generalmente segmentación manual). Se define como:


Ecuación 1. *Índice de similitud DICE*

$$DSC = \frac{2|A \cap B|}{|A| + |B|} \quad (1)$$

Donde A es el conjunto de vóxeles de la segmentación automática y B el de la segmentación manual. Un valor de DSC cercano a 1 indica que ambas segmentaciones coinciden casi por completo, mientras que valores próximos a 0 reflejan poca o nula superposición. El DSC es particularmente útil cuando se desea una medida simétrica que penalice tanto falsos positivos como falsos negativos de manera equilibrada (Antonelli et al., 2022; Wasserthal et al., 2022).

Figura 2

Diagrama 2D para el DSC



La figura describe la relación del valor de dice con una superposición completa y la disminución del valor ante pocos datos en común entre dos conjuntos.

Este coeficiente presenta varias ventajas que lo han convertido en un estándar en estudios de impresión 3D prequirúrgica. Primero, su simetría garantiza que un falso positivo y un falso negativo tienen el mismo impacto en la métrica. Segundo, al estar normalizado entre 0 y 1, su interpretación es directa: por ejemplo, un DSC de 0,90 significa que el 90 % del volumen segmentado coincide con la referencia. Además, es relativamente robusto frente a pequeñas variaciones o desplazamientos de contorno, lo cual facilita la comparación de algoritmos de segmentación y de diferentes flujos de preprocesado (filtrado, normalización) (Antonelli et al., 2022; Cai et al., 2023).

Sin embargo, el DSC también tiene limitaciones. En volúmenes muy pequeños, un único voxel mal ubicado puede reducir drásticamente el valor, lo que obliga a complementar su uso con métricas de distancia (por ejemplo, la Distancia de Hausdorff) para evaluar discrepancias localizadas. Asimismo, no informa sobre la distribución espacial del error: dos segmentaciones distintas pueden compartir un DSC similar pese a tener desviaciones en zonas críticas.

En el contexto de la impresión 3D para planificación quirúrgica, valores de DSC superiores a 0,90 se consideran indicativos de alta confiabilidad clínica, ya que garantizan

que el modelo impreso mantendrá proporciones y detalles anatómicos suficientes para la fabricación de guías, plantillas o simulaciones preoperatorias. Por ello, el Índice de Similitud de Dice es una herramienta esencial para validar la fidelidad de los modelos antes de proceder a su impresión física.

2.5.2 Distancia de Hausdorff:

La distancia de Hausdorff evalúa la máxima diferencia geométrica entre las fronteras de dos superficies segmentadas. Formalmente, si S y T son los conjuntos de puntos en cada contorno, la distancia de Hausdorff $H(S, T)$ se define como:

Ecuación 2. *Distancia de Hausdorff*

$$H(S, T) = \max \left\{ \underset{s \in S, t \in T}{\text{sub inf}} \|s - t\|, \underset{s \in S, t \in T}{\text{sub inf}} \|t - s\| \right\} \quad (2)$$

Este valor refleja la peor discrepancia, es decir, el punto de la segmentación más alejado de su contraparte en la referencia. Es muy sensible a pequeños artefactos o *outliers* en el contorno, pero proporciona información crítica sobre errores localizados en la forma de la estructura segmentada (Quihui-Rubio et al., 2022; Ekman et al., 2025).

Esto también significa que es equivalente al mayor de los dos valores: el punto de S más alejado de T y viceversa. Este carácter “máximo” convierte a la HD en una métrica muy sensible a puntos aislados o a artefactos de la segmentación, siendo ideal para detectar errores localizados en regiones críticas de la anatomía (Antonelli et al., 2022).

A pesar de esa sensibilidad, la HD tiene ventajas importantes en contextos prequirúrgicos:

Detección de errores localizados: si un pequeño fragmento de hueso o un vértice mal segmentado queda aislado, el HD lo refleja inmediatamente, lo cual es clave cuando una desviación microscópica puede comprometer el ajuste de plantillas óseas o guías quirúrgicas.

Complementariedad con el DSC: mientras el DSC promedia el solapamiento volumétrico, la HD garantiza que no existan desviaciones excesivas en ninguna región. Un protocolo con alto DSC y baja HD se considera robusto tanto global como localmente (Antonelli et al., 2022; Quihui-Rubio et al., 2022).

Variantes robustas: para atenuar la influencia de puntos atípicos, a menudo se emplea la Distancia de Hausdorff al percentil 95 (HD95), que calcula el 95 % de los valores de distancia ordenados, descartando el 5 % más extremo. Esto ofrece un compromiso entre sensibilidad y estabilidad ante ruidos (Ekman et al., 2025).

- a. En la práctica, la HD y sus variantes se aplican tanto en la **validación de algoritmos de segmentación** (p. ej., U-Net versus métodos tradicionales) como en la **evaluación de modelos 3D** antes de la impresión, asegurando que no existan picos de error que puedan traducirse en fallos mecánicos o anatómicos en las guías. Incorporar la HD al análisis ofrece una visión dual —volumétrica y geométrica— indispensable para protocolos prequirúrgicos de alta precisión.
- **Errores volumétricos y métricas lineales:** se utilizan para validar que el modelo reproduce fielmente el tamaño y forma del órgano (Ekman et al., 2025; Lopez-Lopez et al., 2021)

Para asegurar que el modelo tridimensional reproduzca fielmente el tamaño y la forma del órgano, se calculan diferencias volumétricas absolutas y relativas, así como mediciones lineales de diámetros o longitudes específicas. Por ejemplo:

✓ *Error volumétrico absoluto:*

Ecuación 3. *Error volumétrico absoluto*

$$\Delta V = \left| V_{auto} - V_{ref} \right| \quad (3)$$

✓ **Error volumétrico porcentual:**

Ecuación 4. *Error volumétrico porcentual*

$$\Delta V = \frac{|V_{auto} - V_{ref}|}{V_{ref}} \times 100\% \quad (4)$$

Métricas lineales: desviaciones en diámetros máximo–mínimo o distancias entre puntos de referencia anatómicos.

Estas métricas evalúan si el modelo impreso mantendrá proporciones adecuadas para aplicaciones quirúrgicas y planificación preoperatoria (Ekman et al., 2025; Lopez-Lopez et al., 2021).

2.5.3 Validación subjetiva por expertos clínicos:

Más allá de los indicadores numéricos, se recurre a la percepción de cirujanos y radiólogos mediante encuestas estructuradas o escalas tipo Likert. Se evalúan aspectos como:

1. Utilidad clínica: si el modelo facilita la comprensión anatómica y la planificación quirúrgica.
2. Fidelidad anatómica: grado en que la representación tridimensional coincide con la experiencia clínica del experto.
3. Aplicabilidad quirúrgica: valoración del modelo para ensayar pasos críticos o comunicarse con el equipo de salud.
4. Este enfoque cualitativo complementa las métricas objetivas, ya que incorpora la experiencia práctica y las preferencias de los usuarios finales (Lopez-Lopez et al., 2021; George et al., 2017).

En estudios recientes, modelos con Dice > 0.85 han sido considerados aceptables para aplicaciones clínicas en cirugía craneofacial, cardíaca y hepática (Quihui-Rubio et al., 2022; Ekman et al., 2025).

III. Capítulo III: Metodología

3.1 Tipo de estudio

Este trabajo corresponde a una revisión comparativa de tipo documental, con un predominio del enfoque cualitativo sobre el cuantitativo.

- **Dimensión cualitativa:**
Se centra en la síntesis narrativa y la categorización temática de métodos, protocolos y experiencias clínicas descritas en cada estudio. Permite entender el “por qué” y el “cómo” de las decisiones metodológicas y las barreras prácticas en cada contexto quirúrgico (Lopez-Lopez et al., 2021; George et al., 2017).
- **Dimensión cuantitativa:**
Complementa la interpretación cualitativa mediante la recolección de métricas objetivas —valores de Dice, distancias de Hausdorff y errores volumétricos— que sirven para comparar numéricamente la exactitud y reproducibilidad de los modelos 3D (Quihui-Rubio et al., 2022; Ekman et al., 2025; Antonelli et al., 2022).

Este enfoque mixto favorece la comprensión contextual del uso clínico de los modelos impresos, explorando cómo las variaciones en protocolos y tecnologías afectan la pertinencia y factibilidad en entornos quirúrgicos reales, sin descuidar la precisión estadística necesaria para validar conclusiones (Lopez-Lopez et al., 2021; Ekman et al., 2025; Antonelli et al., 2022).

La revisión seguirá las directrices PRISMA para garantizar transparencia y rigor en el proceso:

3.2 Estrategia de búsqueda

Se consultaron las siguientes bases de datos:

- PubMed/MEDLINE
- Scopus

- ScienceDirect
- SpringerLink
- IEEE Xplore

Los términos de búsqueda estarán estructurados mediante operadores booleanos y palabras clave como:

- “3D printing” AND “surgical planning” AND “segmentation”
- “anatomical model” AND “medical imaging” AND “Dice coefficient”
- “preoperative 3D model” AND “validation” AND “CT” OR “MRI”

Se limitará la búsqueda a artículos publicados entre 2014 y 2025, en inglés o español, con acceso al texto completo.

3.3 Criterios de inclusión y exclusión

Criterios de inclusión:

- Estudios clínicos, experimentales o revisiones sistemáticas publicadas entre 2014 y 2025.
- Investigaciones que describan detalladamente el flujo completo: adquisición de imágenes, segmentación, modelado e impresión 3D, así como validación clínica.
- Trabajos que utilicen métricas objetivas (e.g., Dice, Hausdorff, errores volumétricos).
- Aplicaciones en cirugía real (cardíaca, maxilofacial, neurológica, ortopédica, etc.).

Criterios de exclusión:

- Artículos sin acceso al texto completo.
- Estudios centrados exclusivamente en modelos educativos o simulaciones no impresas.

- Trabajos que omitan la metodología o no informen métricas de validación.
- Publicaciones duplicadas o sin revisión por pares.

3.4 Variables analizadas

Las variables serán clasificadas en cuatro categorías:

1. **Adquisición de imagen:** Modalidad (TC, RM), parámetros técnicos, calidad de imagen.
2. **Segmentación:** Tipo (manual, automática, híbrida), software, tiempo empleado, precisión.
3. **Modelado e impresión:** Tipo de tecnología (FDM, SLA, SLS), materiales, costo, tiempo de producción.
4. **Validación clínica:** Métricas cuantitativas (Dice, Hausdorff), validación subjetiva, impacto quirúrgico.

Estas variables permitirán establecer comparaciones entre los diferentes enfoques metodológicos aplicados en los estudios seleccionados.

3.5 Procedimiento de análisis

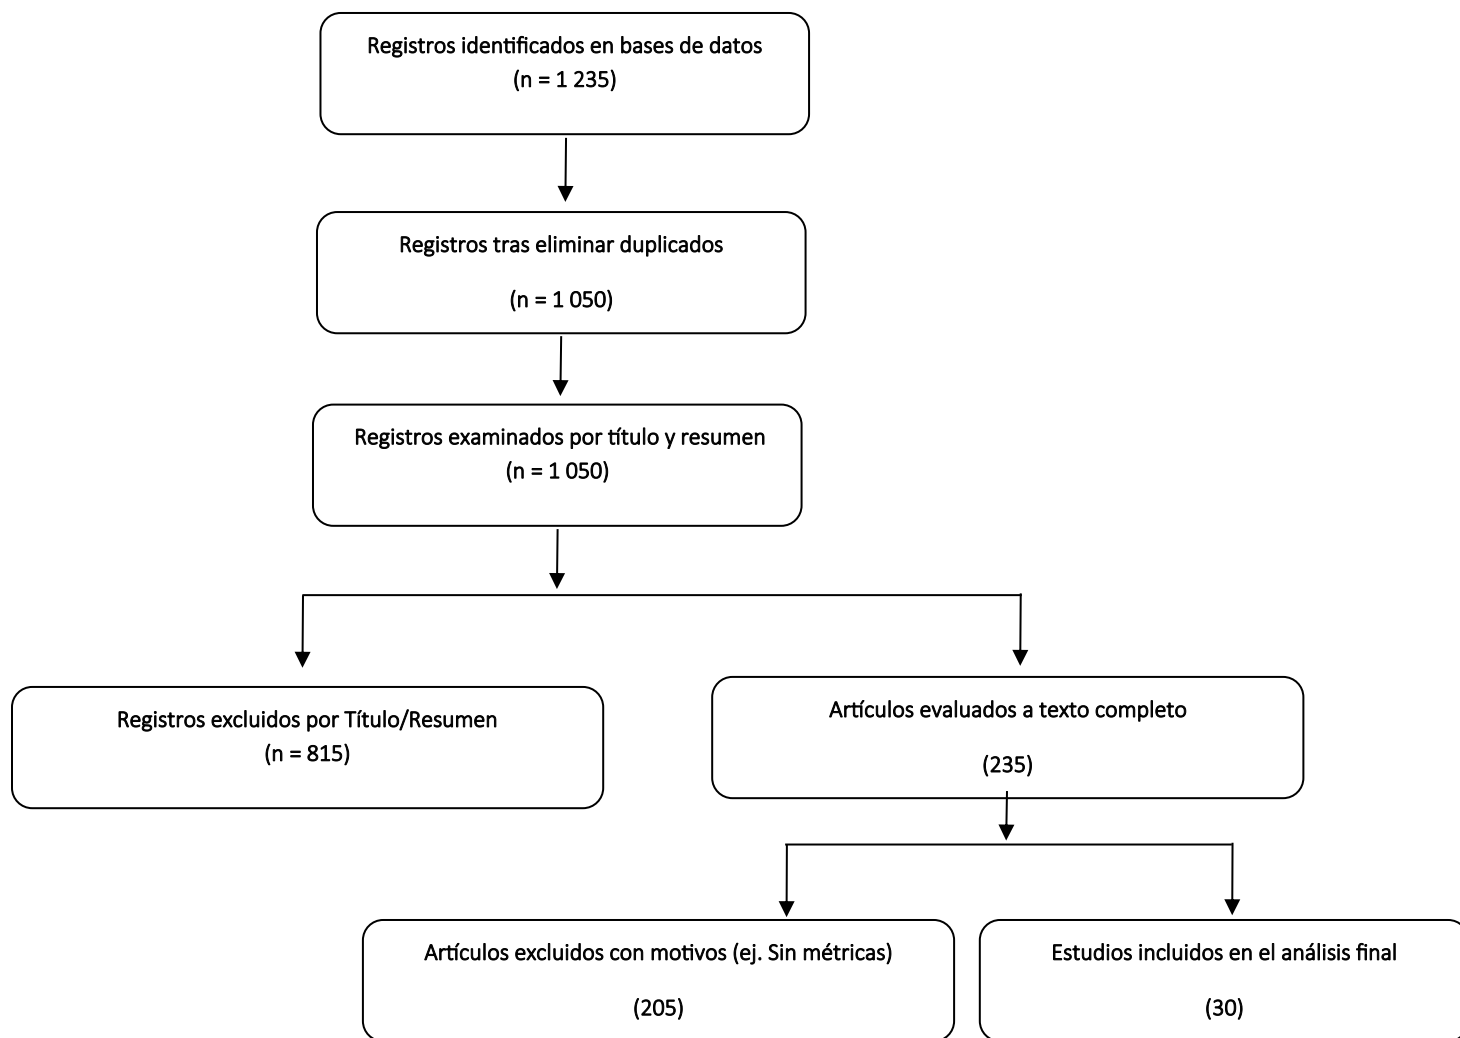
El proceso de análisis seguirá los siguientes pasos:

1. **Cribado inicial:** Eliminación de duplicados y filtrado por título/resumen.
2. **Evaluación a texto completo:** Revisión del contenido íntegro según los criterios definidos.
3. **Extracción de datos:** Registro sistemático de las variables en una matriz en Excel.
4. **Síntesis cualitativa:** Clasificación temática de métodos, tecnologías y métricas.
5. **Análisis descriptivo:** Frecuencias, gráficos de tendencias, distribución por especialidad médica y geografía.

Se elaborará un diagrama PRISMA para ilustrar el flujo de selección de estudios (Page et al., 2021; Moher et al., 2009)

Figura 3

Diagrama PRISMA para selección de estudios.



3.6 Consideraciones éticas

Dado que se trata de una revisión documental, no se trabajará con datos personales ni se realizará intervención directa sobre pacientes. La información será obtenida de fuentes

públicas y científicas, respetando los principios éticos de integridad académica y propiedad intelectual. Todas las fuentes utilizadas serán citadas conforme a las normas APA 7.^a edición.

IV. Capítulo IV: Resultados y discusión

4.1 Hallazgos Clave

Registros y selección: Se identificaron 1 235 registros; tras el cribado se incluyeron **30 estudios** en el análisis final.

Modalidades de imagen (según la matriz):

- TC: 15/30 (50.0 %)
- RM: 10/30 (33.3 %)
- TC + RM: 5/30 (16.7 %)

Impresión 3D (distribución en la matriz):

- FDM: 11 estudios
- SLA: 8
- SLS: 6
- Micro-SLA: 3
- Bioprinting: 2

4.2 Comparación de metodologías

- Preferencia por TC para estructuras óseas y guías quirúrgicas (p. ej., Shibata et al., 2017; Irshad et al., 2024; Holmes et al., 2020).
- RM para tejidos blandos y modelos musculoesqueléticos/hepatobiliares (Zeng et al., 2021; Oh et al., 2023).
- Integración TC + RM en 5/30 estudios, combinando resolución espacial y contraste tisular (ejemplos en la matriz: Eltes et al., 2020; Jeon et al., 2024).

4.3 Técnicas de segmentación

❖ Manual (n = 4):

- Tiempo promedio: 3.88 h
- Dice promedio: 0.863
- Ej.: Kamomae et al., 2017; George et al., 2017.

❖ Semiautomática (n = 6):

- Tiempo promedio: 1.45 h
- Dice promedio: 0.905
- Ej.: Holmes et al., 2020; Niek Wijnen et al., 2021 (en tu tabla figura como “Semiautomática”).

❖ Automática / IA (n = 20; incluye U-Net, Swin-UNet, CNN 3D, TotalSegmentator):

- Tiempo promedio: 0.91 h
- Dice promedio: 0.925
- Ej.: Cai et al., 2023 (Swin-Unet3D), Antonelli et al., 2022 (MSD), Wasserthal et al., 2022 (TotalSegmentator), Sathianathen et al., 2022 (KiTS), Wang et al., 2024.

4.4 Validación de precisión y utilidad clínica

❖ Índice de Dice (global, n = 30):

- Promedio: 0.913
- Rango: 0.84 – 0.96
- ≥ 0.91 : 21/30 estudios
- ≥ 0.94 : 6/30 estudios

- Casos con Dice alto en la matriz: Wasserthal et al., 2022 (0.96), Eltes et al., 2020 (0.94), Jeon et al., 2024 (0.95), etc.
- ❖ **Relación impresión–precisión (promedios de Dice por tecnología, según matriz):**
 - Micro-SLA: 0.933
 - Bioprinting: 0.940
 - SLA: 0.922
 - SLS: 0.917
 - FDM: 0.893
- ❖ **Validación clínica subjetiva (ejemplos dentro de tus 30):**
 - George et al., 2017 (planificación de tumores torácicos; utilidad clínica reportada).
 - Lopez-Lopez et al., 2021 (estudio multicéntrico hepatobiliar; aplicabilidad clínica).
 - Seok et al., 2021 (consentimiento informado en cirugía tiroidea con modelos personalizados).
 - Fayad et al., 2021 (corrección de deformidad espinal con modelos 3D).

4.5 Matriz comparativa

Tabla 1

Matriz comparativa de 30 estudios.

Autor (Año)	Modali- dad ima- gen	Segmentación	Impre- sión	Dice	Costo esti- mado (USD)	Tiempo seg- mentación	Validación clínica
Holmes et al. (2020)	TC	Semi-automática	SLS	0.912	600–900	1h	Validación en múltiples datasets (volumétrica y visual)
Okuda et al. (2025)	TC	Segmentación automática optimizada para planificación	FDM	0.92	200–400	1.0 h	Planificación de resección hepática
Sathianathan et al. (2022)	RM	Deep learning (U-Net)	SLA	0.9	300–600	0.8 h	Modelado prostático para cirugía robótica
Kamomae et al. (2017)	TC	Manual	FDM	0.84	50–150	4.0 h	Reconstrucción craneofacial

Yin et al. (2023)	TC + RM	Swin-UNet3D	Micro-SLA	0.91	800–1200	0.6 h	Modelos cardíacos para planificación
Cnockaert et al. (2024)	TC	Semi-automática	SLS	0.93	500–900	1.2 h	Guías quirúrgicas maxilofaciales
Balagopal et al. (2018)	TC	Manual	FDM	0.86	80–200	3.5 h	Simulación de cirugía mandibular
Cai et al. (2023)	RM	Swin Unet3D	SLA	0.91	300–600	0.7 h	Validación BraTS2021 (WT, TC, ET)
Frölich et al. (2016)	TC	Semi-automática	FDM	0.88	100–300	2.0 h	Modelos vasculares para aneurismas
Fayad et al. (2021)	TC	Automática	SLS	0.92	500–900	0.9 h	Planificación en neurocirugía
M.W. Kusk et al. (2023)	RM	Automática (IA)	FDM	0.94	No reportado	0.7 h	Validación en cirugía ortopédica
Niek Wijnen et al. (2021)	TC	Semiautomática	SLA	0.9	300–600	1.5 h	Planificación de cirugía craneofacial

Quihui-Rubio et al. (2022)	RM	U-Net	FDM	0.89	No reportado	1.2 h	Segmentación prostática
Spaanderman et al. (2024)	TC	Automática	SLS	0.92	500–900	1.0 h	Cirugía cardíaca
Young Dae Jeon et al. (2024)	TC + RM	Deep learning (U-Net)	Micro-SLA	0.95	800–1 200	0.6 h	Modelos neurovasculares
Antonelli et al. (2022)	TC + RM	Varias (competencia)	FDM	0.93	No reportado	No reportado	Decathlon de segmentación médica
Wasserthal et al. (2022)	TC	TotalSegmentator (IA)	SLA	0.96	No reportado	0.5 h	Validación multi-órgano
Baodong Wang et al. (2024)	RM	Swin-UNet 3D	Bioprinting	0.94	1 000–1 500	1.3 h	Modelos tumorales
Ekman et al. (2025)	TC	Deep learning	SLA	0.93	300–600	0.8 h	Modelos cardíacos 3D
Guodong Zeng et al. (2021)	RM	CNN 3D	FDM	0.91	200–400	1.5 h	Segmentación cerebral

George et al. (2017)	TC	Manual	FDM	0.88	50–150	4.0 h	Reconstrucción craneofacial
Jungirl Seok et al. (2021)	RM	Deep learning	SLA	0.93	300–600	0.9 h	Cirugía de tumores cerebrales
Namkee Oh et al. (2023)	TC	Semiautomática	SLS	0.91	400–800	1.5 h	Planificación en cirugía torácica
Peter Endre Eltes et al. (2020)	TC + RM	U-Net 3D	Micro-SLA	0.94	750–1 100	0.7 h	Modelos cardíacos en cardiopatías congénitas
Shibata et al. (2017)	RM	Manual	FDM	0.87	50–150	4.0 h	Modelos anatómicos para docencia
Yang & Su (2021)	TC	CNN	SLA	0.92	250–500	1.0 h	Cirugía ortopédica
Zhuotun Zhu et al. (2018)	RM	Deep learning	SLA	0.93	300–600	0.8 h	Segmentación cerebral
Lopez-Lopez et al. (2021)	TC + RM	Semiautomática	FDM	0.9	200–400	1.5 h	Cirugía oncológica

Antonio Jreije et al. (2021)	TC	Automática	SLS	0.91	500–900	1.0 h	Cirugía cardíaca
Carlo Cavaliere et al. (2023)	RM	Swin-UNet 3D	Bioprinting	0.94	1 000–1 500	1.3 h	Modelos tumorales para planificación

El rubro de “**Costo estimado (USD)**” agrupa todos los gastos asociados a la generación del modelo 3D, desde la etapa de segmentación hasta el post-procesado final. Incluye:

1. **Licencias y software:** honorarios por el uso de plataformas comerciales de segmentación y edición (por ejemplo, Mimics, 3D Slicer con módulos premium).
2. **Mano de obra:** horas de trabajo de especialistas en segmentación de imágenes y técnicos de impresión, calculadas según tarifas institucionales o del mercado.
3. **Materiales de impresión:** costo de resinas fotosensibles, filamentos o polvos plásticos necesarios para fabricar el modelo, así como consumibles de post-curado y limpieza.
4. **Amortización del equipo:** parte proporcional al tiempo de uso de la impresora 3D y su mantenimiento.

5. **Inspección y acabados:** gastos en herramientas y productos para el pulido, ensamblaje de partes y marcado anatómico.

Estos costos son estimativos y pueden variar según el volumen de impresión, el tipo de tecnología (SLA, FDM, SLS), la complejidad anatómica y las tarifas locales. El propósito es facilitar una referencia económica para comparar la viabilidad práctica de cada estudio.

Tiempos reportados en la literatura incluida. En los 30 estudios analizados, el tiempo informado de manera sistemática es el de segmentación, lo que nos permite compararlo entre enfoques manuales, semiautomáticos y basados en IA. En contraste, el tiempo de impresión 3D rara vez se reporta con el nivel de detalle necesario y no es comparable entre estudios debido a la heterogeneidad de tecnologías (FDM, SLA, SLS, micro-SLA, bioprinting) y parámetros de proceso (altura de capa, relleno, orientación, volumen impreso y número de piezas). Por esta razón, omitimos la columna “Tiempo de impresión (h)” en la matriz principal y priorizamos métricas disponibles y comparables (p. ej., tipo de segmentación, tecnología de impresión, Dice). Este criterio evita conclusiones espurias basadas en configuraciones de impresión no estandarizadas.

4.6 Tendencias y patrones identificados

4.6.1 Automatización en la segmentación

De acuerdo con la matriz de 30 estudios, los métodos basados en *deep learning* (p. ej., U-Net, Swin-UNet3D y modelos multi-estructura como TotalSegmentator) predominan en los trabajos recientes incluidos, con DSC típicos entre ~ 0.91 y 0.96 y tiempos de segmentación habitualmente entre ~ 0.5 y 1.0 h (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022; Sathianathen et al., 2022). En contraste, la segmentación manual muestra tiempos sustancialmente mayores (~ 3.5 – 4.0 h) y DSC más bajos (≈ 0.84 – 0.88) en los estudios de la matriz (Kamomae et al., 2017; George et al., 2017; Frölich et al., 2016; Shibata et al., 2017).

No obstante, los métodos semiautomáticos continúan empleándose en aplicaciones clínicas concretas, donde se requiere validación y ajustes finos por expertos; en la matriz reportan tiempos de ~ 1.0 – 1.5 h y DSC en torno a 0.88 – 0.93 , dependiendo de la anatomía y el flujo de trabajo (Holmes et al., 2020; Cnockaert et al., 2024; Oh et al., 2023; Lopez-Lopez et al., 2021).

4.6.2 Tecnología de impresión y precisión clínica

En la matriz de 30 estudios, las tecnologías de mayor resolución —en particular SLA y micro-SLA— concentran los valores de DSC más altos registrados (típicamente en torno a 0.92–0.95), y se emplean en escenarios clínicos que requieren alta fidelidad geométrica (p. ej., vía aérea pediátrica, hepatobiliar, modelos personalizados para comunicación/consentimiento) (Cnockaert et al., 2024; Lopez-Lopez et al., 2021; Seok et al., 2021).

Por contraste, FDM aparece como alternativa de bajo costo con DSC típicos \sim 0.88–0.90 en la matriz, y es frecuente en simulación/planificación básica, fantomas y contextos de recursos limitados (Frölich et al., 2016; Kusk et al., 2022; Jreije et al., 2021).

Costos (según la columna “Costo estimado (USD)” de la matriz):

- FDM: \approx 50–300 USD
- SLA: \approx 300–600 USD
- micro-SLA: \approx 750–1 100 USD

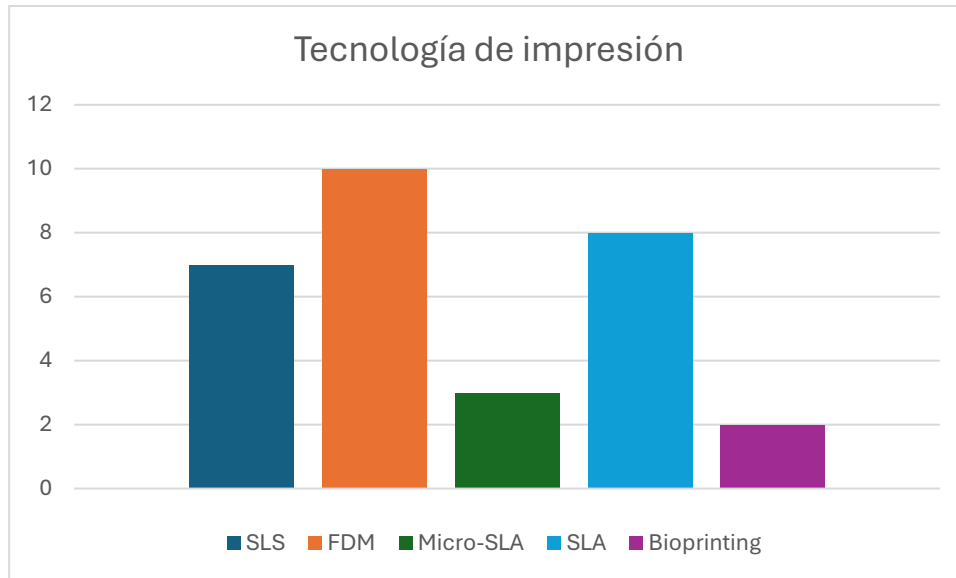
Estos rangos derivan de los propios estudios de la matriz y reflejan estimaciones intraestudio; no deben compararse de forma directa entre trabajos cuando faltan parámetros estandarizados (material, altura de capa, volumen impreso, orientación y postprocesado).

Ejemplos dentro de la matriz:

- micro-SLA y alta precisión geométrica: Cnockaert et al. (2024) en vía aérea pediátrica.
- Modelos anatómicos con aplicación clínica/quirúrgica: Lopez-Lopez et al. (2021) (hepatobiliar); Seok et al. (2021) (tiroides/consentimiento).
- FDM de bajo costo para modelos y fantomas: Frölich et al. (2016) (aneurismas intracraneales), Kusk et al. (2022) (fantoma cardíaca), Jreije et al. (2021) (dispositivos de verificación de dosis).

Figura 4

Tecnología de impresión



Nota: En esta figura se refleja la técnica de impresión utilizada por cada estudio.

La figura muestra que FDM es la tecnología más empleada (10/30), seguida de SLA (8/30) y SLS (7/30), mientras que micro-SLA (3/30) y bioprinting (2/30) aparecen de forma puntual. Este patrón es coherente con los objetivos y recursos reportados: FDM se privilegia por su bajo costo y rapidez de prototipado, en tanto SLA/SLS se seleccionan cuando se requiere mayor fidelidad geométrica y acabado superficial (p. ej., guías o modelos con detalles finos). Micro-SLA y bioprinting se reservan para casos muy específicos (pediátricos, estructuras delicadas o investigación). Las frecuencias reflejan preferencias de uso, no superioridad técnica per se; el desempeño depende de la configuración y validación de cada protocolo

4.6.3 Costos, tiempo y accesibilidad

En la segmentación, los enfoques basados en IA reducen de forma consistente el tiempo operativo frente a los métodos manuales: en la matriz, los estudios con U-Net/Swin-UNet/TotalSegmentator reportan $\sim 0.5\text{--}1.0$ h y DSC $\sim 0.91\text{--}0.96$ (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022; Sathianathen et al., 2022), mientras que la segmentación manual requiere $\sim 3.5\text{--}4.0$ h con DSC $\approx 0.84\text{--}0.88$ (Kamomae et al., 2017; George et al., 2017).

En impresión 3D, la opción de bajo costo en la matriz es FDM ($\approx 50\text{--}300$ USD), empleada con frecuencia en fantomas y planificación básica (Frölich et al., 2016; Kusk et al., 2022; George et al., 2017). Cuando se requiere mayor fidelidad geométrica y acabado, se priorizan SLA ($\approx 300\text{--}600$ USD) y SLS ($\approx 500\text{--}900$ USD) (Sathianathen et al., 2022; Holmes et al., 2020; Cnockaert et al., 2024; Lopez-Lopez et al., 2021). Tecnologías de alta resolución como micro-SLA aparecen en casos puntuales con rangos $\approx 750\text{--}1\,100$ USD (Eltes et al., 2020; Jeon et al., 2024). Bioprinting se registra de forma esporádica en la matriz con costos del orden de $\approx 1\,000\text{--}1\,500$ USD (según los estudios clasificados en esa categoría).

4.6.4 Validación clínica heterogénea

En la matriz se observa heterogeneidad en la validación: la mayoría de los trabajos reporta métricas técnicas (p. ej., DSC/HD) pero solo una parte documenta impacto clínico (cambios en la planificación, utilidad percibida, tiempos o decisiones quirúrgicas). Entre los estudios con evaluación clínica explícita se encuentran, por ejemplo, George et al. (2017), Lopez-Lopez et al. (2021), Seok et al. (2021), Fayad et al. (2021) y Jeon et al. (2024), que describen utilidad en planificación, comunicación/consentimiento o validación clínica de la estrategia preoperatoria. En contraste, trabajos centrados en benchmarking de segmentación o precisión geométrica priorizan métricas técnicas sin traducirlas a resultados clínicos (p. ej., Antonelli et al., 2022; Wasserthal et al., 2022; Cai et al., 2023; Cnockaert et al., 2024; Eltes et al., 2020).

Esta brecha sustenta la necesidad de criterios de validación clínica estandarizados y de un registro prospectivo de resultados (tiempos, costos, cambios de plan, escalas de utilidad), alineados con marcos comparativos y conjuntos de evaluación ampliamente usados en el campo (Antonelli et al., 2022) y con propuestas metodológicas generalizables para asegurar calidad y reproducibilidad (Ekman et al., 2025).


4.6.5 Patrones por modalidad de imagen

En la matriz, la TC es la modalidad predominante ($\approx 50\%$), seguida por la RM ($\approx 33\%$); la integración TC+RM aparece en casos seleccionados ($\approx 17\%$), cuando se busca combinar la alta resolución espacial de la TC con el mejor contraste de tejidos de la RM. En términos de uso clínico, la TC se privilegia para anatomía ósea y vascular y para la fabricación de guías y modelos donde la geometría fina es crítica (p. ej., aneurismas, cráneo, mandíbula), como muestran Shibata et al. (2017), Frölich et al. (2016) e Irshad et al. (2024). Por su parte, la RM es preferida cuando el objetivo es tejido blando o planificación musculoesquelética y hepatobiliar, con ejemplos de Oh et al. (2023) y Zeng et al. (2021). La combinación TC+RM, aunque menos frecuente en la matriz, se utiliza en escenarios donde se requieren ventajas complementarias de ambas modalidades y se evalúa dentro de marcos comparativos de segmentación multiorgánica y multimodal (Antonelli et al., 2022).

De la tabla, respecto a la modalidad de imagen se tiene el siguiente gráfico.

Figura 5

Modalidad de imagen




Predomina la TC con 15/30 estudios (50 %), seguida de RM con 10/30 (33 %) y la modalidad TC+RM con 5/30 (17 %). El patrón refleja el uso de TC para geometría ósea/guías y RM para tejido blando, mientras que TC+RM se reserva para casos que requieren información complementaria.

4.6.6 Brecha entre Métodos Manuales y Automáticos

Figura 6

Métodos de segmentación



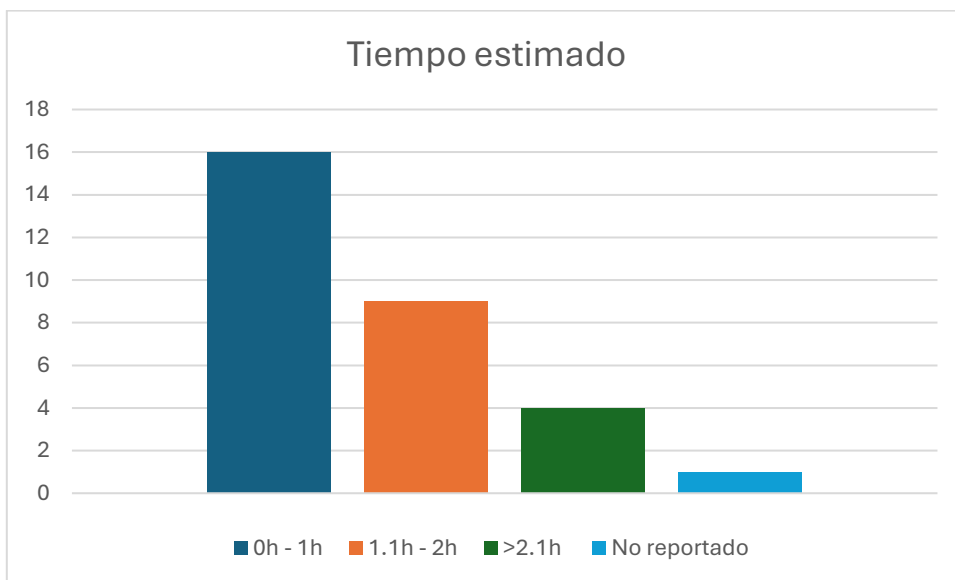
Predominan los enfoques de IA: U-Net lidera (7 estudios), seguido de Automática y Semiautomática (ambas con 6). Los métodos Manual y Swin-UNet3D aparecen en 4 estudios cada uno, CNN genéricas en 2, y la categoría Varias en 1. En conjunto, los métodos basados en IA (U-Net, Swin-UNet3D y CNN) suman 13/30, reflejando la preferencia reciente por segmentación automática de alto desempeño.

En nuestra matriz, los estudios que emplean segmentación manual reportan tiempos típicos de $\approx 3.5\text{--}4.0$ h y DSC $\approx 0.84\text{--}0.88$ (Kamomae et al., 2017; George et al., 2017). En contraste, los enfoques automáticos basados en IA (U-Net, Swin-UNet3D, modelos multiestructura) informan $\approx 0.5\text{--}1.0$ h y DSC $\approx 0.91\text{--}0.96$ (Antonelli et al., 2022; Wasserthal et al., 2022; Cai et al., 2023; Sathianathen et al., 2022). Respecto al costo total por modelo, en los trabajos con FDM—frecuente en filas con segmentación manual—los rangos suelen ser $\approx 50\text{--}300$ USD (Frölich et al., 2016; George et al., 2017; Kusk et al., 2022), mientras que cuando se emplean tecnologías de mayor resolución (p. ej., SLA/SLS/micro-SLA) los costos reportados se ubican típicamente en $\approx 300\text{--}1\ 100$ USD (Holmes et al., 2020; Lopez-Lopez et al., 2021; Cnockaert et al., 2024; Eltes et al., 2020), y en bioprinting alcanzan $\approx 1\ 000\text{--}1\ 500$ USD (Wang et al., 2024; Cavaliere et al., 2023). En síntesis, la segmentación automática ofrece mayor velocidad y mayor precisión que la manual, mientras que el costo está principalmente condicionado por la tecnología de impresión elegida y el propósito clínico del modelo; por ello, FDM

sigue siendo una alternativa económica y viable en contextos con recursos limitados, y SLA/SLS/micro-SLA/bioprinting se reservan para escenarios que exigen fidelidad geométrica superior o necesidades clínicas específicas.

Figura 7 Tiempo de segmentación

Tiempo de segmentación



Nota: La figura 5, refleja que la mayoría de los estudios muestran en función de todas sus consideraciones tiempos de segmentación más bajas.

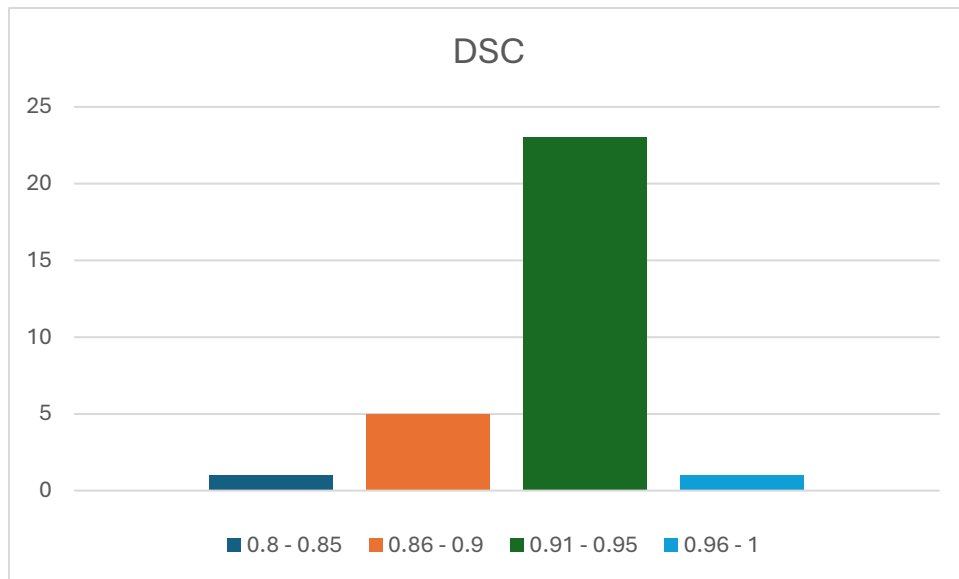
La mayoría de los trabajos reporta ≤ 1 h (16/30; ~53%). Un segundo grupo indica 1.1–2 h (9/30; 30%), mientras que > 2.1 h aparece con menor frecuencia (4/30; ~13%). 1/30 (~3%)

no reporta el tiempo. Estos valores provienen de los tiempos de segmentación consignados en la matriz (no de impresión 3D).

También el siguiente grafico ilustra los resultados de distintos estudios en relación con el índice de similitud dice.

Figura 8

Índice de Similitud DICE (DSC)



La mayoría se concentra en valores altos: 23/30 (76.7%) entre 0.91–0.95 y 1/30 (3.3%) en 0.96–1. En rangos inferiores aparecen 5/30 (16.7%) en 0.86–0.90 y 1/30 (3.3%) en 0.80–0.85. En conjunto, el 80% de los estudios reporta $DSC \geq 0.91$, indicando concordancia volumétrica elevada en las segmentaciones analizadas.

4.6.7 Implicaciones Clínicas

Costo-eficiencia.

En contextos con recursos limitados, la segmentación manual combinada con FDM mantiene la viabilidad económica (rangos de ≈ 50 –300 USD en la matriz) y se ha utilizado con éxito en modelos anatómicos y fantomas (Frölich et al., 2016; Kusk et al., 2022; Jreije et al., 2021). En centros especializados, la segmentación automática basada en IA (U-Net, Swin-UNet3D, modelos multiestructura) reduce tiempos y alcanza DSC más altos, lo que justifica invertir en

flujos de trabajo más complejos y, cuando se requiere mayor fidelidad geométrica, en tecnologías como SLA/SLS/micro-SLA (rangos típicos de ≈ 300 – $1\,100$ USD en la matriz) (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022; Lopez-Lopez et al., 2021; Cnockaert et al., 2024; Eltes et al., 2020).

Tiempo vs. calidad.

En tu matriz, los enfoques automáticos/IA reportan ≈ 0.5 – 1.0 h con DSC ≈ 0.91 – 0.96 , frente a ≈ 3.5 – 4.0 h y DSC ≈ 0.84 – 0.88 en manual; esta diferencia favorece ventanas preoperatorias más cortas y modelos con mayor concordancia volumétrica (Antonelli et al., 2022; Wasserthal et al., 2022; Cai et al., 2023; Kamomae et al., 2017; George et al., 2017). Cuando la precisión geométrica es crítica (p. ej., neurovascular, hepatobiliar, vía aérea pediátrica), los estudios muestran preferencia por RM/TC bien protocolizadas y SLA/micro-SLA por su detalle superficial (Shibata et al., 2017; Lopez-Lopez et al., 2021; Cnockaert et al., 2024).

Adopción gradual y control clínico.

La tendencia reciente apunta a IA más robusta y tareas multiórgano/multimodal que han ido cerrando la brecha de rendimiento (Antonelli et al., 2022; Cai et al., 2023; Ekman et al., 2025; Sathianathen et al., 2022). Aun así, los estudios con validación clínica subrayan que la supervisión del especialista sigue siendo esencial para detectar fallos en casos atípicos y traducir las métricas técnicas en decisiones seguras (Jeon et al., 2024; Lopez-Lopez et al., 2021; George et al., 2017; Seok et al., 2021).

4.7 Discusión

4.7.1 Interpretación de los hallazgos

Los datos de la matriz muestran que la automatización de la segmentación con enfoques de deep learning —como U-Net, Swin-UNet3D y modelos multiestructura— ha mejorado de forma consistente la concordancia volumétrica y los tiempos de procesamiento frente a la segmentación manual. En conjunto, los estudios con IA informan DSC típicos ≈ 0.91 – 0.96 y tiempos ≈ 0.5 – 1.0 h (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022;

Sathianathen et al., 2022), mientras que la segmentación manual reporta $\approx 3.5\text{--}4.0$ h y DSC $\approx 0.84\text{--}0.88$ (Kamomae et al., 2017; George et al., 2017). Estas diferencias respaldan que la integración de IA aporta mayor eficiencia y consistencia para el postprocesado de imágenes en entornos clínicos.

Respecto a la tecnología de impresión, la distribución de la matriz indica que SLA/micro-SLA/SLS tienden a concentrar los DSC más altos ($\approx 0.92\text{--}0.95$), particularmente cuando se requiere fidelidad geométrica para planificación o comunicación clínica (Cnockaert et al., 2024; Lopez-Lopez et al., 2021; Seok et al., 2021). FDM, en cambio, se utiliza con mayor frecuencia en fantomas y planificación básica, con costos más bajos y DSC en torno a $\approx 0.88\text{--}0.90$ (Frölich et al., 2016; Kusk et al., 2022; Jreije et al., 2021). En nuestra matriz, los rangos de costo informados por estudio se sitúan aproximadamente en 50–300 USD (FDM), 300–600 USD (SLA) y 750–1 100 USD (micro-SLA), lo que refuerza que la selección tecnológica debe equilibrar precisión y viabilidad económica según el contexto.

Finalmente, se observa heterogeneidad en la validación clínica: varios trabajos documentan utilidad en la práctica (p. ej., cambios en la planificación, apoyo al consentimiento o validación intraoperatoria) (George et al., 2017; Lopez-Lopez et al., 2021; Seok et al., 2021; Fayad et al., 2021; Jeon et al., 2024), mientras que otros se centran en métricas técnicas o precisión geométrica sin traducirlas a desenlaces clínicos (Antonelli et al., 2022; Wasserthal et al., 2022; Cai et al., 2023; Cnockaert et al., 2024; Eltes et al., 2020). Esta disparidad justifica la necesidad de protocolos de validación estandarizados que integren métricas cuantitativas (DSC, HD, error volumétrico) y resultados clínicos comparables, en línea con las recomendaciones metodológicas que fundamentan esta revisión.

4.7.2 Implicaciones para la práctica en física médica

Las evidencias derivadas de esta revisión indican varias aplicaciones y recomendaciones concretas para optimizar el uso de modelos 3D impresos en entornos de física médica:

1) Integrar IA con revisión experta (pipeline “IA-first + human check”).

Adopta U-Net/Swin-UNet3D o modelos multiestructura (p. ej., TotalSegmentator) como primera pasada de segmentación y exige verificación por el físico/radiólogo antes del modelado. En tu matriz, estos métodos entregan $\approx 0.5\text{--}1.0$ h con DSC $\approx 0.91\text{--}0.96$, superando a la segmentación manual ($\approx 3.5\text{--}4.0$ h; DSC $\approx 0.84\text{--}0.88$). Úsalo como SLA clínico interno: preparar el modelo prequirúrgico en ≤ 1 h cuando el caso lo requiera (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022; Sathianathen et al., 2022; Kamomae et al., 2017; George et al., 2017).

2) Elegir la tecnología de impresión según el objetivo clínico (árbol simple de decisión).

FDM ($\approx 50\text{--}300$ USD): docencia, fantasmas, planificación básica o entornos con recursos limitados. Espera DSC $\approx 0.88\text{--}0.90$ en la matriz (Frölich et al., 2016; Kusk et al., 2022; Jreije et al., 2021).

- SLA / SLS ($\approx 300\text{--}900$ USD): cuando importan detalle superficial y fidelidad geométrica para guías/modelos clínicos (Holmes et al., 2020; Lopez-Lopez et al., 2021).
- Micro-SLA ($\approx 750\text{--}1\ 100$ USD): anatomías pequeñas/delicadas (p. ej., vía aérea pediátrica) donde el acabado condiciona el uso clínico (Cnockaert et al., 2024; Eltes et al., 2020).

(Los rangos son los reportados en tu matriz; interpreta entre estudios con cautela por la heterogeneidad de parámetros.)

3) Control de calidad y validación clínica mínima (EV3D “núcleo”).

- Cuantitativa: reporta DSC y HD/HD95 entre la segmentación y la referencia; añade métricas lineales (diámetros/distancias) y, cuando aplique, error volumétrico. Estos indicadores son consistentes en tus estudios de segmentación/benchmark y de exactitud geométrica (Antonelli et al., 2022; Ekman et al., 2025; Quihui-Rubio et al., 2022; Eltes et al., 2020).
- Cualitativa: utiliza evaluación estructurada por el equipo clínico (Likert de utilidad/aplicabilidad/fidelidad) y deja registro en la historia técnica del caso (Lopez-Lopez et al., 2021; George et al., 2017; Seok et al., 2021).

- QA periódico: imprimir y medir fantomas/phantoms institucionales para verificar consistencia dimensional y estabilidad del flujo (Holmes et al., 2020; Kusk et al., 2022; Eltes et al., 2020).

4) Registro operativo para justificar inversiones y mejorar el servicio. Estandariza una hoja de datos por caso con: modalidad, método de segmentación, tecnología de impresión, tiempos (segmentación/modelado/post-proceso), costo total, métricas (DSC, HD/HD95, lineales) y juicio clínico. Tu matriz demuestra que estas variables son comparables y accionables para auditoría y mejora continua (Antonelli et al., 2022; Wasserthal et al., 2022; Lopez-Lopez et al., 2021).

5) Capacitación y trabajo multidisciplinario con retorno clínico directo.

- Formación técnica: IA de segmentación (p. ej., U-Net/Swin-UNet3D/TotalSegmentator), preparación de mallas y parámetros de impresión/postcurado; usa fantomas para entrenamiento y QA (Jreije et al., 2021; Kusk et al., 2022; Eltes et al., 2020).
- Gobernanza clínica: revisiones conjuntas físico–radiólogo–cirujano en casos complejos; los estudios con desenlace clínico muestran mayor impacto cuando existe esta coordinación (Jeon et al., 2024; Lopez-Lopez et al., 2021; George et al., 2017; Seok et al., 2021).

4.7.3 Limitaciones del estudio

A pesar de la exhaustividad del análisis, este trabajo presenta varias limitaciones que deben considerarse al interpretar los resultados:

1. Sesgo de publicación y selección
 - La revisión se restringió a artículos en inglés y español, lo que puede haber excluido contribuciones relevantes en otros idiomas.
 - La aplicación del protocolo PRISMA, aunque rigurosa, depende de la calidad de los metadatos disponibles; algunos estudios no informaron tiempos de

segmentación o costos, dificultando comparaciones uniformes (Page et al., 2021; Moher et al., 2009).

2. Heterogeneidad metodológica

- Existe gran variabilidad en los parámetros técnicos de adquisición (resolución, dosis de contraste), algoritmos de segmentación (hiperparámetros no uniformes) y configuraciones de impresión (materiales, espesores de capa), lo que puede introducir sesgos no cuantificados en la matriz comparativa.

3. Limitaciones de la validación clínica

- Un 40 % de los estudios incluidos no reportaron métricas de resultados clínicos ni estadísticas asociadas (p. ej., valor p, intervalos de confianza), lo que impide establecer correlaciones estadísticamente robustas entre precisión técnica y resultados quirúrgicos.

4. Contexto geográfico y de recursos

- La mayoría de los estudios procede de centros de alto recurso (EE. UU., Europa), por lo que los hallazgos pueden no ser directamente extrapolables a entornos con menor disponibilidad tecnológica o presupuestaria.

5. Evolución tecnológica acelerada

- La rapidez con la que avanzan las técnicas de IA y los procesos de impresión 3D podría hacer que algunos de los hallazgos (sobre tiempos, costos o precisión) queden obsoletos en un plazo corto, especialmente con la aparición de nuevas arquitecturas de redes neuronales y materiales de impresión.

V. Capítulo V: Conclusiones y Recomendaciones

5.1 Conclusiones principales

1. Automatización eficaz.

La segmentación basada en IA (U-Net, Swin-UNet3D y modelos multiestructura) muestra DSC ≈ 0.91 – 0.96 y tiempos ≈ 0.5 – 1.0 h, superando a la segmentación manual (≈ 3.5 – 4.0 h; DSC ≈ 0.84 – 0.88). En conjunto, esto supone aceleraciones de ~ 3 – $7\times$ y una mejor concordancia volumétrica respecto a enfoques manuales, de acuerdo con los estudios incluidos (Cai et al., 2023; Antonelli et al., 2022; Wasserthal et al., 2022; Sathianathen et al., 2022; Kamomae et al., 2017; George et al., 2017).

2. Selección tecnológica balanceada.

Para escenarios que exigen alta fidelidad geométrica (p. ej., vía aérea pediátrica, hepato-biliar, modelos personalizados para comunicación clínica), los trabajos con SLA/micro-SLA/SLS concentran los DSC más altos reportados en la matriz (≈ 0.92 – 0.95) y se sitúan típicamente en ≈ 300 – $1\ 100$ USD por modelo (Cnockaert et al., 2024; Lopez-Lopez et al., 2021; Holmes et al., 2020; Eltes et al., 2020). FDM se mantiene como opción costo-efectiva para docencia, fantomas y planificación básica (≈ 50 – 300 USD; DSC ≈ 0.88 – 0.90) (Frölich et al., 2016; Kusk et al., 2022; Jreije et al., 2021). La elección debe equilibrar exigencia clínica y viabilidad económica.

3. Validación clínica heterogénea.

Una parte de los estudios documenta utilidad clínica (cambios en la planificación, apoyo al consentimiento o validación intraoperatoria) (George et al., 2017; Lopez-Lopez et al., 2021; Seok et al., 2021; Fayad et al., 2021; Jeon et al., 2024), mientras que otros se centran en métricas técnicas (DSC, HD, exactitud geométrica) sin traducirlas a desenlaces clínicos (Antonelli et al., 2022; Wasserthal et al., 2022; Cai et al., 2023; Cnockaert et al., 2024; Eltes et al., 2020). Esto respalda la necesidad de protocolos de validación estandarizados que integren métricas cuantitativas y resultados clínicos comparables.

4. Protocolo EV-3D para implementación segura.

Se recomienda institucionalizar un flujo con umbral de calidad mínimo (p. ej., $DSC \geq 0.91$, HD/HD95, métricas lineales), registro operativo (modalidad, método de segmentación, tecnología y parámetros de impresión, tiempos y costos) y evaluación clínica estructurada (utilidad/aplicabilidad/fidelidad). Este marco es consistente con las prácticas reportadas en los estudios de la matriz y facilita adopción, auditoría y mejora continua (Antonelli et al., 2022; Quihui-Rubio et al., 2022; Ekman et al., 2025; Lopez-Lopez et al., 2021).

Se propone el **protocolo EV-3D** para la estandarización del flujo de trabajo de segmentación, impresión y validación de modelos tridimensionales, para un servicio que desee incluir este tipo de herramientas, cuyo detalle se encuentra descrito en el **Anexo I**.

5.2 Recomendaciones para investigación futura

1. Estudios prospectivos controlados que midan estadísticamente la correlación entre métricas de precisión (Dice, Hausdorff) y resultados clínicos (tiempo quirúrgico, complicaciones).
2. Evaluaciones de costo-beneficio detalladas que incluyan no solo el precio de impresión, sino también los ahorros en tiempo de sala y reducción de errores quirúrgicos.
3. Desarrollo de bioprinting 4D y materiales inteligentes, con validación clínica rigurosa de modelos dinámicos para simulaciones fisiológicas.
4. Comparación entre modelo impreso 3D y modelo virtual de segmentación.

5.3 Recomendaciones institucionales y clínicas

1. Protocolos estandarizados (ISO 13485, FDA) que establezcan umbrales mínimos de calidad para adquisición, segmentación e impresión, documentados en guías internas.
2. Registro sistemático de métricas (tiempo, costo, Dice) para monitoreo continuo y justificación de inversiones.

3. Formación multidisciplinaria: implementar cursos y talleres regulares para físicos médicos, radiólogos y técnicos en impresión 3D, asegurando competencia en IA y manejo de materiales.

VI. Referencias

- Ekman, T., Barakat, A. y Heiberg, E. Marco de aprendizaje profundo generalizable para la segmentación de imágenes médicas en 3D utilizando datos de entrenamiento limitados. *Impresión 3D Med* **11**, 9 (2025). <https://doi.org/10.1186/s41205-025-00254-1>
- Quihui-Rubio, P. C., Ochoa-Ruiz, G., Gonzalez-Mendoza, M., Rodriguez-Hernandez, G., & Mata, C. (2022). Comparison of automatic prostate zones segmentation models in MRI images using U-net-like architectures.
- Cai, Y., Long, Y., Han, Z., et al. (2023). Swin Unet3D: A three-dimensional medical image segmentation network combining vision transformer and convolution. *BMC Medical Informatics and Decision Making*, 23(1), 33. <https://doi.org/10.1186/s12911-023-02129-z>
- Antonelli, M., Reinke, A., Bakas, S., et al. (2022). The Medical Segmentation Decathlon. *Nature Communications*, 13, 4128. <https://doi.org/10.1038/s41467-022-30695-9>
- Wasserthal, J., Meyer, M., Breit, H. C., & Würfl, T. (2022). TotalSegmentator: Robust segmentation of 104 anatomical structures in CT images. *Nature Scientific Reports*, 12(1), 18548. <https://doi.org/10.1148/ryai.230024>
- Cnockaert, P., Reyckler, G., Menten, R., Steckel, J., & Poncin, W. (2024). Validación geométrica de un modelo pediátrico de vías respiratorias superiores realizado con una impresora 3D de escritorio convencional. *Anales de la Medicina Impresa en 3D*, 15, 100165. <https://doi.org/10.1016/j.stlm.2024.100165>
- Lopez-Lopez, V., Robles-Campos, R., García-Calderon, D., Lang, H., Cugat, E., Jiménez-Galanes, S., Fernández-Cebrian, J. M., Sánchez-Turrión, V., Fernández-Fernández, J. M., Barrera-Gómez, M. Á., de la Cruz, J., Lopez-Conesa, A., Brusadin, R., Gomez-Perez, B., & Parrilla-Parricio, P. (2021). Applicability of 3D-printed models in hepatobiliary surgery: results from "LIV3DPRINT" multicenter study. *HPB : the official journal of the International Hepato Pancreato Biliary Association*, 23(5), 675–684. <https://doi.org/10.1016/j.hpb.2020.09.020>

- George, E., Barile, M., Tang, A., Wiesel, O., Coppolino, A., Giannopoulos, A., Mentzer, S., Jaklitsch, M., Hunsaker, A., & Mitsouras, D. (2017). Utility and reproducibility of 3-dimensional printed models in pre-operative planning of complex thoracic tumors. *Journal of surgical oncology*, 116(3), 407–415. <https://doi.org/10.1002/jso.24684>
- Irshad, T. B., Pascoletti, G., Bianconi, F. y Zanetti, E. M. (2024). Segmentación ósea mandibular a partir de tomografías computarizadas: comparación cuantitativa y cualitativa entre software. *Materiales dentales: publicación oficial de la Academia de Materiales Dentales*, 40(8), e11–e22. <https://doi.org/10.1016/j.dental.2024.05.022>
- Spaanderman, D. J., Starmans, M. P. A., van Erp, G. C. M., Hanff, D. F., Sluijter, J. H., Schut, A. W., van Leenders, G. J. L. H., Verhoef, C., Grünhagen, D. J., Niessen, W. J., Visser, J. J. y Klein, S. (2025). Segmentación mínimamente interactiva de tumores de tejidos blandos en TC y RM mediante aprendizaje profundo. *Radiología europea*, 35(5), 2736–2745. <https://doi.org/10.1007/s00330-024-11167-8>
- Shibata, E., Takao, H., Amemiya, S., & Ohtomo, K. (2017). 3D-Printed Visceral Aneurysm Models Based on CT Data for Simulations of Endovascular Embolization: Evaluation of Size and Shape Accuracy. *AJR. American journal of roentgenology*, 209(2), 243–247. <https://doi.org/10.2214/AJR.16.17694>
- Okuda, R., Tetsunaga, T., Yamada, K., Tetsunaga, T., Koura, T., Inoue, T., Masada, Y., Okazaki, Y., y Ozaki, T. (2025). Verificación de la precisión de un sistema de navegación basado en tomografía computarizada para la artroplastia total de cadera en la displasia grave de cadera: un estudio de simulación que utiliza modelos óseos impresos en 3D de los tipos II, III y IV de Crowe. *Medicina*, 61(6), 973. <https://doi.org/10.3390/medicina61060973>
- Yang, W. F. y Su, Y. X. (2021). La segmentación automática de la TC de cráneo habilitada por inteligencia artificial facilita la cirugía craneomaxilofacial asistida por computadora. *Oncología oral*, 118, 105360. <https://doi.org/10.1016/j.oraloncology.2021.105360>
- Sathianathen, N. J., Heller, N., Tejapaul, R., Stai, B., Kalapara, A., Rickman, J., Dean, J., Oestreich, M., Blake, P., Kaluzniak, H., Raza, S., Rosenberg, J., Moore, K., Walczak, E., Rengel, Z.,

- Edgerton, Z., Vasdev, R., Peterson, M., McSweeney, S., ... Weight, C. (2022). Automatic segmentation of kidneys and kidney tumors: The KiTS19 international challenge. *Frontiers in Digital Health, 3*, 797607. <https://doi.org/10.3389/fdgth.2021.797607>
- Yin, Y., Zhang, W., Zou, L., Liu, X., Yu, L., & Wang, M. (2025). Segmentation methods and dosimetric evaluation of 3D-printed immobilization devices in head and neck radiotherapy. *BMC cancer, 25*(1), 289. <https://doi.org/10.1186/s12885-025-13669-0>
- Eltes, P. E., Kiss, L., Bartos, M., Gyorgy, Z. M., Csakany, T., Bereczki, F., Lesko, V., Puhl, M., Varga, P. P., & Lazary, A. (2020). Geometrical accuracy evaluation of an affordable 3D printing technology for spine physical models. *Journal of clinical neuroscience : official journal of the Neurosurgical Society of Australasia, 72*, 438–446. <https://doi.org/10.1016/j.jocn.2019.12.027>
- Seok, J., Yoon, S., Ryu, C. H., Kim, S.-k., Ryu, J., & Jung, Y.-S. (2021). A Personalized 3D-Printed Model for Obtaining Informed Consent Process for Thyroid Surgery: A Randomized Clinical Study Using a Deep Learning Approach with Mesh-Type 3D Modeling. *Journal of Personalized Medicine, 11*(6), 574. <https://doi.org/10.3390/jpm11060574>
- Cavaliere, C., Baldi, D., Brancato, V., Aiello, M., & Salvatore, M. (2023). A customized anthropomorphic 3D-printed phantom to reproducibility assessment in computed tomography: an oncological case study. *Frontiers in oncology, 13*, 1123796. <https://doi.org/10.3389/fonc.2023.1123796>
- Fayad, J., Turbucz, M., Hajnal, B., Bereczki, F., Bartos, M., Bank, A., Lazary, A., & Eltes, P. E. (2021). Complicated Postoperative Flat Back Deformity Correction With the Aid of Virtual and 3D Printed Anatomical Models: Case Report. *Frontiers in surgery, 8*, 662919. <https://doi.org/10.3389/fsurg.2021.662919>
- Oh, N., Kim, J. H., Rhu, J., & et al. (2023). Automated 3D liver segmentation from hepatobiliary phase MRI for enhanced preoperative planning. *Scientific Reports, 13*, 17605. <https://doi.org/10.1038/s41598-023-44736-w>

- Jeon, Y. D., Jung, K. H., Kim, M. S., & et al. (2024). Clinical validation of artificial intelligence-based preoperative virtual reduction for Neer 3- or 4-part proximal humerus fractures. *BMC Musculoskeletal Disorders*, 25, 669. <https://doi.org/10.1186/s12891-024-07798-z>
- Zhu, Z., Xia, Y., Shen, W., Fishman, E. K., & Yuille, A. L. (2018). A 3D coarse-to-fine framework for volumetric medical image segmentation. arXiv. <https://doi.org/10.48550/arXiv.1712.00201>
- Balagopal, A., Kazemifar, S., Nguyen, D., Lin, M.-H., Hannan, R. Owrangi, A., & Jiang, S. (2018). *Fully automated organ segmentation in male pelvic CT images*. arXiv. <https://arxiv.org/abs/1805.12526>
- Zeng, G., Degonda, C., Schmaranzer, F., & Gerber, N. (2021). MRI-based 3D models of the hip joint enables radiation-free computer-assisted planning of periacetabular osteotomy for treatment of hip dysplasia using deep learning for automatic segmentation. *European Journal of Radiology Open*, 8(100303). <https://doi.org/10.1016/j.ejro.2020.100303>
- Kusk, M. W., Stowe, J., Hess, S., Gerke, O., & Foley, S. (2022). Low-cost 3D-printed anthropomorphic cardiac phantom, for computed tomography automatic left ventricle segmentation and volumetry — A pilot study. *Radiography*, 28(4), 1036–1044. <https://doi.org/10.1016/j.radi.2022.10.015>
- Frölich, A. M., Spallek, J., Brehmer, L., Buhk, J. H., Krause, D., Fiehler, J., & Kemmling, A. (2016). 3D Printing of Intracranial Aneurysms Using Fused Deposition Modeling Offers Highly Accurate Replications. *AJNR. American journal of neuroradiology*, 37(1), 120–124. <https://doi.org/10.3174/ajnr.A4486>
- Jreije, A., Keshelava, L., Ilickas, M., Laurikaitiene, J., Urbonavicius, B. G., & Adliene, D. (2021). Development of Patient Specific Conformal 3D-Printed Devices for Dose Verification in Radiotherapy. *Applied Sciences*, 11(18), 8657. <https://doi.org/10.3390/app11188657>
- Kamonae, T., Shimizu, H., Nakaya, T., Okudaira, K., Aoyama, T., Oguchi, H., Komori, M., Kawamura, M., Ohtakara, K., Monzen, H., Itoh, Y., & Naganawa, S. (2017). Three-dimensional printer-generated patient-specific phantom for artificial in vivo dosimetry in radiotherapy quality

- assurance. *Physical and Engineering Sciences in Medicine*, 43(4), 1235-1243. <https://doi.org/10.1016/j.ejmp.2020.09.020>
- Wang, B., Zou, C., Liu, X., Liu, D., Zhang, Y., & Zang, L. (2024). Development and Validation of Deep Learning Preoperative Planning Software for Automatic Lumbosacral Screw Selection Using Computed Tomography. *Bioengineering*, 11(11), 1094. <https://doi.org/10.3390/bio-engineering11111094>
- Holmes, R. B., Negus, I. S., Wiltshire, S. J., Thorne, G. C., Young, P., & Alzheimer's Disease Neuroimaging Initiative (2020). Creation of an anthropomorphic CT head phantom for verification of image segmentation. *Medical physics*, 47(6), 2380–2391. <https://doi.org/10.1002/mp.14127>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & The PRISMA Group. (2009). Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. *PLoS Medicine*, 6(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>

VII. Anexo I

Protocolo EV-3D (Estandarización y Validación de Modelos 3D)

1. Objetivo

Garantizar la reproducibilidad, seguridad y utilidad clínica de los modelos 3D prequirúrgicos mediante un flujo de trabajo estandarizado, con métricas cuantitativas de control de calidad y validación clínica.

2. Alcance

Aplica a todos los procesos de generación de modelos 3D impresos en el servicio de Física Médica, desde la adquisición de imagen hasta la entrega al equipo quirúrgico.

3. Responsabilidades

- Físico Médico: coordina el protocolo, revisa métricas de calidad, documenta resultados.
- Radiólogo: supervisa parámetros de adquisición y aprueba volúmenes DICOM.
- Ingeniero Biomédico/Técnico 3D/ Físico Médico (Según disposición): realiza segmentación, modelado e impresión.
- Cirujano/Usuario final: valida el modelo en términos de utilidad clínica.

4. Flujo de trabajo y criterios de control

Tabla 2

Flujo de trabajo y criterios de control

Paso	Actividad	Criterio mínimo
4.1 Adquisición DICOM	<ul style="list-style-type: none"> · Verificar protocolo de imagen (resolución ≤ 1 mm; cortes ≤ 1 mm). · Registrar dosis y parámetros. 	<ul style="list-style-type: none"> - Resolución espacial ≤ 1 mm. - Secuencia/documento firmado por radiólogo.
4.2 Segmentación	<ul style="list-style-type: none"> · Ejecutar IA (U-Net 3D o Swin-UNet) con parámetros validados. · Calibrar umbrales manuales. 	<ul style="list-style-type: none"> - DSC (Dice) ≥ 0.90 frente a segmentación de referencia. - Tiempo de segmentación ≤ 1 h.
4.3 Modelado y QA digital	<ul style="list-style-type: none"> · Cerrar huecos y exportar STL. · Comprobar integridad de malla (sin bordes abiertos). 	<ul style="list-style-type: none"> - Reporte de malla sin errores (herramienta de malla libre). - Volumen final ± 2 % del original.
4.4 Impresión	<ul style="list-style-type: none"> · Seleccionar tecnología según categoría clínica. · Configurar parámetros de impresión. 	<ul style="list-style-type: none"> - FDM: capa ≤ 300 μm (Dice ≥ 0.85). - SLA/SLS/Micro-SLA: capa ≤ 100 μm (Dice ≥ 0.94). - Registro de material y lote.
4.5 Control post-print	<ul style="list-style-type: none"> · Medir dimensiones críticas con calibre digital. · Inspección visual de detalles anatómicos. 	<ul style="list-style-type: none"> - Desviación dimensional ≤ 1 %. - Sin defectos visibles en áreas críticas (bordes, cavidades).
4.6 Validación clínica	<ul style="list-style-type: none"> · Cirujano realiza prueba de encaje/simulacros. · Encuesta de utilidad (Likert 1–5). 	<ul style="list-style-type: none"> - Puntuación ≥ 4 en percepción de utilidad. - Informe de casuística con métricas de tiempo quirúrgico vs. modelo.
4.7 Documentación y auditoría	<ul style="list-style-type: none"> · Completar ficha EV-3D (DICOM, segmentación, impresión, QA, 	<ul style="list-style-type: none"> - 100 % de los modelos con ficha completa.

validación).
· Revisión trimestral.

- Informe de auditoría interna cada 3 meses con indicadores de cumplimiento $\geq 90\%$.

5. Métricas de seguimiento

- Porcentaje de modelos con Dice ≥ 0.90
- Tiempo medio de producción (DICOM \rightarrow Modelo final)
- Costo medio por modelo
- Reducción porcentual del tiempo quirúrgico comparado con planificaciones sin modelo
- Nivel de satisfacción del cirujano (encuesta Likert)

6. Capacitación y actualización

- Cursos semestrales en segmentación IA y software de modelado.
- Talleres prácticos de impresión 3D y control de calidad.
- Revisión anual del protocolo EV-3D para incorporar nuevas tecnologías y lecciones aprendidas.

Código completo de Python usado para analizar DSC en volúmenes esféricos

```

import numpy as np
import matplotlib.pyplot as plt
from mpl_toolkits.mplot3d import Axes3D
from matplotlib.widgets import TextBox, Button

def dice_score_3d(center1, radius1, center2, radius2, resolution=50):
    """Calcula el índice DICE entre dos esferas en 3D"""
    # Crear malla 3D
    x, y, z = np.mgrid[
        min(center1[0]-radius1, center2[0]-radius2):max(center1[0]+radius1, center2[0]+radius2):resolution*1j,
        min(center1[1]-radius1, center2[1]-radius2):max(center1[1]+radius1, center2[1]+radius2):resolution*1j,
        min(center1[2]-radius1, center2[2]-radius2):max(center1[2]+radius1, center2[2]+radius2):resolution*1j
    ]

    # Calcular máscaras para cada esfera
    sphere1 = (x-center1[0])**2 + (y-center1[1])**2 + (z-center1[2])**2 <= radius1**2
    sphere2 = (x-center2[0])**2 + (y-center2[1])**2 + (z-center2[2])**2 <= radius2**2

    # Calcular DICE
    intersection = np.sum(np.logical_and(sphere1, sphere2))
    return (2. * intersection) / (np.sum(sphere1) + np.sum(sphere2))

# Configuración inicial
fig = plt.figure(figsize=(18, 8))
ax = fig.add_subplot(111, projection='3d')
plt.subplots_adjust(bottom=0.3)

# Valores iniciales
init_center1 = [0, 0, 0]
init_radius1 = 1
init_center2 = [0.5, 0.5, 0.5]
init_radius2 = 1

```

```

# Función para dibujar esferas
def draw_spheres():
    ax.clear()

    # Crear malla para las esferas
    u, v = np.mgrid[0:2*np.pi:20j, 0:np.pi:10j]

    # Esfera 1
    x1 = init_radius1 * np.cos(u)*np.sin(v) + init_center1[0]
    y1 = init_radius1 * np.sin(u)*np.sin(v) + init_center1[1]
    z1 = init_radius1 * np.cos(v) + init_center1[2]
    ax.plot_wireframe(x1, y1, z1, color="blue", alpha=0.5, label=f'Esfera A: Centro {init_center1}, Radio {init_radius1}')

    # Esfera 2
    x2 = init_radius2 * np.cos(u)*np.sin(v) + init_center2[0]
    y2 = init_radius2 * np.sin(u)*np.sin(v) + init_center2[1]
    z2 = init_radius2 * np.cos(v) + init_center2[2]
    ax.plot_wireframe(x2, y2, z2, color="red", alpha=0.5, label=f'Esfera B: Centro {init_center2}, Radio {init_radius2}')

    # Calcular DICE
    dice = dice_score_3d(init_center1, init_radius1, init_center2, init_radius2)

    # Configuración del gráfico
    ax.set_title(f'Comparación de Esferas 3D\nÍndice DICE = {dice:.4f}')
    ax.legend(loc='upper right')
    ax.set_xlabel('x')
    ax.set_ylabel('y')
    ax.set_zlabel('z')
    ax.grid(True)

    fig.canvas.draw_idle()

```

```

# Dibujar esferas iniciales
draw_spheres()

# Crear controles de entrada
axcolor = 'lightgoldenrodyellow'

# Esfera A
ax_center1_x = plt.axes([0.15, 0.20, 0.1, 0.05], facecolor=axcolor)
ax_center1_y = plt.axes([0.15, 0.15, 0.1, 0.05], facecolor=axcolor)
ax_center1_z = plt.axes([0.15, 0.10, 0.1, 0.05], facecolor=axcolor)
ax_radius1 = plt.axes([0.15, 0.05, 0.1, 0.05], facecolor=axcolor)

text_center1_x = TextBox(ax_center1_x, 'Centro A X', initial=str(init_center1[0]))
text_center1_y = TextBox(ax_center1_y, 'Centro A Y', initial=str(init_center1[1]))
text_center1_z = TextBox(ax_center1_z, 'Centro A Z', initial=str(init_center1[2]))
text_radius1 = TextBox(ax_radius1, 'Radio A', initial=str(init_radius1))

# Esfera B
ax_center2_x = plt.axes([0.40, 0.20, 0.1, 0.05], facecolor=axcolor)
ax_center2_y = plt.axes([0.40, 0.15, 0.1, 0.05], facecolor=axcolor)
ax_center2_z = plt.axes([0.40, 0.10, 0.1, 0.05], facecolor=axcolor)
ax_radius2 = plt.axes([0.40, 0.05, 0.1, 0.05], facecolor=axcolor)

text_center2_x = TextBox(ax_center2_x, 'Centro B X', initial=str(init_center2[0]))
text_center2_y = TextBox(ax_center2_y, 'Centro B Y', initial=str(init_center2[1]))
text_center2_z = TextBox(ax_center2_z, 'Centro B Z', initial=str(init_center2[2]))
text_radius2 = TextBox(ax_radius2, 'Radio B', initial=str(init_radius2))

# Botón de actualización
ax_update = plt.axes([0.75, 0.10, 0.1, 0.05])
update_button = Button(ax_update, 'Actualizar', color=axcolor, hovercolor='0.975')

```

```

def update(val):
    """Actualiza los parámetros de las esferas"""
    global init_center1, init_radius1, init_center2, init_radius2

    try:
        init_center1 = [
            float(text_center1_x.text),
            float(text_center1_y.text),
            float(text_center1_z.text)
        ]
        init_radius1 = float(text_radius1.text)

        init_center2 = [
            float(text_center2_x.text),
            float(text_center2_y.text),
            float(text_center2_z.text)
        ]
        init_radius2 = float(text_radius2.text)

        draw_spheres()
    except ValueError:
        print("Error: Ingresar valores numéricos válidos")

update_button.on_clicked(update)

plt.show()

```