

TRABAJO FIN DE MÁSTER
MÁSTER UNIVERSITARIO EN BIOTECNOLOGÍA Y BIOINGENIERÍA
CURSO 2024-25
UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE

SISTEMA SEMIAUTOMÁTICO DE PLANIFICACIÓN QUIRÚRGICA PARA ROBOTS AUTÓNOMOS

Autor: Marina Poveda Pérez, Bsc.

Tutor académico: Prof. José María Sabater Navarro

Co-tutora: Msc. Juliana Manrique Córdoba



Declaración del tutor o tutores

D. JOSÉ MARÍA SABATER NAVARRO, Catedrático de Universidad del área Ingeniería de Sistemas y Automática de la Universidad Miguel Hernández de Elche.

CERTIFICA

Que el presente trabajo titulado:

“SISTEMA SEMIAUTOMÁTICO DE PLANIFICACIÓN QUIRÚRGICA PARA ROBOTS AUTÓNOMOS”

y que constituye la Memoria del Trabajo Fin de Máster en Biotecnología y Bioingeniería, que presenta:

D.ª MARINA POVEDA PÉREZ

ha sido realizado bajo su supervisión en el Instituto de Bioingeniería, cumpliendo todos los requisitos necesarios.

Y para que así conste, se expide y firma el presente certificado en Elche a fecha de la firma electrónica.



Fdo.: Prof. José María Sabater Navarro

Resumen

Este trabajo presenta un sistema semiautomático para la transferencia de la planificación quirúrgica robótica realizada en un entorno 2D/3D, permitiendo complementar las trayectorias definidas manualmente por el cirujano con información adicional de orientación y velocidad, necesaria para su ejecución autónoma por parte de un robot quirúrgico. El sistema incluye una red neuronal para la segmentación semiautomática de los tejidos hepáticos. Para el cálculo de las orientaciones y velocidades del efector del robot, el sistema se basa en el cálculo de normales a la superficie anatómica del órgano segmentado en cada punto de la trayectoria. La solución presentada ha sido implementada como un plug-in de software dentro del proyecto de software libre 3D Slicer y se ha integrado con ROS para su transferencia a un robot UR3e. La validación se ha realizado en un caso de resección del segmento III del hígado, demostrando que el sistema es eficiente, preciso y adecuado para entornos de planificación quirúrgica.

Palabras Clave

Planificación quirúrgica, robótica, segmentación, planificación de trayectorias, autonomía de robots quirúrgicos.



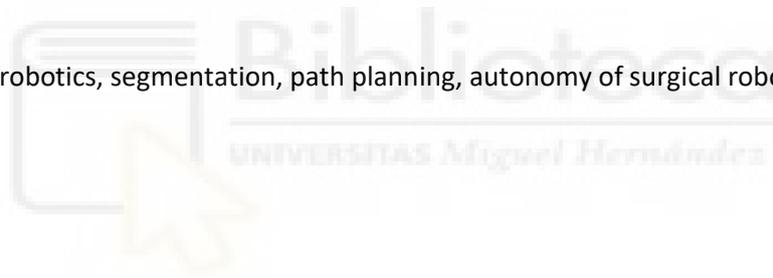
Semi-automatic surgical planning system for autonomos robots.

Abstract

This work presents a semi-automatic system that transfers robotic surgical planning from a 2D/3D environment. This system allows surgeons to manually define trajectories and provides additional orientation and speed information necessary for autonomous execution by a surgical robot. The system includes a neural network for semi-automatic segmentation of liver tissue. To calculate the robot effector's orientations and velocities, the system calculates normals to the anatomical surface of the segmented organ at each point of the trajectory. The solution has been implemented as a software plug-in in the open-source project 3D Slicer and integrated with ROS for transfer to a UR3e robot. Validation was performed for a segment III liver resection, demonstrating that the system is efficient, accurate, and suitable for surgical planning environments.

Keywords

Surgical planning, robotics, segmentation, path planning, autonomy of surgical robots.



Índice

Introducción y antecedentes	7
1. Introducción al problema de la autonomía en robots quirúrgicos	7
a. Teleoperación vs autonomía en robótica quirúrgica	7
Niveles de autonomía en robots manipuladores.....	7
b. Sistemas comerciales y sistemas de investigación	13
c. Dificultades en la autonomía de robots quirúrgicos	14
2. Situación actual de la cirugía asistida por computador (CAS).....	15
a. Esquema global CAS.....	17
Etapa preoperatoria.....	17
Etapa intraoperatoria.....	19
Objetivos	21
Procedimiento experimental	24
Segmentación semiautomática.....	24
Planificación quirúrgica.....	28
Resultados	41
Segmentación semiautomática.....	41
Planificación quirúrgica.....	45
Discusión	55
Conclusiones	56
Bibliografía	57

Introducción y antecedentes

1. Introducción al problema de la autonomía en robots quirúrgicos

La cirugía robótica es una de las áreas más destacadas de la robótica, debido a su convergencia entre tres sectores clave: los cirujanos, quienes consideran a los robots como herramientas avanzadas que potencian sus habilidades y permiten intervenciones más precisas; los ingenieros, que buscan explorar nuevos desafíos y aplicaciones tecnológicas; y los emprendedores, quienes ven en este campo una valiosa oportunidad de negocio (Attanasio et al. 2021).

En las últimas décadas, la robótica quirúrgica ha transformado significativamente la medicina, ofreciendo una mayor precisión, control y acceso a regiones anatómicas complejas. Sin embargo, muchos de los sistemas actuales, como el robot da Vinci, siguen operando bajo un modelo de teleoperación pura, donde el cirujano mantiene el control directo de los instrumentos robóticos. Este enfoque limita el potencial de automatización y eficiencia de los procedimientos, además de generar una gran dependencia del operador humano. Por ello, la robótica quirúrgica autónoma se presenta como un campo desafiante pero prometedor, que ha generado gran interés en los tres sectores mencionados (Attanasio et al. 2021).

a. Teleoperación vs autonomía en robótica quirúrgica

La teleoperación es el paradigma dominante en la cirugía asistida por robot. En este modelo, el robot actúa como una extensión precisa de los movimientos del cirujano, pero sin capacidad para tomar decisiones. Aunque este enfoque ha demostrado ser seguro y efectivo, no explota completamente el potencial de un sistema autónomo, que podría encargarse de tareas repetitivas, supervisar el entorno quirúrgico en tiempo real o corregir errores humanos. Por otro lado, la autonomía en robótica quirúrgica permitiría reducir la carga cognitiva del cirujano, mejorar la consistencia de los procedimientos y facilitar intervenciones en entornos con recursos limitados. Sin embargo, este modelo presenta nuevos desafíos éticos, legales y tecnológicos, particularmente en lo que respecta a la validación, certificación y aceptación clínica de estos sistemas.

A medida que la robótica quirúrgica avanza, es importante entender que la capacidad de decisión de los sistemas robóticos no se reduce a una simple dicotomía entre control humano total y operación completamente automatizada. En realidad, existe un espectro de niveles que refleja distintas formas y grados de independencia frente a la intervención del cirujano. Para clasificar estos niveles, se han desarrollado marcos que permiten analizar el papel que desempeña el robot en el procedimiento quirúrgico, así como sus implicaciones clínicas, regulatorias y éticas.

Niveles de autonomía en robots manipuladores

En 2017, (Yang et al., 2017) proponen una clasificación de los niveles de autonomía en cirugía robótica, inspirada

en los niveles de autonomía de los vehículos autónomos. Esta clasificación define el grado de autonomía alcanzado por una plataforma robótica, desde el nivel 0, que representa la ausencia de autonomía (teleoperación), hasta el nivel 5, que implica una autonomía total, donde el robot realiza la cirugía completamente de forma independiente. Los seis niveles de autonomía en cirugía robótica descritos por (Yang et al., 2017) son los siguientes (Figura 1).

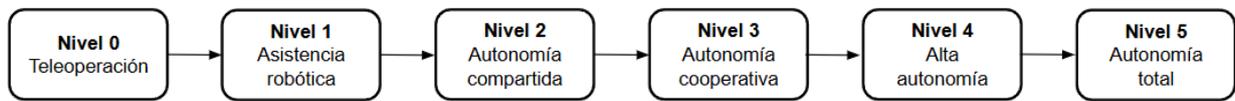


Figura 1. Diagrama de los niveles de autonomía. Fuente propia.

Nivel 0: Teleoperación.

En este nivel, el robot no toma decisiones autónomas. Como se muestra en la Figura 2, el control del movimiento recae completamente en el cirujano, sin apoyo cognitivo o físico del sistema. La mayoría de las plataformas comerciales actuales operan bajo este modelo, replicando fielmente los movimientos del cirujano en los instrumentos quirúrgicos. Aunque estos sistemas pueden incluir funciones automáticas como la supresión de temblores o la resolución de redundancia, no interfieren en las decisiones del cirujano. Este modelo ha sido fundamental para obtener la aprobación regulatoria, como la de la Administración de Alimentos y Medicamentos (FDA, por sus siglas en inglés), ya que no implica decisiones autónomas del robot, lo que minimiza los riesgos legales, ya que el robot se considera una herramienta avanzada y no un agente decisor (Attanasio et al. 2021).

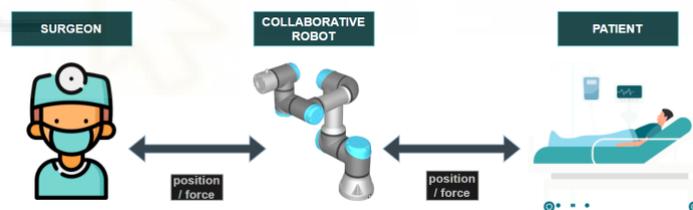


Figura 2. Esquema nivel 0 de autonomía. Fuente propia.

Nivel 1: Asistencia robótica.

En esta etapa, el sistema robótico adquiere un rol más protagonista durante la cirugía, brindando asistencia al cirujano de manera regulada (Figura 3). Es importante subrayar que el robot no actúa de forma autónoma ni toma decisiones por sí mismo; su función es apoyar al profesional humano, mejorando la precisión y el control durante el procedimiento quirúrgico (Attanasio et al., 2021).

Esta asistencia puede dividirse principalmente en dos tipos. La asistencia pasiva proporciona información complementaria al cirujano antes o durante la intervención, para optimizar la planificación y ejecución de la cirugía. Esta puede incluir realidad aumentada (Williams et al., 2020), reconstrucciones 3D (Sys et al., 2017) o trayectorias quirúrgicas predefinidas (Vrooijink et al., 2014). El sistema no interviene en los movimientos ni decisiones del cirujano, sino que actúa como herramienta visual y estratégica.

En cambio, la asistencia activa implica interacción física entre el robot y el cirujano, mediante restricciones de movimiento o fuerzas de guía que aumentan la precisión y seguridad del procedimiento. Aunque el robot no actúa de forma autónoma, responde a las acciones del operador humano, puede compensar movimientos fisiológicos como la respiración o el pulso (Wood et al., 2018) y proporcionar retroalimentación háptica para tareas como la palpación virtual o la detección de estructura internas (Molinero et al., 2019), (Moccia et al., 2019). En ambos casos, el cirujano mantiene el control total, pero el apoyo robótico contribuye a reducir la variabilidad entre procedimientos y a avanzar hacia sistemas con mayor grado de autonomía.

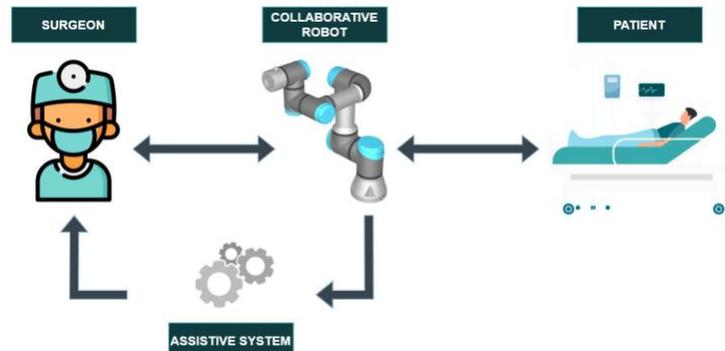


Figura 3. Esquema nivel 1 de autonomía. Fuente propia.

Nivel 2: Autonomía compartida.

En este nivel de desarrollo, también denominado *autonomía en tareas específicas*, los sistemas robóticos son capaces de ejecutar de manera autónoma ciertas acciones quirúrgicas concretas, siempre bajo la supervisión del cirujano (Figura 4). A diferencia de la asistencia activa, donde el robot reacciona en tiempo real a las acciones humanas, aquí el sistema asume directamente el control de subtareas previamente definidas, aunque el profesional conserva la autoridad para intervenir o detener el proceso en cualquier momento (Attanasio et al., 2021).

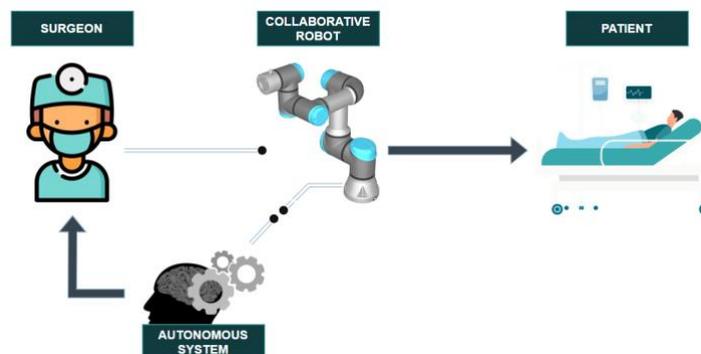


Figura 4. Esquema nivel 2 de autonomía. Fuente propia.

El robot no toma decisiones sobre qué tareas realizar ni cuándo iniciarlas, pero sí puede ejecutar de forma independiente aquellas que le han sido asignadas, siguiendo trayectorias o parámetros preestablecidos (Yang et al., 2017). La responsabilidad de la planificación sigue recayendo en el cirujano, mientras que el robot se encarga de ejecutar con precisión lo que ha sido programado. Sin embargo, uno de los principales beneficios de este nivel

es la reducción de la carga cognitiva y física del profesional, ya que el sistema puede encargarse de tareas repetitivas o que requieren una alta precisión. Ejemplos representativos incluyen el cierre automático de heridas mediante sutura o el fresado óseo en procedimientos ortopédicos, en los que la rigidez estructural del hueso permite una planificación exacta de la trayectoria que luego puede ser ejecutada por el robot (Dillon et al., 2016). Al asumir estas funciones, el sistema permite al cirujano concentrarse en los aspectos estratégicos y críticos de la intervención (Attanasio et al., 2021).

Nivel 3: Autonomía cooperativa.

En el tercer nivel de autonomía, el sistema robótico no solo ejecuta tareas predefinidas, sino que también adquiere la capacidad de colaborar activamente con el cirujano durante el procedimiento quirúrgico (Yang et al., 2017). Como se muestra en la Figura 5, este enfoque se basa en una interacción dinámica entre humano y robot, en la que el sistema interpreta información quirúrgica en tiempo real, identifica elementos relevantes del entorno y propone acciones específicas que deben ser validadas por el profesional antes de su ejecución (Attanasio et al., 2021).

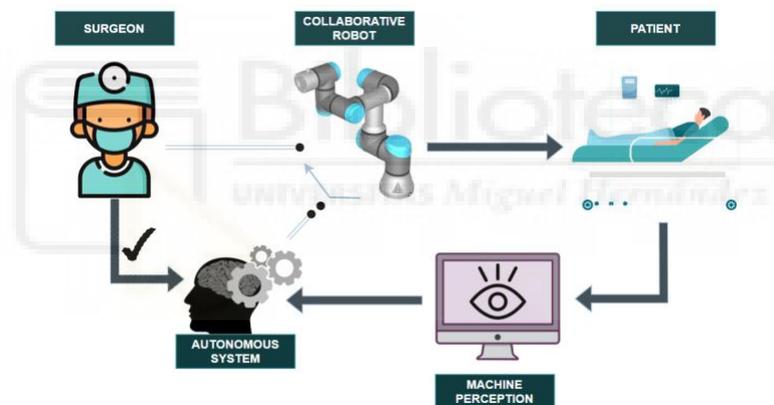


Figura 5. Esquema nivel 3 de autonomía. Fuente propia.

Este nivel implica una colaboración activa entre el cirujano y el robot. A diferencia de niveles anteriores, el sistema ya no se limita a seguir instrucciones fijas, sino que puede analizar tanto datos preoperatorios como información intraoperatoria y generar planes de acción óptimos para tareas complejas. Por ejemplo, en procedimientos de sutura automática, el robot puede detectar la ubicación y geometría de una herida, estimar la trayectoria ideal para la aguja y proponer un plan que el cirujano puede aceptar, modificar o rechazar (Galán-Cuenca et al., 2024).

Además, el robot es capaz de ajustar sus parámetros en tiempo real, adaptándose a los cambios en el entorno quirúrgico, lo que le permite actuar como un asistente inteligente. Esta capacidad de interpretación y adaptación representa un avance significativo respecto al nivel anterior, ya que el sistema no solo ejecuta tareas asignadas, sino que también participa activamente en la planificación operativa y responde de forma contextual a lo que ocurre durante la cirugía. Sin embargo, aunque el sistema contribuya activamente a la ejecución y planificación de tareas, no sustituye el juicio clínico humano ni toma decisiones de forma autónoma (Attanasio et al., 2021). Por

ello, este nivel marca un paso importante hacia sistemas quirúrgicos más inteligentes, sin perder de vista el principio fundamental de mantener al profesional médico en el centro del proceso de toma de decisiones.

Nivel 4: Replanificación en línea o alta autonomía.

En el cuarto nivel de autonomía, el sistema robótico alcanza la capacidad de interpretar información tanto preoperatoria como intraoperatoria, generar un plan quirúrgico de actuación y modificarlo dinámicamente durante el procedimiento (Figura 6), en respuesta a cambios en el entorno o en la evolución de la tarea (Attanasio et al., 2021). A diferencia de los niveles anteriores, en este nivel el robot puede tomar decisiones operativas en tiempo real, dentro de un marco clínico previamente definido y siempre bajo supervisión médica (Yang et al., 2017).

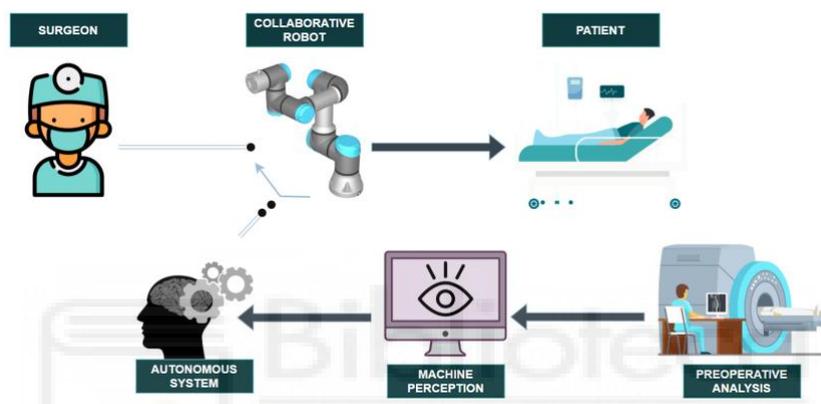


Figura 6. Esquema nivel 4 de autonomía. Fuente propia.

Este grado de autonomía introduce razonamiento autónomo, permitiendo al sistema ajustar sus estrategias de intervención ante desviaciones del plan original. El robot ya no se limita a ejecutar tareas predefinidas o proponer acciones al cirujano, sino que es capaz de adaptar sus movimientos y decisiones de manera autónoma durante la cirugía. Para ello, se requiere una integración avanzada de sensores, modelos anatómicos, algoritmos de control adaptativo y procesamiento de datos en tiempo real, lo cual permite al sistema reajustar trayectorias, modificar parámetros de ejecución o redefinir estrategias quirúrgicas en función del contexto (Attanasio et al., 2021).

En este modelo, el rol del cirujano se asemeja al de un supervisor experto que monitorea la actuación de un "residente robótico", con iniciativa propia para ejecutar tareas quirúrgicas complejas, pero sin una autonomía clínica completa. Aunque el sistema actúa con mayor independencia, la supervisión humana sigue siendo fundamental para garantizar la seguridad y el cumplimiento de los objetivos terapéuticos (Yang et al., 2017).

Un ejemplo ilustrativo de aplicación es la resección tumoral guiada por imagen, en la cual el robot puede adaptarse en tiempo real a desplazamientos anatómicos, alteraciones del tejido o nuevas imágenes adquiridas durante la intervención, ajustando así su plan quirúrgico de forma autónoma (McKinley et al., 2016). No obstante, a pesar de su elevado potencial funcional, este nivel de autonomía aún no ha sido implementado en

plataformas comerciales, debido a los importantes desafíos técnicos, éticos y regulatorios que plantea la delegación parcial de decisiones clínicas a un sistema automatizado (Attanasio et al., 2021).

Nivel 5: Autonomía total.

Finalmente, el nivel 5 representa el grado más avanzado de autonomía en cirugía robótica (Figura 7). En este estadio, el sistema robótico es capaz de planificar, decidir y ejecutar un procedimiento quirúrgico completo de forma completamente independiente, sin necesidad de intervención humana directa durante ninguna fase del acto quirúrgico (Yang et al., 2017), (Attanasio et al., 2021).

Este nivel implica que el robot no solo interpreta el entorno quirúrgico en tiempo real, sino que también toma decisiones clínicas complejas, como la selección de la estrategia quirúrgica más adecuada, la identificación y gestión de riesgos intraoperatorios, y la adaptación ante eventos imprevistos. En otras palabras, el sistema actúa como un cirujano autónomo, con plena capacidad para llevar a cabo una intervención de principio a fin, desde la planificación preoperatoria hasta la ejecución y finalización del procedimiento.

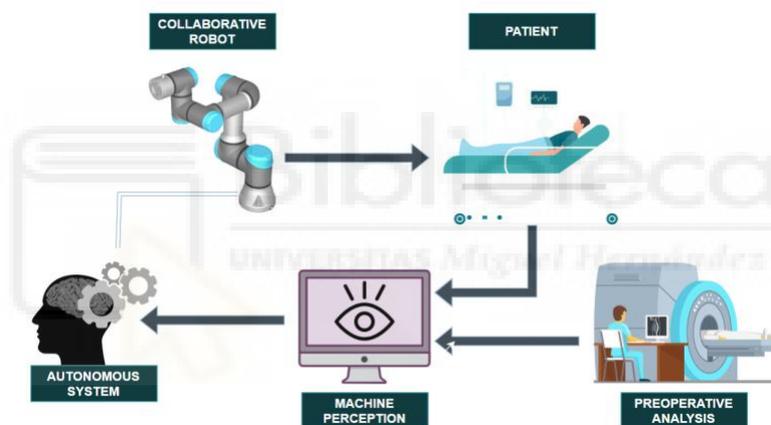


Figura 7. Esquema nivel 5 de autonomía. Fuente propia.

A pesar de su potencial revolucionario, actualmente no existen sistemas clínicos implementados que operen con este nivel de autonomía. Todos los avances en esta área permanecen en fase de investigación, ya que los desafíos tecnológicos, éticos, regulatorios y legales asociados a la delegación completa de decisiones clínicas a una inteligencia artificial son aún inmensos (Yang et al., 2017).

Esta clasificación jerárquica de los niveles de autonomía en cirugía robótica proporciona un marco conceptual claro para comprender la evolución desde sistemas puramente teleoperados hasta plataformas quirúrgicas capaces de actuar con independencia. La progresión entre niveles no solo refleja avances tecnológicos, sino también la creciente complejidad de los desafíos éticos, legales y clínicos que deben abordarse. Este marco resulta fundamental para guiar a investigadores, ingenieros y profesionales de la salud en la evaluación, diseño y desarrollo de las futuras generaciones de robots quirúrgicos inteligentes.

b. Sistemas comerciales y sistemas de investigación

La robótica quirúrgica constituye un campo en plena expansión que involucra tanto el desarrollo de plataformas comerciales como la experimentación en entornos de investigación. Sin embargo, existen diferencias fundamentales entre ambos tipos de sistemas, que afectan tanto a su diseño como a su capacidad de incorporar niveles avanzados de autonomía.

Los sistemas comerciales se caracterizan por estar orientados a la práctica clínica, por lo que su desarrollo y despliegue están fuertemente condicionados por los requisitos regulatorios exigidos por las autoridades sanitarias. Este marco normativo, que busca garantizar la seguridad del paciente y la responsabilidad médica, impone una serie de restricciones técnicas que limitan la autonomía de estos sistemas. En consecuencia, la mayoría de las plataformas disponibles comercialmente operan en un nivel de autonomía 0, es decir, funcionan mediante teleoperación directa por parte del cirujano, sin capacidad de toma de decisiones autónoma. Un ejemplo paradigmático de este enfoque es el sistema da Vinci® de *Intuitive Surgical*, cuyo modelo de operación se basa en la réplica exacta de los movimientos del cirujano a través de instrumentos robóticos, dentro del paradigma de "teleoperación transparente".

Pese a que ciertos componentes algorítmicos como la supresión del temblor o la resolución de redundancia están presentes en estos dispositivos, su funcionalidad está diseñada de manera que no interfiera con las decisiones clínicas del profesional humano. Esta estrategia ha permitido a los fabricantes eximirse de la responsabilidad directa por los resultados quirúrgicos, transfiriendo dicha responsabilidad al cirujano operador. De hecho, esta orientación ha contribuido a una baja incidencia de litigios legales, tal como se ha documentado en el caso de *Intuitive Surgical*.

Por otro lado, los sistemas de investigación no están sujetos a los mismos requerimientos regulatorios que los sistemas comerciales, lo que les otorga una mayor flexibilidad para la exploración de soluciones técnicas avanzadas. Esto ha posibilitado el desarrollo de plataformas experimentales que implementan niveles de autonomía significativamente superiores, incluyendo tareas como el seguimiento autónomo de tejidos, la sutura automatizada y procedimientos guiados por imagen. Dichos sistemas han alcanzado niveles de autonomía de tipo 2 (autonomía de tareas), 3 (autonomía condicional) e incluso 4 (alta autonomía) en entornos controlados de laboratorio o pruebas preclínicas (Attanasio et al., 2021).

La dicotomía entre sistemas comerciales y de investigación refleja un balance entre seguridad regulada y libertad innovadora. Mientras que los primeros priorizan la fiabilidad y la responsabilidad clínica, los segundos actúan como laboratorio tecnológico para las futuras generaciones de robots quirúrgicos con capacidades avanzadas. No obstante, la integración progresiva de estos avances en los entornos clínicos requerirá un replanteamiento de los marcos ético-legales actuales y una mayor colaboración entre ingenieros, cirujanos, legisladores y la industria biomédica.

c. Dificultades en la autonomía de robots quirúrgicos

A pesar de los avances recientes en la integración de autonomía en sistemas quirúrgicos, persisten desafíos significativos que limitan su implementación efectiva en contextos clínicos reales. El artículo *Autonomy in Surgical Robotics* (Attanasio et al., 2021) identifica varios de estos obstáculos, relacionados tanto con la naturaleza del entorno quirúrgico como con la fisiología de los tejidos humanos.

i. Medicina personalizada e intervenciones variables

Uno de los principales desafíos para alcanzar una autonomía efectiva en la robótica quirúrgica radica en la necesidad de adaptar los procedimientos a las características específicas de cada paciente. En este contexto, la medicina personalizada introduce una variabilidad inherente en cuanto a la anatomía, la localización de la patología, la respuesta tisular y las condiciones clínicas particulares. Esta heterogeneidad dificulta la creación de modelos generalizables que permitan a los robots planificar y ejecutar intervenciones de forma autónoma.

Si bien algunos procedimientos pueden ser representados como secuencias discretas de tareas, estas deben ser ajustadas dinámicamente según la información preoperatoria e intraoperatoria de cada caso. La planificación quirúrgica debe considerar múltiples factores individualizados, lo que impone al sistema robótico la necesidad de interpretar y adaptar su comportamiento frente a escenarios únicos. Esta capacidad, que en la práctica clínica humana proviene de la experiencia y juicio del cirujano, representa una barrera significativa para los actuales niveles de autonomía robótica.

ii. Entornos no estructurados y morfología cambiante

Uno de los mayores retos que enfrenta la autonomía robótica es operar en entornos quirúrgicos dinámicos y no estructurados. A diferencia de los entornos industriales controlados, el cuerpo humano presenta variaciones constantes durante la intervención quirúrgica. Esto incluye desplazamientos de órganos, sangrado, presencia de instrumentos y cambios en la visibilidad debidos al movimiento del endoscopio o la presión de los propios instrumentos. La complejidad de interpretar esta información en tiempo real limita la capacidad de los robots para actuar de manera autónoma sin supervisión humana.

iii. Tejidos deformables

El manejo de tejidos blandos y deformables representa un reto técnico considerable. El seguimiento y manipulación de estos tejidos, como se evidencia en tareas de retracción tisular, requiere algoritmos capaces de predecir y adaptarse a la deformación tridimensional en tiempo real. Si bien se han desarrollado simulaciones y estrategias para minimizar la tensión del tejido y evitar desgarros, la mayoría de las implementaciones exitosas se han limitado a entornos de laboratorio. En situaciones clínicas reales, la elasticidad del tejido y la interferencia de herramientas complica enormemente la automatización de estas maniobras.

Además, la detección autónoma de propiedades mecánicas de los tejidos, como la rigidez, es crucial para tareas como la disección y la palpación. Actualmente, se exploran enfoques tanto con sensores hápticos como sin sensores, aunque todos enfrentan obstáculos importantes relacionados con la precisión, el costo, la esterilización y la integración en sistemas clínicos.

iv. Variabilidad en los procedimientos quirúrgicos

El artículo también destaca cómo la diversidad de procedimientos quirúrgicos y la necesidad de adaptabilidad hacen que el diseño de sistemas autónomos sea especialmente complejo (Attanasio et al., 2021). La autonomía de nivel 2 (autonomía de tareas) y nivel 3 (autonomía condicional) requiere que el robot no solo ejecute subtareas de forma independiente, sino que además pueda ajustar su comportamiento en función del estado actual del procedimiento. Esta variabilidad conlleva un aumento en la complejidad algorítmica y en la cantidad de datos necesarios para entrenar y validar modelos confiables. Por ejemplo, en la sutura automatizada el sistema debe ser capaz de localizar los puntos de entrada y salida, ajustar la tensión del hilo y manejar la posible pérdida de la aguja o enredos del hilo, tareas que aún no han sido completamente resueltas.

En conjunto, los retos que enfrenta la autonomía en la robótica quirúrgica trascienden las limitaciones puramente tecnológicas e involucran dimensiones clave del entorno clínico, la variabilidad biológica y la práctica médica personalizada. La implementación progresiva de sistemas autónomos en cirugía requiere no solo avances en algoritmos de control, percepción y modelado de tejidos, sino también una integración efectiva del conocimiento interdisciplinar que abarque la ingeniería biomédica, las ciencias de la computación, la fisiología humana y la bioética. Abordar esta complejidad de manera rigurosa y colaborativa será fundamental para garantizar el desarrollo de tecnologías que no solo sean técnicamente viables, sino también clínicamente relevantes, seguras y aceptadas por la comunidad médica.

2. Situación actual de la cirugía asistida por computador (CAS).

La cirugía asistida por computador (CAS, por sus siglas en inglés) ha emergido como una de las áreas más transformadoras dentro de la cirugía moderna, al integrar tecnologías avanzadas como la imagen médica, la navegación quirúrgica, el registro espacial, la inteligencia artificial y, especialmente, la robótica. Esta convergencia tecnológica ha dado lugar a un nuevo paradigma en el quirófano, donde los sistemas robóticos no solo complementan la labor del cirujano, sino que se integran como una herramienta sofisticada dentro del equipo quirúrgico.

De acuerdo con diversos estudios (Sanchez-Encinas et al., 2023), ('Cirugía Robótica Tratamiento Cáncer Próstata - Clínica CEMTRO', abril 2025), ('"La cirugía robótica aporta mayor precisión y seguridad en las intervenciones de oncología ginecológica"', abril 2025), la robótica quirúrgica representa una revolución conceptual: aunque en el imaginario colectivo puede entenderse como un "cirujano robótico inteligente" con capacidades autónomas, la

realidad actual es que estos robots actúan principalmente como herramientas avanzadas, bajo un esquema de teleoperación. Esto implica que el control permanece en manos del cirujano, quien se ve beneficiado por una mayor precisión, mejor ergonomía y menor fatiga durante procedimientos complejos.

Según el doctor Julio Mayol (“La cirugía robótica aporta mayor precisión y seguridad en las intervenciones de oncología ginecológica”, abril 2025), este nuevo enfoque quirúrgico implica “una visión de futuro” que exige un cambio conceptual en la forma de abordar la cirugía, convirtiéndola en una actividad “intuitiva, integrada e inteligente”. Por su parte, el pionero Russell Taylor sostiene que la finalidad de la robótica quirúrgica no es reemplazar al cirujano, sino establecer una sinergia en la que ambos—humano y máquina—complementen sus capacidades para lograr una intervención más eficiente de lo que podrían por separado.

Robots como da Vinci (Figura 8), CyberKnife (Figura 9), ROBOdoc o SpineAssist ejemplifican la diversidad de enfoques actuales: desde sistemas grandes y fijos montados en la mesa quirúrgica (table-mounted), hasta sistemas compactos montados directamente sobre el paciente (patient-mounted), o incluso robots móviles y colaborativos que se desplazan por el interior del cuerpo o trabajan en conjunto en tareas específicas.



*Figura 8. Robot quirúrgico Da Vinci.
Fuente (Clinic Robotics 2023)*



*Figura 9. Robot quirúrgico CyberKnife
Fuente (MedlinePlus enciclopedia médica 2024)*

Este avance ha generado también una transformación en la educación médica. Frente al modelo tradicional de aprendizaje quirúrgico basado en la oportunidad clínica, el desarrollo de simuladores quirúrgicos permite ahora replicar escenarios con distintos niveles de complejidad, lo cual mejora la preparación sin poner en riesgo a los pacientes. No obstante, se reconoce que la sensación de realismo en estos simuladores aún es limitada, lo cual representa un área de mejora activa en el campo.

La revolución tecnológica de la CAS está siendo impulsada globalmente. Universidades como la University of California, San Diego, han creado institutos interdisciplinarios de ingeniería médica, mientras que, en España, instituciones como la Universidad Miguel Hernández han desarrollado programas de posgrado en bioingeniería que integran conocimientos en robótica, imagen médica y procesamiento de señales aplicadas a la medicina. La CAS constituye un entorno en constante evolución tecnológica, conceptual y educativa, donde la colaboración entre ingeniería y medicina es esencial. A medida que se desarrollan robots más eficientes, inteligentes y ergonómicos, se espera que el papel del cirujano continúe fortaleciéndose gracias a estas herramientas, ampliando así el alcance de los procedimientos quirúrgicos seguros y precisos.

a. Esquema global CAS

El desarrollo completo de una intervención quirúrgica asistida por computadora puede representarse de forma esquemática, como se muestra en la Figura 10. Este proceso abarca múltiples fases interconectadas: diagnóstico, planificación preoperatoria, ejecución intraoperatoria y evaluación postoperatoria. Cada una de estas etapas incorpora tecnologías específicas que interactúan de manera progresiva para facilitar una intervención precisa, mínimamente invasiva y segura. A lo largo de este ciclo, la calidad de los datos y su adecuada integración juegan un papel fundamental en la precisión del procedimiento quirúrgico. Además, el ciclo se retroalimenta, permitiendo que la información obtenida tras la cirugía contribuya a perfeccionar los procesos anteriores.

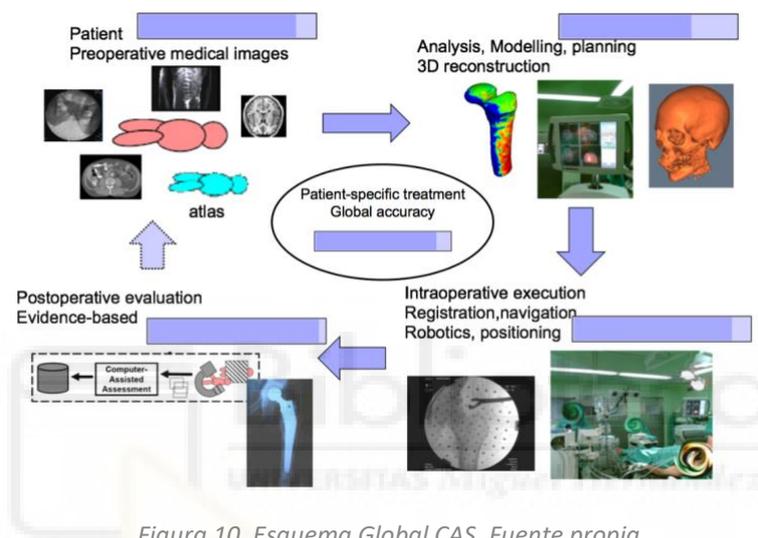


Figura 10. Esquema Global CAS. Fuente propia

En los siguientes apartados se abordará, en primer lugar, la **fase preoperatoria**, centrándose en la adquisición de imágenes médicas y su segmentación para la reconstrucción anatómica. A continuación, se describirá la **fase intraoperatoria**, donde se detallarán dos elementos clave: el registro quirúrgico (proceso de alineación entre los datos preoperatorios y la anatomía real del paciente) y la navegación quirúrgica (tecnologías que permiten guiar instrumentos durante la cirugía). Finalmente, se tratará brevemente la **fase postoperatoria**, orientada a la evaluación de los resultados mediante nuevas imágenes y su aprovechamiento para la mejora continua del sistema.

Etapa preoperatoria

La fase preoperatoria constituye uno de los pilares fundamentales de CAS, ya que en ella se generan y procesan los datos anatómicos esenciales para la planificación quirúrgica. Este proceso comienza con la adquisición de imágenes médicas, que pueden provenir de distintas modalidades como la tomografía computarizada (CT, por sus siglas en inglés), la resonancia magnética (MRI, por sus siglas en inglés) o la ecografía. Cada una de estas técnicas presenta diferentes características en cuanto a resolución espacial, sensibilidad a los tejidos y niveles de ruido, lo cual introduce variabilidad e incertidumbre en la información generada.

Una vez adquiridas, las imágenes deben ser segmentadas, es decir, deben etiquetarse todos los píxeles (2D) o vóxeles (3D) indicando a qué tipo de tejido pertenecen. Esta segmentación es el paso clave que permite reconstruir digitalmente la anatomía del paciente, facilitando una visualización tridimensional que ayuda al cirujano a comprender mejor la disposición espacial de las estructuras anatómicas. Esta reconstrucción no solo permite adaptar la intervención al paciente, sino que también permite anticipar posibles complicaciones quirúrgicas y planificar trayectorias más seguras y precisas.

La segmentación puede realizarse mediante técnicas manuales, semiautomáticas o automáticas. En los métodos manuales, el especialista traza directamente los contornos anatómicos sobre cada corte de imagen, lo cual ofrece gran precisión, pero es altamente demandante en tiempo y depende fuertemente de la experiencia del operador. Por otro lado, las técnicas semiautomáticas, como el crecimiento de regiones (*region growing*) o el algoritmo *watershed*, permiten que el usuario seleccione ciertas zonas de interés y el sistema expanda la segmentación basándose en la intensidad de la imagen o en gradientes de borde. Estas técnicas combinan control humano con eficiencia computacional. Sin embargo, ha sido la segmentación automática la que más ha evolucionado en los últimos años, especialmente mediante el uso de modelos de inteligencia artificial.

Los enfoques más avanzados en segmentación de imágenes biomédicas se basan en redes neuronales convolucionales (CNN), siendo U-Net una de las arquitecturas de referencia debido a su capacidad para capturar tanto el contexto global como los detalles locales de la imagen (Ronneberger et al., 2015). Su uso se ha generalizado en entornos clínicos y de investigación gracias a su robusto desempeño en diversas tareas y modalidades de imagen. Una evolución destacada de este modelo es nnU-Net, una arquitectura autoajutable que adapta automáticamente su configuración (incluyendo preprocesamiento, arquitectura y estrategia de entrenamiento) según las características del conjunto de datos, logrando resultados sobresalientes en numerosos estudios y competiciones (Savjani, 2021). Además, U-Net ha demostrado una eficacia notable en tareas específicas, como la segmentación automática del hígado en imágenes de tomografía computarizada, superando a otros métodos en términos de precisión y consistencia (Araújo et al., 2022).

Sin embargo, aunque la segmentación basada en inteligencia artificial ha mejorado notablemente en precisión y eficiencia, su uso en estructuras anatómicas complejas, como el hígado, aún presenta desafíos. Esto se debe a que muchas regiones presentan intensidades similares (por ejemplo, entre vasos y parénquima hepático), dificultando la discriminación por parte del modelo. Además, estas redes carecen de conocimiento anatómico explícito, por lo que su desempeño en zonas ambiguas o mal representadas en el conjunto de entrenamiento puede verse comprometido. En consecuencia, es común que incluso los modelos más avanzados requieran ajustes manuales para corregir errores o compensar sesgos en los datos de entrenamiento. Así, la supervisión experta sigue siendo un componente crítico del proceso, especialmente en aplicaciones clínicas sensibles.

Para realizar procesos de segmentación biomédica, existe una amplia variedad de herramientas tanto comerciales como de código abierto. Entre estas últimas, 3D Slicer destaca como una de las plataformas más utilizadas en entornos clínicos y de investigación, gracias a su arquitectura modular y su compatibilidad con

segmentación manual, semiautomática y basada en inteligencia artificial (Fedorov et al., 2012). Esta flexibilidad permite adaptar el entorno de trabajo a distintas necesidades, incluyendo la integración de algoritmos personalizados. Otras opciones relevantes, aunque no utilizadas en este trabajo, incluyen Mimics, Amira, ITK-SNAP y librerías como SimpleITK o VTK. También entornos como MATLAB ofrecen herramientas clásicas de segmentación y soporte para redes profundas como U-Net.

La calidad de la segmentación obtenida en esta fase preoperatoria impacta directamente en todas las etapas posteriores del flujo quirúrgico asistido por computadora. Una segmentación precisa permite generar modelos anatómicos fiables, definir zonas de riesgo, planificar trayectorias quirúrgicas óptimas y mejorar la seguridad del procedimiento. A medida que evolucionan las técnicas y herramientas disponibles, la integración de algoritmos inteligentes con supervisión clínica se perfila como el camino más prometedor hacia una segmentación precisa, eficiente y clínicamente relevante.

Etapa intraoperatoria

La etapa intraoperatoria representa uno de los momentos más desafiantes de CAS y, actualmente, constituye uno de los mayores retos tanto para la ingeniería biomédica como para la práctica quirúrgica. Durante esta fase, la precisión en la ejecución de la intervención depende en gran medida de la capacidad del sistema para integrar, en tiempo real, la información anatómica del paciente con la posición de los instrumentos quirúrgicos. Para ello, se combinan tecnologías de registro anatómico y navegación quirúrgica que permiten guiar al cirujano con una referencia espacial continua y fiable (Sabater-Navarro et al., 2013).

i. Registro quirúrgico

El registro quirúrgico es el primer paso crítico dentro del quirófano. Su objetivo es alinear el modelo anatómico generado a partir de imágenes preoperatorias, con la realidad anatómica del paciente. Esta alineación puede lograrse mediante técnicas basadas en marcadores artificiales (fiduciales), que se implantan previamente en el cuerpo del paciente y son fácilmente identificables en las imágenes médicas.

Alternativamente, es posible utilizar puntos anatómicos reconocibles (landmarks naturales), cuya localización se compara entre el modelo tridimensional y el paciente. Un enfoque más avanzado consiste en el registro por superficie, donde se adquiere una nube de puntos de la anatomía del paciente a través de dispositivos de rastreo óptico o electromagnético, y se emplean algoritmos como el *Iterative Closest Point* (ICP) para ajustar estos datos al modelo. Este método ha ganado popularidad por no requerir elementos invasivos y por adaptarse con eficacia al entorno cambiante del quirófano (Sabater-Navarro et al., 2013).

ii. Navegación quirúrgica

Una vez establecido el registro, el sistema de navegación quirúrgica proporciona visualización precisa y en tiempo real de la posición de los instrumentos respecto a las estructuras anatómicas. Para ello, se utilizan tecnologías como la navegación óptica, basada en cámaras infrarrojas y marcadores, y la navegación electromagnética, que rastrea sensores mediante campos magnéticos. La navegación óptica ofrece alta precisión, pero puede verse limitada por obstrucciones visuales, mientras que la electromagnética es más adecuada para procedimientos mínimamente invasivos, aunque sensible a interferencias.

La integración de imagen médica intraoperatoria, mediante modalidades como escáneres, arco en C (C-arm en inglés), MRI o ultrasonido (US), promete mejorar los resultados clínicos, pero su adopción rutinaria enfrenta desafíos relacionados con la ergonomía, la ligereza y la no interferencia en el flujo quirúrgico. Este entorno dinámico requiere dispositivos adaptables que no comprometan la seguridad ni comodidad del equipo. Además, emergen métodos automatizados que combinan planificación activa y modelos probabilísticos para mapear estructuras no visibles. Un ejemplo destacado es el sistema de (Cho et al., 2021), que usa Bayesian Hilbert Maps para actualizar mapas anatómicos en tiempo real mediante movimientos planificados optimizados con algoritmos bayesianos, facilitando la localización precisa de tumores ocultos y avanzando en la automatización y toma de decisiones quirúrgicas.

La evolución de la CAS ha transformado profundamente la concepción, planificación y ejecución de las intervenciones quirúrgicas, desde la fase preoperatoria, donde técnicas avanzadas de imagen y segmentación anatómica potenciadas por inteligencia artificial permiten reconstrucciones precisas y personalizadas, hasta la fase intraoperatoria, en la que el registro espacial, la navegación quirúrgica y la imagen médica en tiempo real mejoran la precisión y seguridad del procedimiento. Si bien aún existen desafíos como la integración ergonómica de estos sistemas, la adaptación a variaciones anatómicas y la validación clínica, el panorama futuro se perfila hacia una sinergia creciente entre la inteligencia humana y la computacional, orientada a optimizar los resultados quirúrgicos sin sustituir el papel del cirujano.

Objetivos

La cirugía laparoscópica hepática representa uno de los mayores retos dentro del ámbito de la cirugía mínimamente invasiva, debido tanto a la complejidad anatómica del hígado como a la alta probabilidad de eventos adversos intraoperatorios, tales como hemorragias o deformaciones tisulares. En este contexto, la integración de tecnologías robóticas no solo permite superar algunas de las limitaciones tradicionales de la laparoscopia, como la falta de ergonomía, la pérdida de visión tridimensional o la elevada curva de aprendizaje, sino que abre nuevas oportunidades para avanzar hacia sistemas quirúrgicos más autónomos, seguros y personalizados.

El presente Trabajo de Fin de Máster se enmarca en el proyecto nacional **L2AST (PID2021- 1225490B-C21)**, financiado por el Ministerio de Ciencia e Innovación, cuyo objetivo principal es el desarrollo e integración de tecnologías que permitan aumentar la autonomía de sistemas robóticos asistidos en cirugía laparoscópica hepática. El enfoque del proyecto se sitúa en el paradigma de colaboración humano-robot, buscando que los robots no solo ejecuten tareas teleoperadas, sino que puedan comprender el estado del campo quirúrgico y adaptarse dinámicamente a las condiciones intraoperatorias mediante procesos de supervisión y replanificación.

El hígado ha sido seleccionado como órgano de referencia dada su relevancia clínica y las dificultades inherentes a su tratamiento quirúrgico. Su gran tamaño, alta vascularización y tendencia a las deformaciones lo convierten en un caso de estudio especialmente exigente, que desafía tanto las capacidades actuales de los sistemas CAS como las de los asistentes robóticos. Estas características lo sitúan en el centro de los objetivos tecnológicos del proyecto L2AST, especialmente en lo referente a la generación de trayectorias adaptativas y la monitorización intraoperatoria.

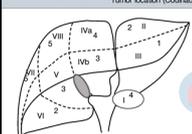
IWATE Criteria																																					
Difficulty index	0	1	2	3	4	5	6	7	8	9	10	11	12																								
Difficulty level	Low			Intermediate			Advanced			Expert																											
Index surgery	Left lateral sectionectomy Simple and small/partial hepatectomy in segment III						Right or left hepatectomy Posterior sectionectomy for segment VII tumor ≥ 3 cm																														
Scoring system																																					
Tumor location (Couinaud segment)							Tumor size																														
 <table border="1"> <thead> <tr> <th>Segment</th> <th>Score</th> </tr> </thead> <tbody> <tr><td>S1</td><td>4</td></tr> <tr><td>S2</td><td>2</td></tr> <tr><td>S3</td><td>1</td></tr> <tr><td>S4a</td><td>4</td></tr> <tr><td>S4b</td><td>3</td></tr> <tr><td>S5</td><td>3</td></tr> <tr><td>S6</td><td>2</td></tr> <tr><td>S7</td><td>5</td></tr> <tr><td>S8</td><td>5</td></tr> </tbody> </table>							Segment	Score	S1	4	S2	2	S3	1	S4a	4	S4b	3	S5	3	S6	2	S7	5	S8	5	<table border="1"> <thead> <tr> <th>Score</th> </tr> </thead> <tbody> <tr><td><3 cm</td><td>0</td></tr> <tr><td>≥ 3 cm</td><td>1</td></tr> </tbody> </table>						Score	<3 cm	0	≥ 3 cm	1
Segment	Score																																				
S1	4																																				
S2	2																																				
S3	1																																				
S4a	4																																				
S4b	3																																				
S5	3																																				
S6	2																																				
S7	5																																				
S8	5																																				
Score																																					
<3 cm	0																																				
≥ 3 cm	1																																				
							Proximity to major vessel*																														
							<table border="1"> <thead> <tr> <th>Score</th> </tr> </thead> <tbody> <tr><td>No</td><td>0</td></tr> <tr><td>Yes</td><td>1</td></tr> </tbody> </table>						Score	No	0	Yes	1																				
Score																																					
No	0																																				
Yes	1																																				
							*Main or second branch of Glisson's tree, major hepatic vein, or inferior vena cava																														
Extent of liver resection							HALS/hybrid		Liver function																												
<table border="1"> <thead> <tr> <th>Extent of liver resection</th> <th>Score</th> </tr> </thead> <tbody> <tr><td>Partial resection</td><td>0</td></tr> <tr><td>Left lateral sectionectomy</td><td>2</td></tr> <tr><td>Segmentectomy</td><td>3</td></tr> <tr><td>Sectionectomy and more</td><td>4</td></tr> </tbody> </table>							Extent of liver resection	Score	Partial resection	0	Left lateral sectionectomy	2	Segmentectomy	3	Sectionectomy and more	4	<table border="1"> <thead> <tr> <th>HALS/hybrid</th> <th>Score</th> </tr> </thead> <tbody> <tr><td>No</td><td>0</td></tr> <tr><td>Yes</td><td>-1</td></tr> </tbody> </table>		HALS/hybrid	Score	No	0	Yes	-1	<table border="1"> <thead> <tr> <th>Liver function</th> <th>Score</th> </tr> </thead> <tbody> <tr><td>Child Pugh A</td><td>0</td></tr> <tr><td>Child Pugh B</td><td>1</td></tr> </tbody> </table>				Liver function	Score	Child Pugh A	0	Child Pugh B	1			
Extent of liver resection	Score																																				
Partial resection	0																																				
Left lateral sectionectomy	2																																				
Segmentectomy	3																																				
Sectionectomy and more	4																																				
HALS/hybrid	Score																																				
No	0																																				
Yes	-1																																				
Liver function	Score																																				
Child Pugh A	0																																				
Child Pugh B	1																																				

Figura 11. Criterio IWATE. Fuente (Barron et al., 2022).

Con el fin de evaluar las capacidades técnicas del sistema desarrollado en un entorno controlado, se ha llevado a cabo la planificación quirúrgica de una resección del segmento III del hígado (sector lateral izquierdo). Esta intervención, clasificada como de baja complejidad según el sistema de puntuación de Iwate (Barron et al., 2022), Figura 11, ha sido elegida estratégicamente por su menor riesgo clínico, lo que permite focalizar la validación en

aspectos clave del proyecto L2AST, como la precisión en la generación de trayectorias autónomas y la capacidad del sistema para adaptarse a condiciones intraoperatorias variables sin interferencias derivadas de escenarios quirúrgicos de alta complejidad.

Este trabajo se alinea específicamente con el subapartado de **Medicina Personalizada**, abordando tres ejes fundamentales del flujo quirúrgico: el procesamiento avanzado de imagen médica, la planificación preoperatoria personalizada a partir de modelos anatómicos deformables y la ejecución robótica asistida, con vistas a una cirugía adaptativa centrada en las particularidades anatómicas de cada paciente. Además, se integra en la línea de investigación de Interfaces *Persona-Máquina*, al ser una herramienta que facilitará la integración entre los datos clínicos y los módulos robóticos, contribuyendo a una mayor autonomía y cooperación en el quirófano.

Con todo, los objetivos de este trabajo se recogen en los siguientes puntos:

1. Segmentación semiautomática de hígado

Uno de los principales desafíos en cirugía hepática es la obtención de una representación anatómica precisa del hígado y sus estructuras adyacentes, que permita al cirujano planificar el procedimiento con la máxima seguridad. Este objetivo cobra especial relevancia en el contexto de la cirugía mínimamente invasiva, donde el acceso visual directo está limitado y una planificación adecuada depende en gran medida de la calidad de los modelos anatómicos disponibles. En este sentido, el primer objetivo de este trabajo consiste en generar una máscara volumétrica tridimensional del órgano de interés, el hígado, a partir de imágenes de tomografía computarizada (CT). Dicha máscara permitirá reconstruir de forma precisa la geometría del hígado, incluyendo elementos relevantes como vasos sanguíneos, vena cava y posibles lesiones. La obtención de este modelo personalizado constituye un paso esencial dentro del flujo de trabajo, ya que sienta las bases para una planificación quirúrgica adaptada a la anatomía específica de cada paciente, favoreciendo un enfoque de medicina personalizada y aumentando el control espacial previo a la intervención.

2. Planificación quirúrgica en 3D

Una vez obtenido el modelo tridimensional segmentado del hígado, el siguiente paso dentro del flujo quirúrgico consiste en definir de forma precisa las trayectorias que deberá seguir el instrumental durante la intervención. Por tanto, el segundo objetivo de este trabajo es el desarrollo de una herramienta de planificación quirúrgica sobre entornos tridimensionales, que permita al cirujano establecer puntos de entrada, orientaciones deseadas y rutas seguras para el abordaje laparoscópico. Esta planificación debe estar basada en el modelo anatómico personalizado generado previamente y contemplar tanto las restricciones clínicas como la geometría específica del paciente. El objetivo no es solo facilitar la visualización del acceso quirúrgico, sino estructurar la información espacial de forma que pueda ser interpretada y ejecutada por un sistema robótico. Así, la planificación queda digitalizada y estructurada en un formato que conecta directamente el entorno virtual con la futura ejecución

automatizada de la intervención.

3. Transferencia de la planificación quirúrgica al procedimiento quirúrgico.

La última etapa del flujo propuesto consiste en trasladar la planificación virtual, realizada sobre el modelo 3D del paciente, al entorno físico del quirófano para su ejecución mediante un sistema robótico. Este paso es crucial para cerrar el ciclo entre la fase de planificación preoperatoria y la intervención real, y requiere establecer una correspondencia espacial precisa entre el entorno virtual y el espacio físico del quirófano. Para ello, se recurre a técnicas de registro y al uso de sistemas de referencia compartidos entre los diferentes dispositivos implicados. Uno de los principales retos en esta fase es garantizar que la trayectoria definida en el entorno virtual se reproduzca con exactitud en el mundo real. Este objetivo exige tener en cuenta los distintos sistemas de coordenadas que intervienen: el del modelo anatómico, el del robot quirúrgico y el del entorno clínico. La clave para una correcta transferencia reside en el uso de herramientas matemáticas que permiten convertir posiciones y orientaciones de un sistema de referencia a otro.

Este TFM presenta un flujo de trabajo integrado dentro del marco de la medicina personalizada. El objetivo final de esta integración es mejorar la seguridad, precisión y eficacia de las intervenciones hepáticas asistidas por robot. Al haber desarrollado y conectado cada una de estas etapas, se espera que el robot sea capaz de ejecutar la trayectoria quirúrgica definida con alta fidelidad, tanto en posición como en orientación. Esto permitiría validar que todo el proceso funciona de manera coherente y efectiva, demostrando el potencial de esta aproximación para su futura aplicación clínica.

Para abordar de forma estructurada los objetivos planteados, el desarrollo del trabajo se organiza en dos grandes bloques experimentales. El primero se centra en la **segmentación semiautomática del hígado**, en línea con el primer objetivo del proyecto, y describe el flujo de trabajo necesario para generar modelos anatómicos tridimensionales a partir de imágenes médicas. El segundo bloque, correspondiente a la **planificación quirúrgica** asistida, abarca los objetivos segundo y tercero, y detalla tanto el diseño e implementación de módulos específicos en 3D Slicer como la transferencia de la planificación al entorno físico del quirófano mediante ejecución robótica. Esta organización permite analizar de forma clara y progresiva cada una de las fases que componen el sistema propuesto, desde la generación de modelos hasta su aplicación práctica en cirugía laparoscópica hepática asistida por robot.

Procedimiento experimental

Segmentación semiautomática

Tal como se ha descrito anteriormente en el apartado de **Etapas preoperatorias**, la segmentación anatómica es un paso clave en la planificación quirúrgica asistida por computador, ya que permite extraer y representar con precisión las estructuras relevantes del paciente a partir de sus imágenes médicas. En este contexto, los métodos semiautomáticos ofrecen una solución intermedia entre la precisión de la segmentación manual y la eficiencia de los enfoques completamente automáticos, permitiendo al usuario intervenir y corregir el proceso cuando sea necesario. El resultado es un flujo de trabajo flexible que mantiene la supervisión experta sin exigir el esfuerzo que supone una segmentación completamente manual.

Con el fin de facilitar la comprensión del trabajo realizado, a continuación se describen de forma ordenada las distintas etapas seguidas hasta alcanzar el primer objetivo. En primer lugar, se presentará el uso del módulo Segment Editor de 3D Slicer, una de las herramientas más utilizadas para la segmentación semiautomática en imágenes médicas. Una vez comprendido en profundidad el proceso de segmentación y adquirida experiencia en el uso de esta plataforma, se decidió ampliar el enfoque del estudio. Para ello, se realizó una comparativa de distintos métodos de segmentación automática basados en redes neuronales disponibles públicamente. Este análisis sentó las bases para el desarrollo de un algoritmo propio, se diseñó, entrenó y validó una red neuronal personalizada para la segmentación del hígado, y posteriormente se ajustó manualmente su salida para optimizar la precisión en casos clínicos reales.

Evaluación de los diferentes algoritmos de segmentación en Slicer

Durante el desarrollo del presente trabajo se ha llevado a cabo una evaluación de los principales algoritmos de segmentación integrados en el módulo *Segment Editor* de 3D Slicer (Figura 12), con el objetivo de determinar su aplicabilidad y rendimiento en la segmentación semiautomática de estructuras hepáticas. Cada herramienta fue analizada en función de su metodología, su capacidad de adaptación a la anatomía del hígado, su facilidad de uso en entornos clínicos reales y la calidad del resultado obtenido a partir de imágenes de tomografía computarizada ('Segment editor — 3D Slicer documentation', octubre 2024).

En este contexto, se emplearon distintos algoritmos según el tipo de estructura a segmentar. En primer lugar, se utilizó la herramienta *Draw* para trazar manualmente los contornos del hígado y la vena cava en cortes seleccionados, generando etiquetas iniciales que sirvieron de base para el proceso. A partir de estos contornos, la herramienta *Fill between slices* permitió interpolar la segmentación en el resto del volumen, generando una reconstrucción tridimensional continua especialmente útil en estructuras con geometría definida.

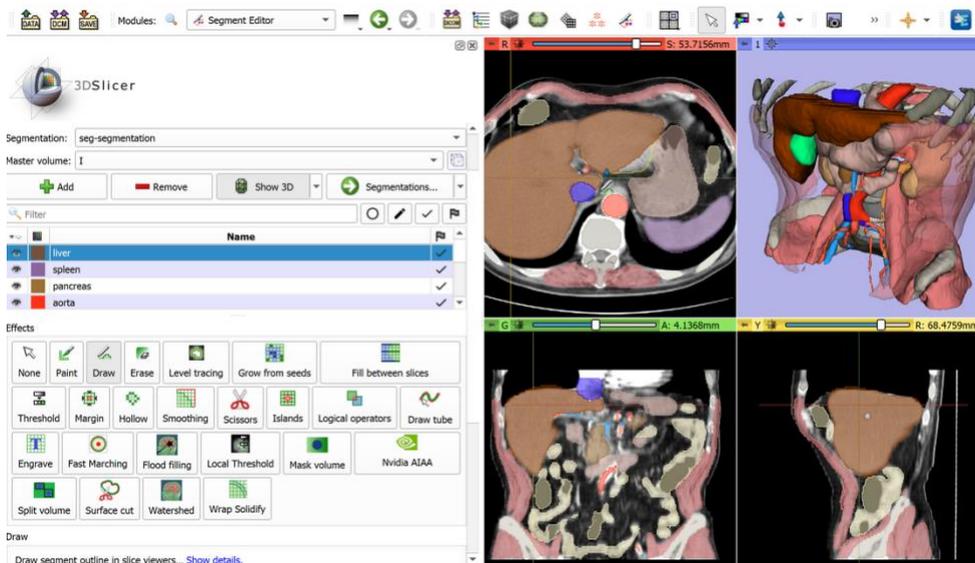


Figura 12. Interfaz Segment Editor, 3D Slicer. Fuente (Barron et al., 2022).

Para la detección de vasos y tumores se aplicó el algoritmo *Threshold*, que permite extraer regiones dentro de un rango de intensidades determinado. Se ajustaron manualmente estos rangos según la estructura objetivo, utilizando valores altos para vasos y bajos para tumores. Posteriormente, se empleó *Islands* para aislar únicamente las regiones conectadas de mayor tamaño, eliminando fragmentos pequeños o artefactos generados durante el umbralado.

El refinamiento de las segmentaciones se realizó mediante *Logical Operators*, que facilitaron la combinación o sustracción de etiquetas según fuera necesario, especialmente en zonas de solapamiento entre estructuras adyacentes. Además, la herramienta *Scissors* permitió realizar ajustes manuales localizados, corrigiendo imperfecciones que no habían sido resueltas automáticamente. Finalmente, se aplicó *Smoothing* (modo Gaussian) para suavizar la superficie de los volúmenes segmentados, mejorando la continuidad espacial y la visualización anatómica.

Esta combinación de herramientas manuales y semiautomáticas ofreció un flujo de trabajo flexible y preciso, adaptado a las particularidades de las estructuras hepáticas y al nivel de contraste presente en cada volumen analizado.

Estudio comparativo de redes neuronales para segmentación anatómica en imágenes médicas

Dentro del campo de la Inteligencia Artificial (AI, por sus siglas en inglés), dos conceptos fundamentales orientan la creación de sistemas inteligentes: el Aprendizaje Automático (*Machine Learning*) y el Aprendizaje Profundo (*Deep Learning*). Ambos enfoques están interrelacionados y permiten a los sistemas informáticos mejorar su rendimiento en tareas específicas a medida que procesan más datos.

Por un lado, el Aprendizaje Automático (*Machine Learning*), se centra en desarrollar algoritmos capaces

de aprender a partir de datos estructurados o no estructurados, con aplicaciones comunes en clasificación, regresión y predicción. Este enfoque ha sido ampliamente utilizado en diversos campos científicos e industriales (Cruz Díaz et al., 2010). Mientras que el Aprendizaje Profundo (*Deep Learning*) representa una subárea del aprendizaje automático que se basa en redes neuronales artificiales con múltiples capas (*deep neural networks*). Estas redes son capaces de aprender representaciones jerárquicas y complejas de los datos, siendo especialmente eficaces en tareas como el reconocimiento de imágenes médicas, la segmentación de órganos y tejidos, o el análisis de texto clínico (Orellana Guevara, 2020).

En el ámbito de la tomografía computarizada (CT), el uso de *Deep Learning* para la segmentación automática de estructuras como el hígado, las venas hepáticas o lesiones tumorales ha experimentado un crecimiento exponencial. Esta expansión se ha visto favorecida por la disponibilidad de bases de datos públicas, la mejora del hardware computacional y el desarrollo de librerías específicas para el procesamiento de datos médicos. Entre las arquitecturas más extendidas se encuentra la U-Net y sus múltiples variantes, ampliamente utilizadas en tareas de segmentación de hígado, pulmones o cerebro, gracias a su capacidad para capturar tanto el contexto global como los detalles locales de la imagen.

Con el fin de contextualizar el estado actual de la segmentación automática en imágenes médicas, se llevó a cabo una revisión exploratoria de distintos trabajos científicos, repositorios públicos y plataformas especializadas. Esta revisión permitió identificar enfoques basados en redes neuronales convolucionales tridimensionales aplicados a la segmentación hepática, tanto de órganos como de lesiones tumorales. Entre las propuestas analizadas se encuentran arquitecturas representativas como 3D U-Net (Ellis & Aizenberg, 2021), variantes híbridas orientadas a la segmentación de tumores y modelos de dos etapas que combinan localización y segmentación (Meng, Zhang, & Bu, 2021). Además, este análisis comparativo sirvió como base para seleccionar las estrategias más adecuadas para el caso específico de la cirugía laparoscópica hepática y fundamentar el desarrollo posterior de una red neuronal personalizada.

En términos de implementación técnica, dos frameworks dominan el panorama actual del desarrollo de redes neuronales: TensorFlow/Keras y PyTorch. Si bien TensorFlow ha sido durante años el estándar en entornos empresariales por su ecosistema integrado y su escalabilidad, PyTorch ha ganado una posición preponderante en la comunidad investigadora. Su naturaleza más intuitiva, la facilidad para depurar modelos complejos y su orientación a objetos hacen que PyTorch sea especialmente útil en proyectos que requieren flexibilidad y personalización. Esta preferencia ha llevado a que muchas librerías de vanguardia se construyan directamente sobre PyTorch, permitiendo un acceso más ágil a innovaciones recientes y facilitando la reproducción de experimentos académicos.

Además, una de estas librerías especializadas es MONAI (Medical Open Network for AI), desarrollada específicamente para el procesamiento de imágenes médicas. MONAI ofrece un entorno robusto y

altamente configurable, que permite implementar pipelines completos de segmentación incluyendo preprocesado, entrenamiento, validación y evaluación con métricas clínicas como Dice Similarity Coeficiente, Hausdorff Distance y Volumetric Overlap Error. Esta librería no solo facilita el trabajo técnico, sino que también permite una rápida integración con herramientas clínicas como 3D Slicer y soporte nativo para formatos como NIfTI, elementos clave cuando se trabaja con CT hepáticas.

Como se ha comentado anteriormente, la segmentación del hígado plantea retos particulares debido a la alta variabilidad anatómica entre pacientes, la baja resolución en ciertas regiones y la presencia de lesiones que alteran la morfología esperada. Si bien modelos 2D como la U-Net original resultan eficaces en cortes axiales, no capturan adecuadamente la continuidad espacial tridimensional. Por esta razón, versiones 3D como 3D U-Net o V-Net son preferibles en contextos volumétricos. Modelos más recientes, como nnU-Net, automatizan el pipeline completo y se adaptan de forma dinámica a las características del conjunto de datos, mostrando resultados sobresalientes en múltiples benchmarks. No obstante, su implementación requiere altos recursos computacionales y tiempos de entrenamiento prolongados. En cambio, arquitecturas como las integradas en MONAI ofrecen un equilibrio más favorable entre rendimiento y eficiencia, lo que las convierte en candidatas especialmente adecuadas para proyectos como el presente, que requieren precisión clínica junto con tiempos razonables de entrenamiento e integración.

Diseño e implementación de una red neuronal 3D U-Net

Durante el desarrollo de este trabajo, se emplearon redes neuronales convolucionales profundas para la segmentación médica, utilizando específicamente una arquitectura 3D U-Net implementada con la librería MONAI sobre PyTorch. Esta elección se fundamentó en una evaluación previa de distintas opciones, decantándose por PyTorch debido a su mayor flexibilidad, control en el diseño de modelos y mejor integración con entornos de investigación en comparación con alternativas como Keras. Por otro lado, MONAI, diseñada específicamente para tareas de imagen médica, facilita la implementación eficiente y estructurada de pipelines completos de entrenamiento, validación y evaluación.

Para entrenar la red se utilizó el conjunto de datos del Liver Tumor Segmentation Challenge 2017 (LiTS17) (Bilic et al., 2023), una iniciativa que promueve el desarrollo de métodos automáticos de segmentación hepática. Este dataset incluye más de un centenar de estudios clínicos de tomografía computarizada abdominal en formato 3D, acompañados de segmentaciones manuales expertas del hígado y de tumores hepáticos. Su uso se ha consolidado como un estándar de referencia en el ámbito de la investigación en segmentación médica, ya que permite comparar algoritmos en condiciones realistas y de forma objetiva.

La arquitectura diseñada para la realización de este proyecto (Figura 13) se basa en una red U-Net tridimensional configurada para recibir volúmenes con un único canal de entrada y generar

segmentaciones multiclase con tres categorías de salida, correspondientes a fondo, hígado y tumor. La red cuenta con cuatro niveles jerárquicos, donde se duplica progresivamente el número de filtros (16, 32, 64, 128). Se incorporan bloques residuales y operaciones de reducción espacial ($\text{strides}=(2, 2, 2)$). La normalización se realiza mediante capas InstanceNorm, adaptadas a datos volumétricos. Para el entrenamiento se utilizó la función de pérdida combinada DiceCELoss, que integra el coeficiente de Dice y la entropía cruzada, mientras que la métrica principal de evaluación fue el Dice medio. Esta configuración permite extraer patrones anatómicos relevantes con buena fidelidad espacial.

```
model = UNet(  
    spatial_dims=3,  
    in_channels=1,  
    out_channels=3,  
    channels=(16, 32, 64, 128),  
    strides=(2, 2, 2),  
    num_res_units=1,  
    norm=Norm.INSTANCE  
) .to(device)
```

Figura 13. Estructura modelo Monai. Fuente propia

Para garantizar que los volúmenes de entrada cumplieran con los requisitos del modelo, se diseñó un pipeline de preprocesamiento específico utilizando MONAI. Este proceso comienza con la adición explícita del canal en las imágenes y sus máscaras correspondientes. A continuación, se aplica una interpolación trilineal para homogeneizar la resolución espacial a un tamaño de vóxel de $0.7735 \times 0.7735 \times 1.3096$ mm, utilizando interpolación bilineal en las imágenes y nearest-neighbor en las etiquetas. Posteriormente, las intensidades se normalizan y los datos se transforman en tensores con los tipos requeridos por PyTorch. Este preprocesado asegura que los datos de entrada estén estandarizados, lo que mejora la estabilidad y el rendimiento del entrenamiento.

Para garantizar la consistencia en los datos de entrenamiento, se seleccionaron 20 volúmenes con una profundidad cercana a la media global del conjunto (valor medio: 447.62). Esta selección permitió homogeneizar el conjunto de entrenamiento y reducir la variabilidad estructural entre muestras, lo cual es especialmente importante en modelos tridimensionales como U-Net, donde las diferencias de tamaño pueden afectar significativamente el aprendizaje.

Uno de los principales desafíos en el procesamiento de redes 3D es el manejo de volúmenes con dimensiones variables, ya que pueden generar incompatibilidades en las capas convolucionales. Inicialmente se consideró el uso de *padding* para uniformizar la profundidad, pero esta aproximación introduce regiones vacías que podrían distorsionar la anatomía real y afectar el aprendizaje. Como alternativa, se implementó una estrategia de interpolación trilineal dentro del pipeline de MONAI, que ajusta los volúmenes a un tamaño estándar de $512 \times 512 \times 512$. Este método preserva la coherencia espacial al calcular valores intermedios basados en los ocho vóxeles circundantes, evitando artefactos artificiales. Esta configuración constituye el modelo diseñado y entrenado para el proyecto. En la

sección de resultados, se analizarán y evaluarán las segmentaciones obtenidas a partir de este modelo.

Planificación quirúrgica

Tras la explicación experimental del procedimiento de segmentación que permitió obtener una máscara volumétrica precisa del hígado, se da paso a la descripción experimental de la etapa de planificación quirúrgica, en la que se definen las trayectorias que el instrumental deberá seguir durante la intervención. Esta fase involucra tanto herramientas de software como componentes físicos y de comunicación, distribuidos en dos escenarios complementarios: el entorno virtual, basado en el software 3D Slicer, y el entorno físico, compuesto por el robot colaborativo UR3e. Para poder relacionar ambos entornos, es imprescindible realizar un procedimiento de registro espacial entre sistemas de referencia, que permita establecer la correspondencia entre el sistema de coordenadas virtual (del modelo segmentado en 3D Slicer) y el sistema físico del robot. Una vez definido este registro, se implementa un sistema de comunicación basado en ROS que posibilita la transferencia y sincronización de la planificación quirúrgica desde el entorno virtual hacia el entorno físico, garantizando que el robot UR3e siga las trayectorias previamente definidas.

A continuación, se describen los elementos experimentales que intervienen en esta etapa, los cuales permiten avanzar en el cumplimiento de los objetivos 2 y 3 de este trabajo.

Desarrollo de módulos personalizados en Python para 3D Slicer

Además de ofrecer potentes herramientas para la segmentación y visualización de imágenes médicas, 3D Slicer, también permite la creación de módulos personalizados. Esta personalización es clave en investigación, donde se requieren herramientas específicas no incluidas en los módulos estándar. En línea con el segundo objetivo del proyecto, se desarrolla una herramienta de planificación quirúrgica en 3D que permite al cirujano definir puntos de entrada, orientaciones y rutas seguras para abordajes laparoscópicos, implementando un módulo que genera estas trayectorias.

Estos módulos integran tanto la lógica de procesamiento como la interfaz gráfica, siguiendo una estructura estándar compuesta por la clase del módulo, la clase del widget y la clase de lógica, lo que facilita un desarrollo ordenado, reutilizable y la separación entre cálculo e interfaz.

La creación de nuevos módulos se inicia a través de herramientas integradas como el *Extension Wizard*, Figura 14, que genera automáticamente la estructura base del módulo. Esta estructura incluye los archivos .py necesarios, junto con un archivo .ui editable en Qt Designer, desde donde se puede construir la interfaz gráfica sin necesidad de codificación manual. En versiones recientes como la 5.8.0, el sistema añade automáticamente las rutas de los módulos al entorno de Slicer, facilitando así el proceso de carga y prueba.

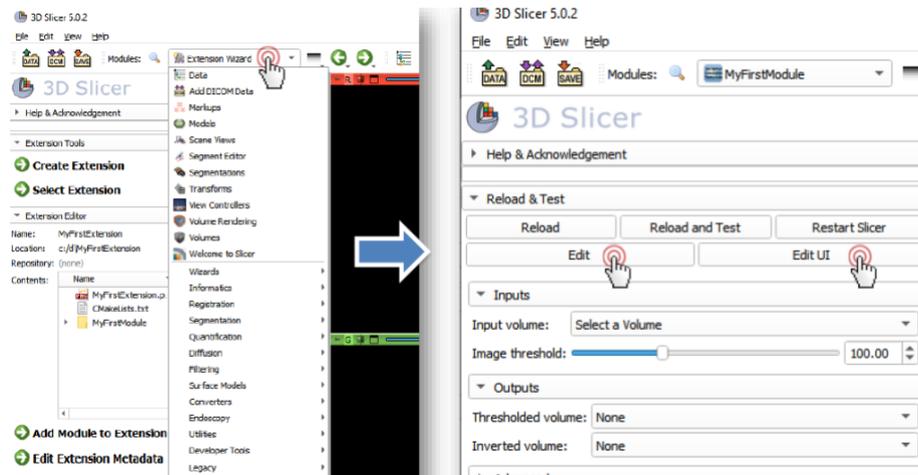


Figura 14. Creación módulos en 3D Slicer. Fuente propia.

Dentro de este entorno, el uso de nodos MRML (Medical Reality Markup Language) permite una comunicación estructurada entre módulos, facilitando la actualización dinámica de parámetros, el seguimiento en tiempo real y el almacenamiento persistente de configuraciones. El desarrollo se apoya en entornos como Visual Studio Code o PyCharm y la consola Python integrada, que permiten probar y depurar funciones de forma interactiva.

Una vez desarrollado y probado, un módulo puede ser empaquetado y distribuido mediante el *Extension Manager* de Slicer o compartido públicamente a través de repositorios como GitHub, siguiendo la filosofía open-source del proyecto. Esta arquitectura modular, abierta y personalizable hace que 3D Slicer sea una plataforma especialmente adecuada para el desarrollo de soluciones clínicas avanzadas, donde es necesario adaptar el software a casos de uso concretos.

En el contexto de este trabajo, 3D Slicer representa una solución óptima para abordar el objetivo de planificación quirúrgica, ya que permite trabajar sobre modelos anatómicos segmentados, incorporar módulos personalizados y estructurar trayectorias quirúrgicas interpretables por sistemas robóticos. Su capacidad para manipular modelos 3D, definir puntos de acceso y calcular orientaciones en un entorno programable facilita la creación de trayectorias precisas y adaptadas a la anatomía del paciente. Esto hace de Slicer una herramienta clave en entornos clínicos que requieren alta personalización, trazabilidad y conexión con plataformas robóticas externas. En el apartado de resultados, se presentan las funcionalidades implementadas en el módulo desarrollado a lo largo del trabajo, junto con la visualización del resultado obtenido tras su ejecución.

Una vez descrito el procedimiento experimental para obtener la trayectoria en el entorno virtual, se presentan los materiales y métodos correspondientes al último objetivo del proyecto. Esta sección detalla las características de la sala de cirugía donde se llevará a cabo el experimento, con especial énfasis en el robot utilizado, y expone el proceso de registro necesario para transferir la planificación virtual al entorno real del quirófano.

Infraestructura experimental: sala de cirugía robótica

El entorno de trabajo corresponde a la sala de cirugía robótica (Figura 15), perteneciente al grupo Medical Robotics, ubicada en el edificio de Ingeniería Biomédica de la Universidad Miguel Hernández. Esta sala está equipada con dos brazos robóticos colaborativos, modelos UR3e y UR5e, ambos montados sobre guías lineales que amplían su alcance operativo. Además, cuenta con un sistema de captura de movimiento OptiTrack, instalado en el techo, que permite el seguimiento espacial preciso en tiempo real de los elementos presentes en el entorno. En el centro de la sala se encuentra un sensor de fuerza montado sobre una estructura metálica, que funciona como superficie de trabajo común para ambos robots. Sobre esta superficie se colocará el órgano de interés, en este caso, el hígado, actuando como referencia física durante los procedimientos. Para asegurar una correcta integración y coordinación entre los distintos dispositivos, se han definido varios sistemas de coordenadas: el sistema global (World), los sistemas asociados a cada guía lineal y robot, y el correspondiente al sensor de fuerza.

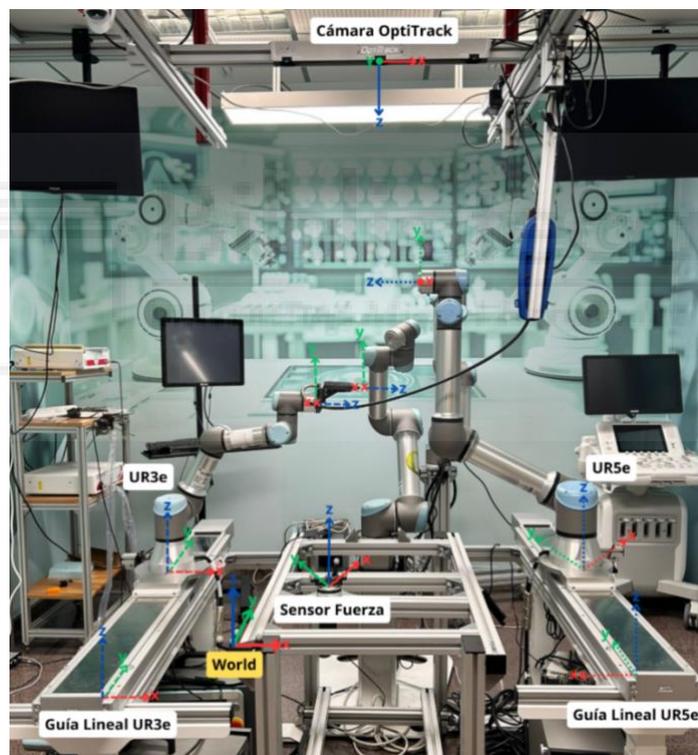


Figura 15. Sala de cirugía robótica. Fuente propia

Con el objetivo de llevar a cabo un registro quirúrgico preciso, resulta imprescindible conocer con exactitud la posición y orientación de la herramienta quirúrgica acoplada al efector final del robot, en relación con el sistema de coordenadas global del quirófano.

Para ello, se define un sistema de referencia global, denominado World, situado en un punto fijo del entorno, concretamente en una de las esquinas de la mesa de operaciones. Este sistema actúa como marco de referencia común a partir del cual se pueden expresar las coordenadas del resto de elementos presentes en la sala. De esta manera, se garantiza que todos los dispositivos compartan un sistema de

referencia unificado, lo cual es fundamental para coordinar tareas como la localización del efector final del robot o la aproximación de la herramienta a un objeto detectado por el sistema de visión. Es importante destacar que el sistema World debe estar dentro del campo de visión del sistema OptiTrack, ya que su localización será determinada mediante este sistema de captura de movimiento.

Una vez establecido el sistema World, se define una cadena de transformaciones homogéneas que permite relacionar los distintos sistemas de coordenadas del entorno con respecto a este origen común. Estas transformaciones se expresan mediante matrices de transformación homogénea y permiten describir la posición y orientación relativa entre los elementos del sistema.

Cabe señalar que, aunque en la sala se dispone de dos brazos robóticos (UR3e y UR5e), en el presente trabajo se centra el análisis exclusivamente en el modelo UR3e, por ser el dispositivo principal utilizado. No obstante, el procedimiento descrito sería aplicable de forma análoga al robot UR5e.

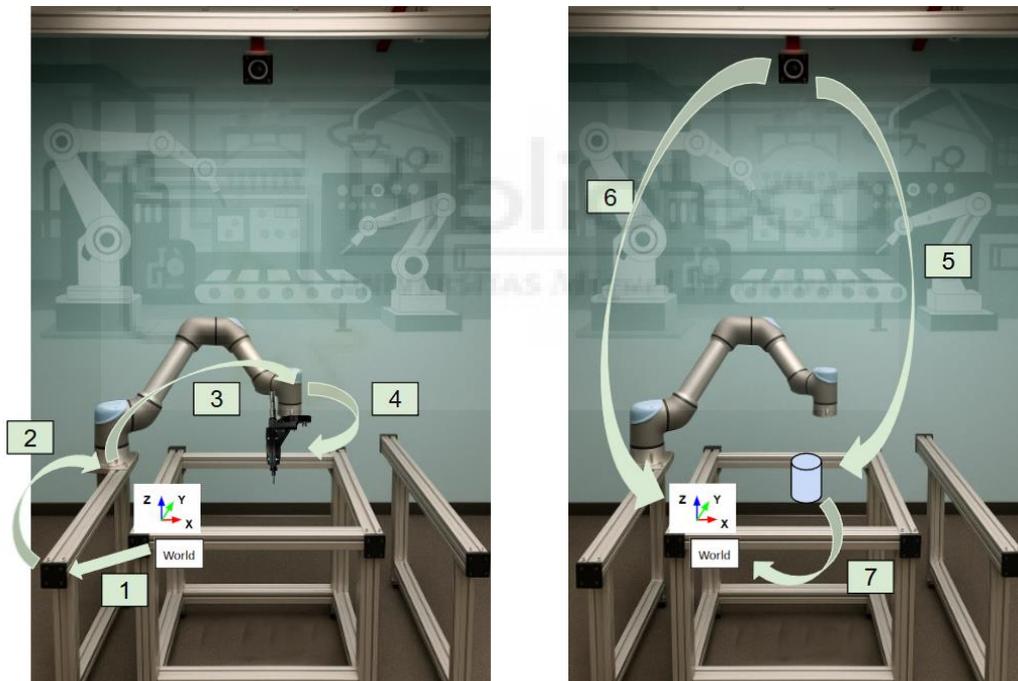


Figura 16. Transformaciones sala de cirugía robótica. Fuente propia

Siguiendo el esquema de flechas de la Figura 16, vamos a ir viendo la matriz de transformación para cada transformación:

➤ Transformación 1: Matriz World-guía lineal

La primera transformación establece la relación entre el sistema de referencia global (World, W) y el sistema asociado a la guía lineal (G) sobre la que se desplaza el robot. Esta guía se encuentra desplazada una distancia fija de 200 mm en el eje X con respecto al origen del sistema World. En el eje Y, la guía abarca desde $y = -661,52$ mm (posición del motor) hasta $y = 172,68$ mm, por lo que su posición en este

eje se define mediante la expresión $172,68 - y$ (mm), donde y es la posición del robot a lo largo de la guía.

En cuanto al eje Z, al haberse nivelado la guía con la mesa de operaciones (donde se sitúa el sistema World), se establece una altura relativa de 66,7 mm con respecto al cero de la guía. Por tanto, su posición en Z se determina mediante la expresión $66,7 + z$ (mm), siendo z la altura respecto al origen de la guía. Dado que no existe rotación entre ambos sistemas, esta transformación es puramente traslacional y, por tanto, la matriz correspondiente será una matriz de transformación homogénea con componentes únicamente de traslación.

$${}^w A_G = \begin{pmatrix} 1 & 0 & 0 & 220 \\ 0 & 1 & 0 & 172.68 - y \\ 0 & 0 & 1 & 66.7 + z \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

➤ Transformación 2: Matriz guía lineal – robot base

La siguiente transformación permite establecer la relación entre el sistema de referencia de la guía lineal (G), sobre la que se desplaza el robot, y el sistema de referencia de la base del robot (R_b). El robot se encuentra montado sobre una plataforma con un espesor de 30 mm, lo que implica un desplazamiento en el eje Z que debe ser considerado en la matriz de transformación. Además, el punto de la guía se encuentra en la esquina de esta, mientras que la base del robot se encuentra justo en el medio de la guía, por lo que existe un desplazamiento en el eje X de 75 mm.

Además, el sistema de coordenadas de la base del robot presenta una rotación de -45° respecto al sistema global (World) y, por tanto, también respecto al sistema asociado a la guía (Figura 17). Esta rotación debe ser incluida en la matriz, que contendrá tanto una componente traslacional como rotacional.

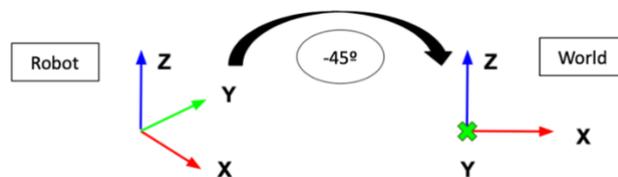


Figura 17. Sistemas de referencia de la base del robot y del World. Fuente propia

Por tanto, la matriz de transformación será:

$${}^G A_{R_b} = \begin{pmatrix} \cos(-45^\circ) & \text{sen}(-45^\circ) & 0 & -75 \\ \text{sen}(-45^\circ) & \cos(-45^\circ) & 0 & 0 \\ 0 & 0 & 1 & 30 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

➤ Transformación 3: Matriz base robot – efector final

Una vez definido el sistema de referencia en la base del robot (R_b), la posición y orientación del efector final (EF) se obtienen a través de la cinemática directa que proporciona el propio robot. Esta transformación, que relaciona la base con el efector final, es de carácter dinámico y se actualiza en tiempo real conforme el robot se desplaza.

Los datos necesarios para construir esta matriz se obtienen mediante el sistema de control del robot, a través del *Teach Pendant* o por medio de la interfaz proporcionada por ROS. El robot proporciona esta información en forma de un vector de rotación, el cual debe ser convertido a una matriz de rotación para su uso en una matriz de transformación homogénea. Esta conversión se realizó mediante una función implementada en Matlab (Figura 18). Matlab es un entorno de programación y cálculo numérico ampliamente utilizado en ingeniería y ciencia. La función mostrada (Figura 18) convierte un vector de rotación (formato ángulo-eje) en su correspondiente matriz de rotación 3x3, facilitando su integración en transformaciones homogéneas.

```
function R = vectorToRotationMatrix(r)
    theta = norm(r);
    if theta < eps
        R = eye(3);
        return;
    end
    k = r / theta;
    K = [ 0 -k(3) k(2);
         k(3) 0 -k(1);
        -k(2) k(1) 0 ];
    R = eye(3) + sin(theta) * K + (1 - cos(theta)) * K^2;
end
```

Figura 18. Función Matlab, transformación rotacional. Fuente propia

Por tanto, la matriz de transformación que relaciona la base del robot con su efector final se expresa como:

$${}^{R_b}A_{EF} = \begin{pmatrix} R_{11} & R_{21} & R_{31} & x \\ R_{21} & R_{22} & R_{32} & y \\ R_{31} & R_{23} & R_{33} & z \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

donde \mathbf{R} representa la matriz de rotación obtenida a partir del vector proporcionado por el robot, y (x,y,z) corresponden a la posición del efector final en el sistema de referencia de la base. Se mantiene la notación genérica \mathbf{R}_{ij} para indicar que los valores dependen del estado dinámico del robot.

➤ Transformación 4: Matriz efector final – herramienta

Sin embargo, el punto activo del sistema no se encuentra en el efector final (EF), sino en la herramienta quirúrgica (tool) acoplada a él. Por esta razón, se emplea una transformación adicional que relaciona el efector final con la herramienta real. Para ello, se midieron las dimensiones y la orientación de la herramienta (Figura 19), obteniendo la matriz de transformación. A modo de ejemplo, se toma como

referencia una herramienta tipo dremel (Figura 20), herramienta de uso común en intervenciones experimentales por su tamaño compacto y facilidad de manejo.

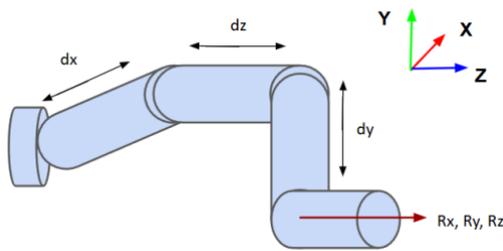


Figura 19. Dimensiones y orientación herramienta. Fuente propia

$${}^{EF}A_{tool} = \begin{pmatrix} R_{11} & R_{21} & R_{31} & dx \\ R_{12} & R_{22} & R_{32} & dy \\ R_{13} & R_{23} & R_{33} & dz \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

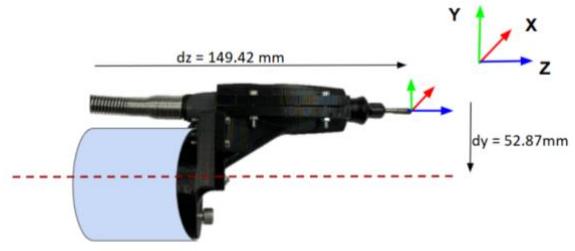


Figura 20. Dimensiones y orientación dremel. Fuente propia

$${}^{EF}A_{dremel} = \begin{pmatrix} R_{11} & R_{12} & R_{13} & -0.26 \\ R_{21} & R_{22} & R_{23} & -52.87 \\ R_{31} & R_{32} & R_{33} & 149.42 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Una vez definidas las relaciones asociadas al robot, se procede a describir las matrices de transformación que vinculan el sistema con el Optitrack, el sensor de fuerzas y el sistema de referencia global (World).

➤ Transformación 5: Matriz OptiTrack-sensor de fuerzas

El sistema también integra un sensor de fuerzas empleado para registrar fuerzas y poses durante la intervención. Sobre este se encontrará el órgano de interés, el hígado. Para ubicar este sensor en el entorno y determinar automáticamente su posición y orientación con respecto al sistema de referencia global (World), se utiliza el OptiTrack. Este es un sistema de captura de movimiento que proporciona la posición y orientación del sensor con respecto a sus propias cámaras.

Para ello, el sensor de fuerzas se equipa con cuatro marcadores pasivos (Figura 22), dispuestos de forma asimétrica y visibles para el sistema OptiTrack. Estos marcadores son detectados por las cámaras, agrupados como un *Rigid Body*, y utilizados para definir automáticamente un sistema de referencia propio en el centro geométrico del cuerpo rígido. En la interfaz del software (Figura 21), este centro geométrico se representa como una esfera grande, mientras que los marcadores individuales se muestran como esferas pequeñas.

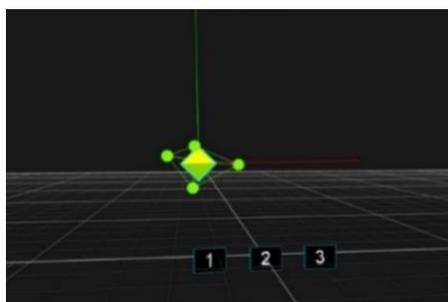


Figura 21. Interfaz del Optitrack. Fuente propia



Figura 22. Sensor de fuerzas con marcadores. Fuente propia

Para el procesamiento de datos, es necesario definir una matriz de transformación que permita convertir las coordenadas desde el sistema de referencia ubicado en el centro geométrico (CG) del sensor de fuerzas hacia el marcador (M) que se utiliza como referencia física en dicho sensor. El software proporciona la posición del marcador respecto al centro geométrico mediante coordenadas (x, y, z), expresadas en el sistema de referencia del sensor de fuerzas. Estos valores pueden ajustarse en función de las características específicas del experimento, por ejemplo, según la anatomía del hígado.

La pieza donde se encuentran los marcadores tiene un espesor de 10 mm. Por tanto, considerando que el sistema de referencia del sensor está ubicado en su superficie, es necesario corregir la coordenada z sumándole dicho valor. La matriz de transformación que relaciona el centro geométrico (CG) del cuerpo rígido con el marcador de referencia (M) se expresa de forma general como:

$${}^{CG}A_M = \begin{pmatrix} R_{11} & R_{12} & R_{13} & x \\ R_{21} & R_{22} & R_{23} & y \\ R_{31} & R_{32} & R_{33} & z + 10 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Por otro lado, el software OptiTrack proporciona la posición y orientación del objeto respecto al sistema de referencia global definido por las cámaras. Esta información se representa mediante una matriz homogénea de transformación genérica, ya que sus valores dependen de la captura en tiempo real:

$${}^{OT}A_{FT} = \begin{pmatrix} R_{11} & R_{12} & R_{13} & x \\ R_{21} & R_{22} & R_{23} & y \\ R_{31} & R_{32} & R_{33} & z \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Donde ${}^{OT}A_{FT}$ representa la transformación desde el sistema de referencia de OptiTrack (OT) al sensor de fuerzas (FT), en el centro geométrico del cuerpo rígido definido por los marcadores.

Para obtener la transformación completa hacia un marcador físico de referencia, es necesario aplicar una matriz adicional a la proporcionada por el sistema OptiTrack. Dado que OptiTrack entrega la posición y orientación del centro geométrico del cuerpo rígido, se debe aplicar la transformación del centro geométrico (CG) al marcador (M). La transformación total se expresa como:

$${}^{OT}A_M = {}^{OT}A_{FT} \cdot {}^{CG}A_M$$

Donde la matriz resultante da la posición y orientación del marcador respecto al sistema de referencia del OptiTrack.

➤ Transformación 6: Matriz OptiTrack-World

Para completar el proceso y transformar desde el sistema de referencia de la cámara OptiTrack al sistema de referencia global (World), se sigue un procedimiento similar:

- Se define un Rigid Body que representa el World, equipado con marcadores reflectantes visibles por las cámaras.
- La matriz de transformación que permite pasar del centro geométrico (CG) de este Rigid Body al marcador de referencia se expresa como:

$${}^{CG}A_M = \begin{pmatrix} R_{11} & R_{12} & R_{13} & x \\ R_{21} & R_{22} & R_{23} & y \\ R_{31} & R_{32} & R_{33} & z + 22.5 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Considerando que la pieza donde están ubicados los marcadores tiene un espesor de 22.5 mm. Finalmente, la matriz que representa la transformación desde el sistema OptiTrack al World, proporcionada por la cámara, es:

$${}^{OT}A_W = \begin{pmatrix} R_{11} & R_{12} & R_{13} & x \\ R_{21} & R_{22} & R_{23} & y \\ R_{31} & R_{32} & R_{33} & z \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

➤ Transformación 7: Matriz Sensor de fuerzas – World

Una vez tenemos ambas matrices, podemos obtener la matriz que pasa del sensor de fuerzas (FT) al World para cerrar el sistema:

$${}^{FT}A_W = ({}^{OT}A_{FT})^{-1} \cdot {}^{OT}A_W$$

La matriz ${}^{OT}A_{FT}$ representa la transformación del sensor de fuerzas respecto al sistema OptiTrack. Como se necesita la transformación en sentido contrario, es decir, del sensor de fuerzas hacia el sistema global, es necesario invertirla. Al multiplicarla por ${}^{OT}A_W$ que representa la posición de un elemento respecto a OptiTrack, se encadenan correctamente las transformaciones y se obtiene así la transformación completa desde el sensor de fuerzas hasta el sistema de referencia global.

Infraestructura experimental: robot colaborativo UR3e

Puesto que el robot empleado durante el desarrollo del proyecto es el UR3e, a continuación, se presenta una descripción más detallada de sus capacidades y características técnicas. El UR3e, Figura 16, desarrollado por Universal Robots, es un robot colaborativo (*cobot*) de seis grados de libertad perteneciente a la familia *e-Series*, diseñado específicamente para aplicaciones de sobremesa y entornos con espacio limitado. Su formato compacto, alta precisión y facilidad de integración lo convierten en una solución especialmente adecuada para contextos quirúrgicos asistidos por robot, donde se requiere una interacción segura y precisa en un entorno clínico restringido ('Brazo Robótico UR3e | Universal Robots', enero 2025).

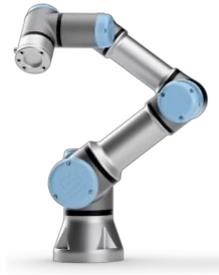


Figura 16. UR3e. Fuente ('Brazo Robótico UR3e | Universal Robots', enero 2025.).

Con una carga útil máxima de 3 kg y un alcance de 500 mm, el UR3e resulta ideal para tareas que exigen alta maniobrabilidad en espacios confinados, como las que se presentan durante una resección hepática. En este tipo de procedimientos, puede actuar como plataforma para la guía de herramientas quirúrgicas, sondas de navegación, láseres o dispositivos de ablación, manteniendo trayectorias estables y seguras previamente planificadas sobre modelos anatómicos tridimensionales. Su bajo peso (11,2 kg) facilita su reubicación dentro del quirófano según las necesidades de la intervención ('Brazo Robótico UR3e | Universal Robots', enero 2025).

Una ventaja clave del UR3e en contextos médicos es su capacidad de operar de forma colaborativa sin requerir barreras físicas, gracias a su sistema de sensores y diseño ergonómico. A diferencia de los robots industriales convencionales, los robots colaborativos están diseñados para compartir el espacio de trabajo con humanos de forma segura, promoviendo un entorno de cooperación entre el robot y el cirujano (Sherwani et al., 2020). Esta característica resulta fundamental en quirófanos, donde la proximidad al campo quirúrgico exige interacción directa con el equipo humano.

Los robots colaborativos de Universal Robots, como el UR3e, han sido ampliamente adoptados en sectores industriales, médicos y educativos por su flexibilidad, movilidad y facilidad de programación (Vivas & Sabater, 2021). En particular, estos sistemas incorporan un *teach pendant* que permite su programación tanto mediante la introducción directa de coordenadas como por guiado manual, definiendo los puntos de paso de la trayectoria deseada.

La precisión en movimientos repetitivos, junto con la posibilidad de controlar la orientación mediante sistemas de navegación externos, hace del UR3e una herramienta idónea para ejecutar trayectorias quirúrgicas planificadas sobre modelos anatómicos. Esto es especialmente relevante en intervenciones hepáticas, donde el respeto de márgenes oncológicos milimétricos y la evitación de estructuras vasculares críticas es esencial. Además, el UR3e permite integrar sistemas de visión, sensores de fuerza o efectores personalizados, ampliando su versatilidad en procedimientos quirúrgicos complejos.

El robot puede ser programado a través de interfaces intuitivas o guiado directamente por el operador, lo que facilita su adaptación a protocolos quirúrgicos personalizados sin necesidad de conocimientos avanzados en robótica. Esta facilidad de uso ha demostrado ser útil en contextos formativos, donde

permite simular procedimientos sobre modelos biomédicos impresos en 3D, incluyendo réplicas de hígados con lesiones simuladas.

Por su combinación de dimensiones compactas, precisión técnica, compatibilidad con ROS y diseño colaborativo, el UR3e representa una opción especialmente adecuada para proyectos de cirugía mínimamente invasiva, como una hepatectomía parcial asistida por robot. En estas intervenciones, donde es necesario controlar con exactitud la posición y orientación del instrumental respecto al modelo anatómico del paciente, el UR3e ofrece un equilibrio óptimo entre rendimiento técnico, seguridad clínica y adaptabilidad operativa.

Registro quirúrgico

Actualmente, existe una capacidad limitada para integrar de forma efectiva la información proveniente de la imagen médica o la planificación preoperatoria dentro del contexto real del quirófano. Esta dificultad se debe, en gran medida, a los desafíos que implica correlacionar directamente los datos virtuales con el entorno físico, lo que reduce el aprovechamiento clínico de dicha información. Además, interpretar geoméricamente las posiciones y orientaciones de los distintos elementos implicados en la intervención, como herramientas quirúrgicas, tejidos u otros datos visuales, dentro de un espacio tridimensional resulta especialmente complejo. Por esta razón, cobra especial relevancia el concepto de registro.

El registro es el proceso mediante el cual se establecen correspondencias geométricas entre diferentes sistemas de referencia, como el entorno virtual de planificación y el entorno físico del quirófano (robots, sensores, estructuras anatómicas). Este paso es esencial para garantizar que las trayectorias, posiciones y orientaciones definidas digitalmente puedan ser interpretadas y ejecutadas de forma precisa en el entorno físico mediante sistemas robóticos o de navegación quirúrgica (Sabater-Navarro et al., 2013).

En el entorno experimental desarrollado (Figura 15), el órgano de interés se sitúa sobre un sensor de fuerza ubicado en el centro de la sala quirúrgica. Este sensor actúa como referencia física común, mientras que un sistema de captura de movimiento OptiTrack, mediante marcadores reflectantes adheridos al modelo anatómico, permite localizar con precisión su posición y orientación en el espacio. A partir de esta configuración se define un sistema de coordenadas local asociado al órgano, que permite su seguimiento dinámico durante la planificación y ejecución del procedimiento.

El registro se basa en la utilización de transformaciones rígidas, las cuales permiten expresar la posición y orientación de un objeto o punto en un sistema de coordenadas de destino a partir de su localización en un sistema de referencia original. Estas transformaciones se representan mediante matrices homogéneas de 4×4 , que combinan en una única estructura tanto la rotación (una matriz 3×3) como la traslación (un vector 3×1). La composición secuencial de estas matrices permite establecer cadenas de

transformación entre múltiples marcos espaciales, como el del órgano, el sensor, el robot o el sistema de navegación óptica.

La transformación de un punto definido en un sistema de referencia {B} al sistema {A} se realiza mediante la siguiente multiplicación de matrices homogéneas:

$$\begin{bmatrix} x_A \\ y_A \\ z_A \\ 1 \end{bmatrix} = \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x_B \\ y_B \\ z_B \\ 1 \end{bmatrix}$$

donde \mathbf{R} es la matriz de rotación 3×3 , t es el vector de traslación 3×1 y (x_B, y_B, z_B) representa las coordenadas del punto en el sistema {B}. El resultado de esta operación es el mismo punto expresado en el sistema de referencia {A}, con sus coordenadas transformadas a ese nuevo marco espacial.

En cirugía robótica, es habitual que convivan múltiples sistemas de referencia: el del modelo anatómico planificado en 3D Slicer, el del sensor de fuerza, el del efector final del robot o el del sistema óptico de seguimiento. Para poder trasladar un punto desde el sistema de planificación virtual de Slicer hasta el efector final del robot, es necesario componer varias transformaciones intermedias encadenadas.

Este encadenamiento permite convertir con precisión las coordenadas y orientaciones definidas en la planificación virtual al espacio físico del robot, garantizando así que las trayectorias planificadas puedan ejecutarse correctamente. Además, esta estructura de transformaciones encadenadas sirve como base para tareas críticas como la navegación quirúrgica, el guiado visual, el seguimiento en tiempo real o la automatización de movimientos complejos. El registro constituye el vínculo fundamental entre el entorno de planificación y el entorno de ejecución. Su correcta implementación, basada en transformaciones rígidas homogéneas, es clave para preservar la seguridad, precisión y eficacia de los procedimientos quirúrgicos asistidos por robot (Sabater-Navarro et al., 2013).

Con todo, en el apartado de resultados se muestra cómo, al integrar las transformaciones espaciales con el proceso de registro quirúrgico, es posible establecer una correspondencia efectiva entre la trayectoria planificada y el espacio operativo del robot. De este modo, se habilita la comunicación precisa entre el entorno virtual y el sistema robótico para la ejecución de la intervención.

Resultados

En esta sección se presentan los resultados obtenidos en las dos etapas principales del sistema desarrollado: la segmentación semiautomática del hígado y la planificación quirúrgica sobre el modelo 3D generado. Estas fases, descritas previamente en el procedimiento experimental, constituyen la base para validar el flujo completo de trabajo propuesto.

Segmentación semiautomática

El modelo fue entrenado en CPU durante aproximadamente 48 horas, con una configuración de 100 épocas. Durante el proceso de entrenamiento, se observó una evolución constante de la pérdida media (*average loss*), que descendió desde un valor inicial de 2.0691 hasta alcanzar un mínimo de 0.4660. Esta tendencia descendente sugiere una buena progresión del aprendizaje por parte del modelo.

No obstante, durante la validación se identificaron algunas limitaciones en la segmentación de tumores. En ciertos volúmenes, la red no logró detectar correctamente la masa tumoral visible, mientras que, en otros casos, como hígado_6 (Figura 17), se generaron falsos positivos, segmentando estructuras que no correspondían a lesiones reales. A pesar de estos errores, la segmentación del hígado resultó consistente y de buena calidad en la mayoría de los casos, confirmando la robustez del modelo para delinear el órgano principal.

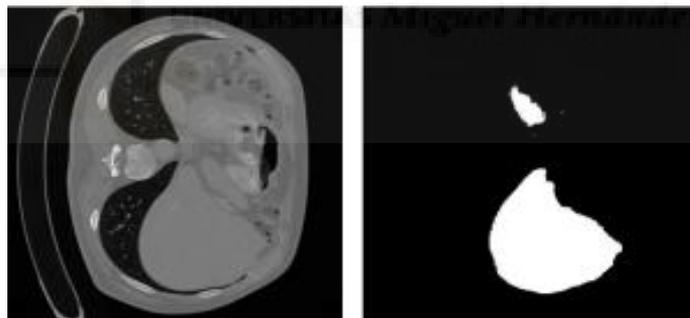


Figura 17. Volumen y máscara segmentada hígado_6. Fuente propia

Dado que una posible causa de los errores en la detección tumoral era la escasa representación de lesiones evidentes en los volúmenes seleccionados inicialmente, se decidió repetir el entrenamiento con un conjunto diferente. Para ello, se revisaron 39 volúmenes previamente analizados y se seleccionaron 18 de ellos, considerando no solo su profundidad (proximidad a la media global del conjunto), sino también la presencia clara de tumores hepáticos. Esta nueva estrategia buscó mejorar la capacidad de generalización del modelo, al centrarse en datos más representativos desde el punto de vista clínico.

El nuevo entrenamiento mantuvo el mismo número de épocas y la misma configuración general. Nuevamente, la pérdida promedio disminuyó progresivamente, comenzando en 1.9765 y estabilizándose alrededor de 0.45 al final del proceso. Este comportamiento confirma la robustez del modelo U-Net cuando se entrena con datos cuidadosamente seleccionados y con una distribución de clases equilibrada.

Las evaluaciones realizadas mostraron que, tras el segundo entrenamiento, el modelo mejoró de forma sustancial en la identificación de estructuras hepáticas. En algunos casos, logró segmentar correctamente tanto el contorno del hígado como la presencia de lesiones, aunque en otros persistieron ciertas imprecisiones, algo esperable dado el grado de complejidad del órgano. A pesar de estas limitaciones, los resultados indican que la arquitectura U-Net, implementada en MONAI, presenta un buen potencial para la segmentación de estructuras hepáticas complejas. El uso de interpolación como técnica de normalización espacial, junto con la adecuada selección de volúmenes de entrenamiento, contribuyó significativamente a mejorar el rendimiento general del sistema.

Con el objetivo de validar visualmente la calidad de las segmentaciones automáticas, se importaron las máscaras generadas por la red neuronal y se superpusieron sobre las imágenes originales de tomografía computarizada (Figura 18). Esta operación se llevó a cabo utilizando 3D Slicer, donde la superposición permitió comprobar que las máscaras se ajustaban adecuadamente a las regiones anatómicas correspondientes al hígado, respetando con precisión su forma y extensión. Esta visualización permitió validar de forma cualitativa la coherencia anatómica de las segmentaciones obtenidas.

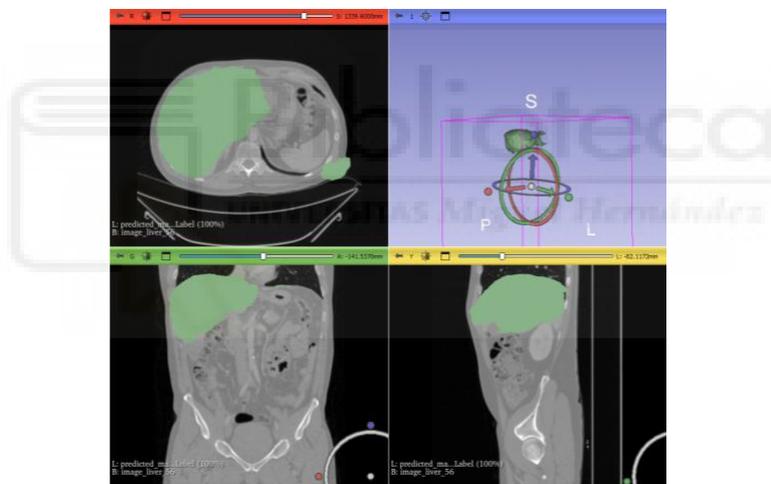


Figura 18. Validación hígado_6. Fuente propia

Se podría concluir que se ha consolidado una estrategia de segmentación basada en una arquitectura U-Net clásica pero eficaz, combinada con un pipeline de transformaciones robusto en MONAI y una selección de volúmenes clínicamente representativos. Aunque aún existe margen de mejora en la segmentación de lesiones tumorales, el sistema desarrollado proporciona una base sólida para futuras optimizaciones.

Una vez validadas las segmentaciones automáticas generadas por la red, se procedió a una fase de segmentación manual para completar y refinar las estructuras anatómicas de interés. En esta etapa se incluyeron la vena cava y los vasos sanguíneos, utilizando para ello los distintos algoritmos y herramientas disponibles en 3D Slicer explicados anteriormente.

La segmentación manual comenzó con la vena cava. Esta estructura se etiquetó inicialmente en varios cortes separados dentro del plano sagital. A continuación, se utilizó la herramienta "Fill between slices", que permite

interpolar entre cortes manuales y generar automáticamente un volumen continuo. Posteriormente, se aplicó la herramienta “*Logical Operators > Subtract*” para eliminar aquellas zonas del segmento del hígado que se superponían con la vena cava (ver Figura 19).

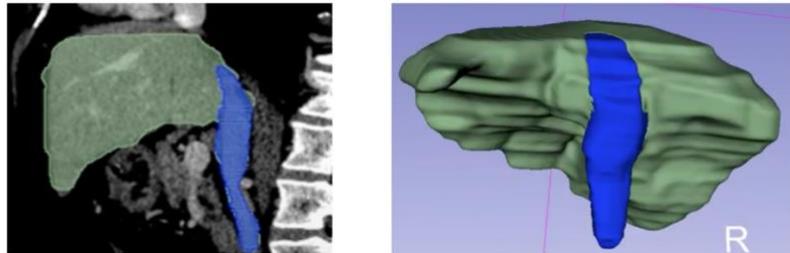


Figura 19. Hígado y vena cava. Fuente propia

Posteriormente, se llevó a cabo la segmentación de los vasos sanguíneos (Figura 20). Para ello se utilizó inicialmente el algoritmo “*Threshold*”, seleccionando aquellas regiones de alta intensidad ubicadas dentro del volumen hepático. El umbral de intensidad fue ajustado manualmente para cada caso, con el fin de aislar con precisión los vasos y excluir otras estructuras que pudieran tener intensidades similares. Este enfoque permitió generar una máscara que representa específicamente las estructuras vasculares intrahepáticas. A continuación, se aplicó la herramienta “*Islands*”, con la opción de conservar únicamente las islas de mayor tamaño. Esta operación permitió eliminar automáticamente aquellas estructuras pequeñas, dispersas o desconectadas que no eran relevantes desde el punto de vista clínico ni aptas para su posterior impresión 3D o análisis anatómico detallado.

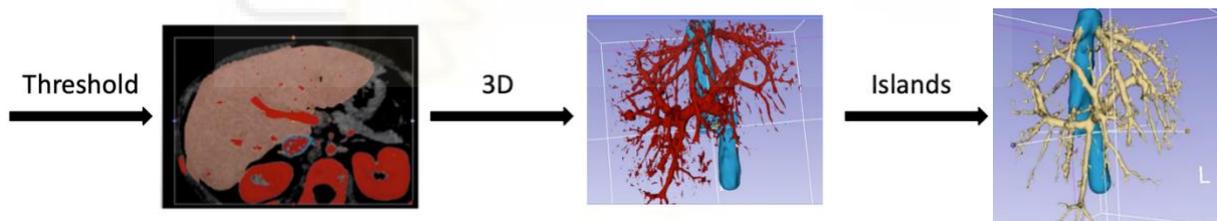


Figura 20. Proceso segmentación vasos sanguíneos. Fuente propia

Tras esta etapa de refinamiento, se obtuvo una segmentación depurada de las estructuras vasculares, libre de artefactos y centrada en los componentes anatómicamente más significativos. Con ello, tanto la máscara del hígado como las segmentaciones refinadas de la vena cava y los vasos sanguíneos quedaron debidamente etiquetadas, validadas y listas para su exportación. Este conjunto de etiquetas constituye una base precisa y coherente para la planificación quirúrgica, y resulta especialmente útil para su integración en flujos de trabajo como la simulación preoperatoria, la navegación quirúrgica o la impresión 3D.

Impresión 3D de los modelos anatómicos

Tras la segmentación de las estructuras anatómicas de interés, se generaron tres modelos principales: uno correspondiente al hígado junto con la vena cava, otro compuesto exclusivamente por los tumores,

y un tercero que incluía los vasos sanguíneos. Cada uno fue exportado en formato .stl, lo que permitió su posterior procesamiento para la fabricación mediante impresión 3D.

El modelo del hígado y la vena cava se generó combinando ambas etiquetas en una única estructura, utilizando operaciones lógicas que permitieron unificarlas en una máscara conjunta. De este modo, se obtuvo una geometría continua que representaba con precisión la relación espacial entre ambos elementos. En el caso de los tumores y los vasos sanguíneos, se crearon modelos independientes a partir de sus respectivas etiquetas, conservando únicamente las estructuras anatómicamente relevantes y eliminando aquellas que no cumplían criterios de impresión.

Una vez exportados los modelos, se procedió a la creación de moldes negativos con el objetivo de replicar físicamente las estructuras mediante técnicas de fundición o moldeo. Para ello, se emplearon herramientas como Blender© y Luban©. En Blender© se diseñaron cajas alrededor de cada modelo y se aplicaron operaciones booleanas para generar cavidades que actuaran como molde negativo. También se añadieron manualmente conectores y perforaciones, adaptando el diseño a las necesidades específicas de cada pieza. Luban© permitió automatizar parte del proceso, generando cajas contenedoras, dividiendo el molde en secciones y añadiendo conectores predeterminados. En algunos casos fue necesario regresar a Blender© para realizar ajustes finos o incorporar detalles adicionales.

Con los moldes ya definidos, se vaciaron internamente utilizando herramientas como “Eraser” en 3D Slicer o “Hollow” en Meshmixer©, obteniendo así estructuras huecas aptas para impresión o colado. Posteriormente, se aplicó una expansión volumétrica a los modelos para compensar posibles contracciones del material durante el enfriamiento. Por ejemplo, el molde del hígado y la vena cava fue expandido 5 mm, mientras que el de los vasos sanguíneos se amplió 1 mm (Figura 21) y se suavizó para facilitar su fabricación.

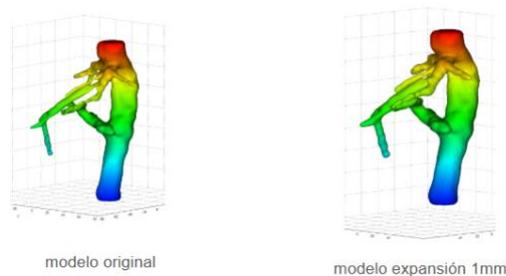


Figura 21. Expansión modelo. Fuente propia

Finalmente, los archivos .stl se prepararon para la impresión utilizando Orca Slicer y el software de MakerBot©, donde se configuraron los parámetros técnicos correspondientes. La impresión se realizó mediante tecnología FDM, utilizando filamento de PLA, un material biodegradable, en impresoras Ender 3 Pro y MakerBot. El resultado fue la obtención de modelos físicos anatómicamente precisos, que no solo permitieron validar el flujo de trabajo digital completo, sino que también constituyen un recurso

tangible útil para aplicaciones clínicas, formativas o de planificación quirúrgica (Figura 22).

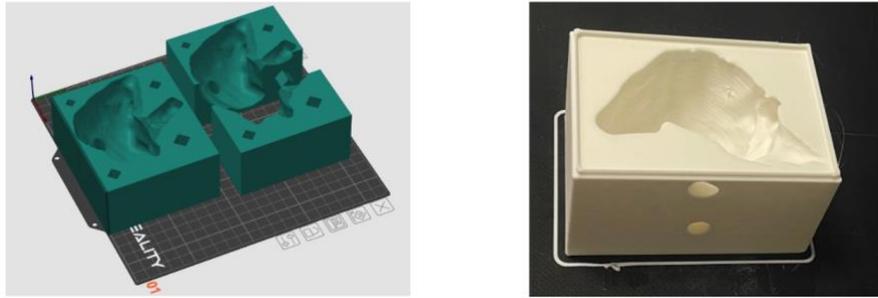


Figura 22. Molde del hígado en el software e impreso. Fuente propia

Con esta etapa se da por finalizado el primer objetivo del proyecto, habiendo conseguido no solo la segmentación tridimensional del órgano de interés, sino también su representación física mediante impresión 3D.

Planificación quirúrgica

Una vez obtenido el modelo tridimensional del órgano a intervenir, se abordan los siguientes dos objetivos del trabajo. En primer lugar, la definición de la trayectoria quirúrgica directamente sobre el modelo anatómico en un entorno virtual. En segundo lugar, el desarrollo de un sistema que permita transferir dicha planificación al entorno físico, de forma que pueda ser interpretada y ejecutada por un robot quirúrgico.

Definición de trayectorias quirúrgicas sobre el modelo 3D

Como parte central del procedimiento experimental, se desarrolló e integró en 3D Slicer un módulo específico denominado **Calculate Normal Orientation**, diseñado para facilitar la definición de trayectorias quirúrgicas directamente sobre el modelo tridimensional del órgano, en este caso, el hígado. El objetivo principal de este módulo es generar, para cada punto seleccionado sobre la superficie del volumen anatómico, una orientación quirúrgica precisa que pueda ser interpretada y ejecutada posteriormente por un sistema robótico.

Como se muestra en la interfaz (Figura 23), el módulo identifica los distintos puntos fiduciales cargados en la escena de Slicer, permitiendo al usuario seleccionar manualmente aquellos que desee marcar como referencias quirúrgicas o bien seleccionar automáticamente todos los disponibles. A partir de estos puntos, se inicia un proceso de cálculo geométrico que determina la normal a la superficie del órgano en cada ubicación, lo que resulta fundamental para establecer la dirección óptima de entrada del instrumental quirúrgico.

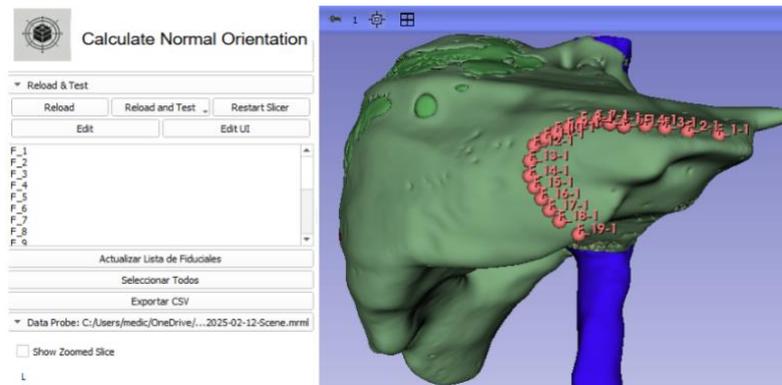


Figura 23. Plug-in desarrollado en Slicer para el cálculo de la normal. Fuente propia

Junto con el cálculo de la normal, el módulo genera una representación tridimensional de los ejes de referencia locales sobre cada punto, facilitando así la comprensión de la orientación espacial (Figura 24). Esta visualización es especialmente útil durante la fase de validación y simulación del sistema, ya que permite comprobar de forma intuitiva que las trayectorias generadas son seguras, anatómicamente viables y clínicamente ejecutables.



Figura 24. Ejes de referencia y normal calculados por el módulo. Fuente propia

El módulo permite también la exportación automática de toda la información generada a un archivo en formato .CSV, compatible con plataformas externas de navegación quirúrgica o sistemas robóticos. Este archivo recoge la etiqueta del punto, sus coordenadas espaciales dentro del sistema de referencia global de la escena y su orientación completa, expresada mediante los tres ángulos de rotación clásicos utilizados en robótica: roll, pitch y yaw. Estos ángulos permiten describir con precisión la orientación de un efector robótico en el espacio tridimensional, siendo fundamentales en tareas de planificación, navegación y control de movimiento. El ángulo de roll representa una rotación alrededor del eje Z, equivalente a un giro lateral, el pitch, por su parte, describe la rotación alrededor del eje Y, asociado a una inclinación hacia arriba o hacia abajo, el yaw corresponde a la rotación en torno al eje X, relacionada con el movimiento de giro horizontal hacia los lados, Figura 25, (*Cinématica del Robot CI-2657 Robótica*, febrero 2025). La combinación de estos tres movimientos permite definir de manera

completa cualquier orientación en el espacio, lo cual resulta esencial para posicionar con precisión instrumentos o componentes en entornos quirúrgicos robotizados.

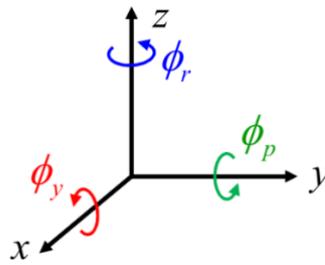


Figura 25. Roll, pitch and yaw. Fuente ('Cinemática del Robot CI-2657 Robótica', febrero 2025)

Para asegurar la consistencia geométrica de los datos exportados, el módulo contempla las posibles transformaciones espaciales aplicadas sobre los modelos o puntos fiduciales, garantizando que las coordenadas reflejen su posición real y actualizada en relación con el sistema de referencia del quirófano o del entorno robótico. Esta capacidad es esencial en entornos clínicos en los que intervienen marcos de referencia dinámicos o dispositivos de navegación.

Asimismo, con el fin de mejorar la precisión de la planificación y reducir la posibilidad de daño tisular, se ha implementado una lógica de agrupación de puntos basada en su alineación vertical. De este modo, aquellos puntos que comparten una disposición espacial similar heredan la orientación del punto más externo del grupo, lo que contribuye a mantener una dirección uniforme a lo largo de la trayectoria. Esta estrategia reduce variaciones angulares innecesarias y favorece una ejecución robótica más estable y respetuosa con los tejidos.

De forma que este módulo supone una herramienta sólida y versátil dentro del entorno de 3D Slicer. Su integración de visualización anatómica avanzada, generación automática de trayectorias y exportación estructurada de datos quirúrgicos lo convierten en un componente clave para la planificación preoperatoria personalizada. Gracias a su diseño, es posible definir trayectorias quirúrgicas adaptadas a cada paciente que pueden ser transferidas con precisión a sistemas robóticos para su ejecución automatizada, cerrando así el ciclo completo de una cirugía mínimamente invasiva asistida por tecnología inteligente.

Durante el desarrollo de este trabajo surgió la necesidad de establecer una estructura de datos eficiente y clara para representar la planificación quirúrgica en un formato fácilmente interpretable por el sistema robótico. En este contexto, se propuso una estructura basada en tramos de movimiento, compuesta por la secuencia:

Punto actual – Punto destino – Booleano de acción

Esta organización permite no solo registrar los puntos de forma individual, sino también definir

explícitamente los movimientos que debe realizar el robot entre cada par de puntos, estableciendo con claridad la trayectoria completa. La incorporación de un valor booleano permite indicar si la herramienta del efector final debe actuar sobre el tejido (por ejemplo, cortar, perforar) o simplemente trasladarse entre puntos sin intervenir, lo cual es especialmente relevante en contextos quirúrgicos donde conviven movimientos activos y pasivos.

Este enfoque ofrece una mayor flexibilidad para modificar o reconfigurar trayectorias sin necesidad de redefinir toda la planificación. Asimismo, mejora el control y la precisión del robot durante la ejecución, al permitir ajustar dinámicamente los desplazamientos según las necesidades intraoperatorias. Esta estructura contribuye a facilitar la cooperación entre el equipo quirúrgico y el sistema robótico, permitiendo al cirujano comprender y supervisar fácilmente las acciones que el robot ejecutará en cada fase del procedimiento. Al traducir la planificación quirúrgica a un lenguaje estructurado y lógico, comprensible tanto para los sistemas de control como para el profesional humano, se mejora significativamente la interacción humano-robot, fortaleciendo el paradigma de colaboración cirujano–ingeniero y reduciendo la ambigüedad en la toma de decisiones compartidas durante la intervención.

A continuación, como parte del proceso de **validación de las trayectorias**, se implementó un procedimiento para comparar la orientación entre vectores normales consecutivos mediante cuaterniones. Este cálculo se llevó a cabo en 3D Slicer a través de un script en Python que identifica los nodos de tipo línea, extrae sus vectores direccionales y determina la rotación relativa entre ellos. A partir de los cuaterniones obtenidos, se extrajo el ángulo de rotación θ entre cada par de normales, el cual se utilizó como métrica para evaluar la continuidad de la orientación a lo largo de la trayectoria, con el propósito de detectar posibles variaciones bruscas que pudieran comprometer la precisión del robot durante la ejecución del procedimiento quirúrgico.

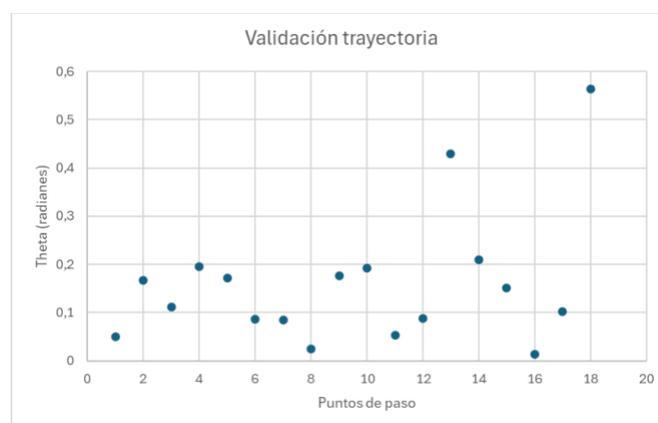


Figura 26. Gráfico de continuidad angular entre orientaciones sucesivas. Fuente propia

Se calculó el ángulo θ entre vectores normales consecutivos y se representaron gráficamente estos valores en la Figura 26, donde el eje X indica los pares de posiciones sucesivas del robot y el eje Y el valor de θ en radianes. Esta visualización permite verificar la continuidad angular de la trayectoria generada.

El eje vertical se escaló entre 0 y 0.6 para resaltar posibles irregularidades, aunque los resultados obtenidos muestran que los valores se mantienen consistentemente bajos y sin picos abruptos. Este comportamiento confirma que la trayectoria presenta una orientación continua y suavemente variable, sin cambios angulares significativos, lo cual es esencial para garantizar movimientos estables y precisos del robot durante la intervención.

Con este análisis, se valida la calidad geométrica de la planificación quirúrgica desarrollada sobre el modelo anatómico, lo que permite dar por alcanzado el segundo objetivo del proyecto: la generación de trayectorias quirúrgicas personalizadas, anatómicamente viables y exportables para su futura ejecución robótica. Una vez verificada esta coherencia espacial, se procede al siguiente paso: la transferencia de la planificación al entorno físico.

Sistema de transferencia de la planificación quirúrgica al entorno real

Siendo el entorno real la sala de cirugía descrita previamente en el procedimiento experimental, y una vez establecida la metodología para adaptar coordenadas y orientaciones entre sistemas de referencia mediante transformaciones homogéneas, este apartado presenta el sistema diseñado para trasladar la planificación quirúrgica virtual al espacio físico de intervención.

En primer lugar, se detallan los ajustes realizados en 3D Slicer para definir correctamente la planificación quirúrgica con respecto al sistema de referencia seleccionado. A continuación, se describe el esquema de implementación en Simulink, responsable de procesar dicha planificación mediante cinemática inversa y generar las instrucciones necesarias para el movimiento del robot.

a. Ajuste del sistema de referencia en 3D Slicer para la planificación quirúrgica.

En el contexto de la planificación quirúrgica virtual, resulta fundamental definir un sistema de referencia que permita una transición clara y precisa entre el entorno digital y el entorno físico del robot. Para ello, es necesario establecer un origen de coordenadas común que actúe como referencia para el resto de los puntos y orientaciones utilizados durante el procedimiento. En este trabajo, se ha optado por redefinir el origen de la escena de 3D Slicer en torno al punto F_1 (fiducial 1). Esta decisión se justifica por la necesidad de que todas las posiciones y transformaciones aplicadas a partir de la planificación, incluyendo trayectorias, vectores normales u orientaciones obtenidas previamente, estén expresadas de forma relativa al primer punto de referencia, es decir, al punto F_1.

Este ajuste del sistema de coordenadas se lleva a cabo utilizando el módulo *Transforms* de 3D Slicer, que permite aplicar una traslación a toda la escena de manera que F_1 pase a ocupar la posición (0, 0, 0) en el espacio RAS (sistema de referencia del software). Para ello, primero se

identifican las coordenadas del punto F_1 (Figura 27) mediante el módulo *Markups*, y posteriormente se crea una transformación de traslación (Figura 28) inversa introduciendo los valores negativos de sus coordenadas. Al aplicar esta transformación al conjunto de modelos y puntos de interés, todos los elementos quedan automáticamente referenciados al nuevo origen. Así, cualquier distancia, posición u orientación extraída del entorno virtual será interpretable directamente con respecto a F_1, lo cual simplifica enormemente la posterior transferencia al sistema de coordenadas físico de la sala de cirugía robótica.

	<input checked="" type="checkbox"/>			Name	Description	R	A	S	
1	<input checked="" type="checkbox"/>			F_1-1		-41.668	219.600	-206.762	<input checked="" type="checkbox"/>

Figura 27. Coordenadas fiducial 1 Slicer. Fuente propia

▼ Transform Matrix			
1.00	0.00	0.00	41.67
0.00	1.00	0.00	-219.60
0.00	0.00	1.00	206.76
0.00	0.00	0.00	1.00

Figura 28. Matriz transformación Slicer. Fuente propia

Una vez aplicada la transformación, se procede a validar visualmente que el punto F_1 ha sido correctamente posicionado en el origen, asegurando que el resto de la geometría mantiene su coherencia espacial. A continuación, se consolida la transformación mediante la herramienta *Harden Transform*, garantizando que el cambio quede incorporado de forma permanente en los datos del modelo. Esta modificación representa un paso fundamental para asegurar que las coordenadas extraídas en Slicer puedan ser correctamente mapeadas al sistema del robot, dado que todas las distancias y orientaciones estarán expresadas ahora en un marco de referencia común y controlado. De este modo, al exportar las coordenadas, todas se encuentran referenciadas al punto F_1.

b. Implementación del sistema de ejecución en el entorno físico

En el presente trabajo, la ejecución de la trayectoria se implementa mediante control de velocidad articular del brazo robótico UR3e. Por ello, las variables seleccionadas para definir la trayectoria deseada incluyen la posición cartesiana de la herramienta en el extremo del robot a lo largo de cada eje, la orientación (expresada en cuaterniones) y las correspondientes componentes de velocidad lineal. Esta representación permite un control de movimiento suave y continuo, manteniendo la precisión espacial requerida para el procedimiento quirúrgico.

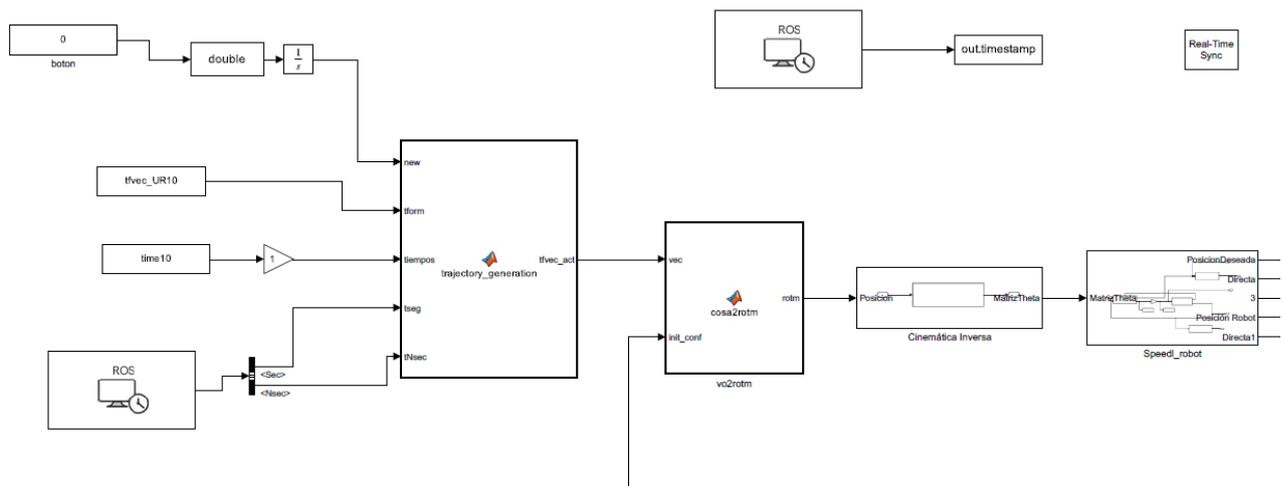


Figura 29. Modelo de control robótico en Simulink. Fuente propia

Este apartado presenta el sistema diseñado para trasladar la planificación quirúrgica virtual al espacio físico de intervención, mediante un entorno de control implementado en Simulink, una herramienta de modelado y simulación basada en bloques, integrada con MATLAB, que permite diseñar, simular y verificar sistemas dinámicos de forma gráfica (Figura 29). Su uso resulta especialmente apropiado en este contexto debido a su capacidad para representar visualmente flujos de control en tiempo real, integrar múltiples fuentes de datos (como desde ROS o archivos CSV) y modelar procesos complejos como el cálculo de la cinemática inversa y el control de velocidad del robot. Además, permite una implementación modular, intuitiva y flexible, facilitando el desarrollo de sistemas de control robustos para aplicaciones quirúrgicas asistidas por robot.

Previo a la implementación en Simulink, se realizó un preprocesamiento de los datos exportados desde 3D Slicer, contenidos en un archivo CSV. Este archivo incluía las coordenadas de posición (X, Y, Z) y orientación en formato Roll-Pitch-Yaw (RPY) para cada punto de la trayectoria planificada. Los datos fueron cargados y transformados en MATLAB, donde se generaron matrices homogéneas 4x4 para cada pose.

Como parte de este proceso, se aplicó una rotación adicional de 90° sobre el eje X. Esta transformación se justificó por el hecho de que, en el entorno clínico real, el paciente se encuentra en posición supina (tumbado boca arriba), mientras que en 3D Slicer el modelo anatómico del hígado está representado en una orientación vertical. Esta discrepancia en los sistemas de referencia requiere ajustar las orientaciones para que coincidan con la dirección anatómicamente correcta durante la intervención física.

Además, se visualizó la trayectoria mediante una representación tridimensional de la normal exportada de Slicer. Esta visualización permitió validar de forma gráfica la orientación y

distribución espacial de los puntos antes de integrarlos al entorno de control. En dicha representación, se dibujaron los vectores normales a partir de las matrices de rotación, junto con la posición de cada punto, facilitando la verificación de la coherencia geométrica de la trayectoria quirúrgica y asegurando su adecuada ejecución en el espacio físico (Figura 30).

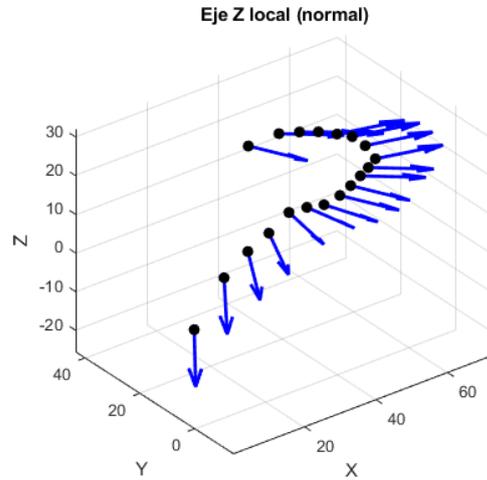


Figura 30. Representación tridimensional de la normal de cada punto de la trayectoria quirúrgica. Fuente propia

Además, se presenta una visualización tridimensional de la trayectoria, que incluye tanto la orientación del sistema como el comportamiento espacial de la herramienta quirúrgica. En la figura, la línea punteada representa la trayectoria seguida por el efector final del robot, mientras que la línea continua muestra el recorrido de la punta de la herramienta quirúrgica simulada. Esta herramienta, modelada como un instrumento de punción de 12 mm de longitud, se incorpora con fines de validación visual, permitiendo verificar que las transformaciones geométricas aplicadas y la orientación del brazo robótico se traduzcan correctamente en una trayectoria realista y coherente con la planificación quirúrgica (Figura 31).

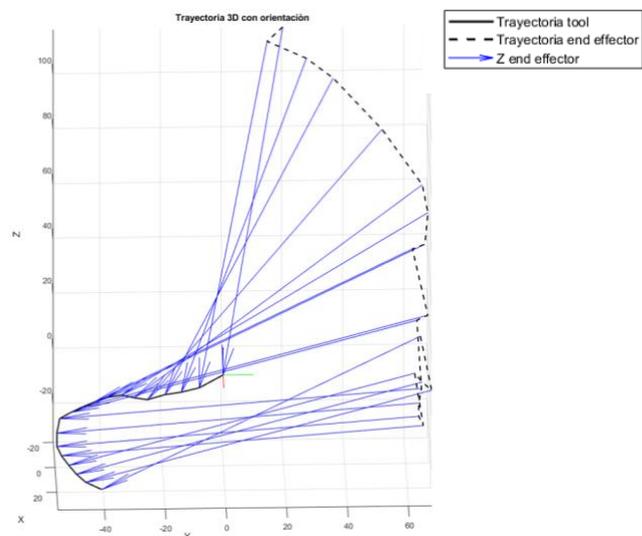


Figura 31. Representación tridimensional de la trayectoria planificada. Fuente propia

Una vez preprocesados y validados los datos de trayectoria, el siguiente paso consiste en integrarlos al entorno de control en Simulink. El sistema tiene como entradas, además de los puntos que definen la trayectoria planificada, una señal de inicio (comando *Init*), que habilita el procedimiento tras la configuración inicial, y un vector de tiempo asociado a cada punto, que permite sincronizar con precisión el movimiento del robot a lo largo del recorrido definido.

Estas entradas son procesadas por el primer bloque funcional del sistema, denominado *trajectory_generation*. Este bloque se encarga de asociar cada instante de tiempo con un punto específico de la trayectoria quirúrgica, generando así una trayectoria continua con su correspondiente tiempo de ejecución. Adicionalmente, incorpora un módulo de transformación del sistema de coordenadas, dado que los puntos planificados están definidos en el sistema de referencia virtual (F_0), con origen en el F_1 de 3D Slicer, definido en el apartado anterior. A través de una transformación homogénea, este bloque convierte las coordenadas al sistema de referencia físico del robot, garantizando una correspondencia espacial precisa entre el entorno virtual de planificación y el espacio real de intervención.

Como resultado, el bloque *trajectory_generation* devuelve, en función del tiempo, cada punto de la trayectoria ya transformado y listo para su ejecución. Estos puntos, que incluyen posición y orientación en el sistema del robot, son recogidos por el siguiente bloque funcional: *IK_UR10*. Este módulo se encarga de calcular la cinemática inversa del robot UR3e, entendida como el proceso mediante el cual se determinan los valores de las articulaciones necesarios para alcanzar una determinada posición y orientación del extremo del brazo robótico (*end-effector*). Para ello, toma como entrada la posición y orientación deseadas del *end-effector* y devuelve las posiciones articulares correspondientes para alcanzar dicha configuración en cada instante de tiempo.

Una vez obtenidos estos valores articulares, son transmitidos al bloque *Speed_mode*, el cual implementa el control de velocidad articular. Este módulo se encarga de generar comandos de movimiento compatibles con la interfaz del robot, respetando las limitaciones de velocidad de cada articulación, y enviarlos al robot en tiempo real, permitiendo así una ejecución precisa y segura de la trayectoria planificada.

El sistema incorpora, además, un bucle de retroalimentación que actualiza de forma continua la posición articular real del robot. Esta información es procesada por dos bloques adicionales encargados de calcular la cinemática directa, entendida como el proceso mediante el cual se determina la posición y orientación del extremo del brazo robótico (*end-effector*) a partir de los valores de sus articulaciones. Uno de estos bloques estima la posición teórica esperada del

end-effector (Forward Kinematics deseado), y el otro calcula la posición real a partir de los datos articulares medidos en tiempo real (Forward Kinematics actual). La comparación entre ambas salidas permite verificar visualmente el correcto seguimiento de la trayectoria y, junto con los valores articulares esperados y actuales, proporciona una base para validar el comportamiento del sistema en tiempo real, asegurando la fiabilidad y precisión del procedimiento quirúrgico asistido por robot.

Con todo el sistema en funcionamiento, el robot UR3e fue capaz de recibir e interpretar correctamente la información relativa a la trayectoria planificada. Durante la ejecución experimental, se comprobó que las poses y velocidades exportadas desde 3D Slicer eran comprendidas con precisión por el sistema de control, lo que permitió una reproducción fiel de la trayectoria en el entorno físico. La ejecución robótica se llevó a cabo sin errores de interpretación ni desviaciones perceptibles respecto al modelo simulado. Estos resultados confirman la estabilidad, fiabilidad y reproducibilidad del sistema, validando su adecuación para ser integrado en un flujo de trabajo quirúrgico real y sentando las bases para futuras aplicaciones clínicas de cirugía asistida por robot.



Discusión

El sistema presentado aborda una de las brechas actuales en la transición desde la planificación quirúrgica virtual hasta la ejecución robótica autónoma: la ausencia de información de orientación en los puntos definidos por el cirujano. Mientras que la mayoría de los sistemas actuales permiten definir posiciones espaciales sobre modelos anatómicos, la orientación requerida por un efector robótico suele omitirse o delegarse a procesos de control en tiempo real. Esto limita la capacidad de anticipación, seguridad y adaptabilidad en contextos autónomos o semiautónomos. Nuestro enfoque, basado en el cálculo de normales a la superficie del órgano, permite asociar de forma natural una orientación a cada punto definido por el usuario, con continuidad geométrica y significado clínico.

El caso de validación seleccionado, la resección del segmento III del hígado, ha permitido probar el sistema en un escenario clínicamente representativo, pero de baja complejidad técnica. Los resultados demuestran que la orientación generada automáticamente se alinea con las expectativas del cirujano y permite una ejecución fluida y precisa por parte del robot. Las métricas de continuidad angular, precisión de las normales y tiempo de generación indican que el sistema es eficiente, reproducible y clínicamente viable en etapas preoperatorias.

Una de las principales ventajas del sistema es su modularidad y su integración directa en un entorno clínico conocido como Slicer, así como su compatibilidad con estándares abiertos como ROS. Esto facilita su adopción en contextos hospitalarios sin necesidad de modificar el flujo de trabajo existente. Además, el uso de sistemas ópticos para el registro quirúrgico permite una transferencia espacial precisa sin requerir dispositivos invasivos.

Sin embargo, el sistema presenta también limitaciones. La precisión del cálculo de normales depende de la calidad del modelo 3D segmentado, que a su vez está condicionado por la resolución de imagen y el rendimiento de los algoritmos de segmentación. Además, aunque la orientación calculada es geoméricamente adecuada, no incorpora restricciones cinemáticas del robot ni modelos biomecánicos del órgano, lo que podría ser relevante en tejidos blandos o zonas de difícil acceso. Finalmente, la validación se ha realizado en un entorno simulado, aunque se ha utilizado un robot real, no se ha realizado una intervención clínica en pacientes o modelos anatómicos vivos.

Si bien la validación actual en un entorno simulado y con un robot real representa un avance significativo, es imprescindible continuar con estudios en modelos anatómicos vivos y eventualmente en entornos clínicos reales para confirmar la robustez y seguridad del sistema. Además, la incorporación futura de restricciones cinemáticas y modelos biomecánicos enriquecerá la precisión y adaptabilidad en tejidos blandos, acercándonos cada vez más a una cirugía robótica autónoma fiable.

Conclusiones y trabajos futuros

En este trabajo se ha desarrollado un sistema semiautomático para la planificación quirúrgica robótica que incorpora de forma explícita la orientación en cada punto definido manualmente por el cirujano. Los resultados obtenidos evidencian que el enfoque basado en el cálculo de normales a las superficies anatómicas segmentadas proporciona una representación precisa y coherente de la orientación necesaria para la ejecución autónoma de tareas quirúrgicas, cumpliendo de manera satisfactoria los objetivos planteados.

Respecto al primer objetivo, la segmentación semiautomática del hígado a partir de imágenes de tomografía computarizada ha alcanzado un nivel de precisión alto, generando modelos tridimensionales detallados que incluyen estructuras anatómicas relevantes. Esta calidad en la segmentación ha sido fundamental para el correcto cálculo de las normales y, en consecuencia, para la definición fiable de la orientación en cada punto, sentando una base sólida para la planificación personalizada.

En cuanto a la planificación quirúrgica tridimensional, el sistema desarrollado ha permitido establecer trayectorias suaves, continuas y geoméricamente consistentes que respetan la anatomía específica del paciente y las restricciones clínicas planteadas. El módulo encargado de generar estas trayectorias ha funcionado adecuadamente, facilitando la visualización, edición y estructuración de la información espacial de manera que puede ser interpretada y ejecutada por un robot. Finalmente, la transferencia de la planificación al entorno real se ha realizado con éxito mediante la integración en 3D Slicer y la comunicación a través de ROS, garantizando una correspondencia espacial precisa entre el modelo virtual y el espacio físico del quirófano. La correcta transferencia y ejecución de las trayectorias planificadas en el robot validan la robustez del flujo completo, confirmando que el sistema funciona coherentemente desde la segmentación inicial hasta la ejecución en un entorno físico real.

Estos resultados evidencian que el sistema cumple satisfactoriamente con los objetivos planteados, proporcionando una herramienta práctica, eficiente y modular para la cirugía robótica asistida. No obstante, se identifican áreas de mejora, principalmente relacionadas con la incorporación futura de modelos cinemáticos y biomecánicos específicos, así como la necesidad de validar el sistema en procedimientos quirúrgicos de mayor complejidad y en entornos clínicos reales.

Como futuras líneas de trabajo, se plantea validar el sistema en procedimientos más complejos, incorporar restricciones cinemáticas y clínicas, aplicar el método en entornos quirúrgicos reales con modelos animales o simulados, e integrar feedback intraoperatorio para adaptar dinámicamente las trayectorias. Este enfoque impulsa el desarrollo de sistemas quirúrgicos más autónomos y precisos. Así pues, este trabajo constituye un avance relevante en medicina personalizada, al integrar segmentación anatómica, planificación virtual y ejecución robótica para mejorar la seguridad y eficacia en intervenciones hepáticas asistidas por robot.

Bibliografía

- Araújo, J. D. L., da Cruz, L. B., Diniz, J. O. B., Ferreira, J. L., Silva, A. C., de Paiva, A. C., & Gattass, M. (2022). Liver segmentation from computed tomography images using cascade deep learning. *Computers in Biology and Medicine*, 140, 105095. Retrieved from <https://doi.org/10.1016/j.combiomed.2021.105095>
- Attanasio, A., Scaglioni, B., De Momi, E., Fiorini, P., & Valdastri, P. (2021). Autonomy in Surgical Robotics. *Annual Review of Control, Robotics, and Autonomous Systems*, 4(1), 651–679. Retrieved from <https://doi.org/10.1146/annurev-control-062420-090543>
- Barron, J. O., Orabi, D., Moro, A., Quintini, C., Berber, E., Aucejo, F. N., ... Kwon, C.-H. D. (2022). Validation of the IWATE criteria as a laparoscopic liver resection difficulty score in a single North American cohort. *Surgical Endoscopy*, 36(5), 3601–3609. Retrieved from <https://doi.org/10.1007/s00464-021-08561-4>
- Bilic, P., Christ, P., Li, H. B., Vorontsov, E., Ben-Cohen, A., Kaissis, G., ... Menze, B. (2023). The Liver Tumor Segmentation Benchmark (LiTS). *Medical Image Analysis*, 84, 102680. Retrieved from <https://doi.org/10.1016/j.media.2022.102680>
- Brazo Robótico UR3e | Universal Robots. (enero 2025). Retrieved 10 June 2025, from <https://www.universal-robots.com/es/productos/robot-ur3/>
- Cho, B. Y., Hermans, T., & Kuntz, A. (2021). Planning Sensing Sequences for Subsurface 3D Tumor Mapping. Retrieved 10 June 2025 from <https://arxiv.org/abs/2110.06195v1>
- Cinemática del Robot CI-2657 Robótica Prof. Kryscia Ramírez Benavides. (febrero 2025). Retrieved 10 June 2025 from
- Cirugía Robótica Tratamiento Cáncer Próstata - Clínica CEMTRO. (abril 2025). Retrieved 10 June 2025, from <https://www.clinicacentro.com/98-pacientes-operados-cirugia-robotica-recuperan-continencia-urinaria/>
- Cruz Díaz, N. P., Maña López, M. J., & Mata Vázquez, J. (2010). Aprendizaje automático versus expresiones regulares en la detección de la negación y la especulación en biomedicina. Retrieved 10 June 2025 from <http://rua.ua.es/dspace/handle/10045/14709>
- Dillon, N. P., Fichera, L., Wellborn, P. S., Labadie, R. F., & Webster, R. J. (2016). Making robots mill bone more like human surgeons: Using bone density and anatomic information to mill safely and efficiently. In *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 1837–1843). IEEE. Retrieved from <https://doi.org/10.1109/IROS.2016.7759292>
- Ellis, D. G., & Aizenberg, M. R. (2021). Trialing U-Net Training Modifications for Segmenting Gliomas Using Open Source Deep Learning Framework (pp. 40–49). Retrieved from https://doi.org/10.1007/978-3-030-72087-2_4
- Fedorov, A., Beichel, R., Kalpathy-Cramer, J., Finet, J., Fillion-Robin, J.-C., Pujol, S., ... Kikinis, R. (2012). 3D Slicer as an image computing platform for the Quantitative Imaging Network. *Magnetic Resonance Imaging*, 30(9), 1323–1341. Retrieved from <https://doi.org/10.1016/j.mri.2012.05.001>
- Galán-Cuenca, Á., De Luis-Moura, D., Herrera-López, J. M., Rollón, M., García-Morales, I., & Muñoz, V. F. (2024). Sutura automatizada para una plataforma robótica de asistencia a la cirugía laparoscópica. *Revista*

- Iberoamericana de Automática e Informática Industrial*, 21(4), 339–350. Retrieved from <https://doi.org/10.4995/riai.2024.20642>
- ‘La cirugía robótica aporta mayor precisión y seguridad en las intervenciones de oncología ginecológica’. (abril 2025). Retrieved 10 June 2025, from <https://davinci.imedhospitales.com/blog/cirugia-robotica-aporta-mayor-precision-seguridad-intervenciones-oncologia-ginecologica>
- McKinley, S., Garg, A., Sen, S., Gealy, D. V., McKinley, J. P., Jen, Y., ... Goldberg, K. (2016). An interchangeable surgical instrument system with application to supervised automation of multilateral tumor resection. In *2016 IEEE International Conference on Automation Science and Engineering (CASE)* (pp. 821–826). IEEE. Retrieved from <https://doi.org/10.1109/COASE.2016.7743487>
- Meng, L., Zhang, Q., & Bu, S. (2021). Two-Stage Liver and Tumor Segmentation Algorithm Based on Convolutional Neural Network. *Diagnostics*, 11(10), 1806. Retrieved from <https://doi.org/10.3390/diagnostics11101806>
- Moccia, R., Selvaggio, M., Villani, L., Siciliano, B., & Ficuciello, F. (2019). Vision-based Virtual Fixtures Generation for Robotic-Assisted Polyp Dissection Procedures. In *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 7934–7939). IEEE. Retrieved from <https://doi.org/10.1109/IROS40897.2019.8968080>
- Molinero, M. B., Dagnino, G., Liu, J., Chi, W., Abdelaziz, M. E. M. K., Kwok, T. M. Y., ... Yang, G. Z. (2019). Haptic Guidance for Robot-Assisted Endovascular Procedures: Implementation and Evaluation on Surgical Simulator. In *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 5398–5403). IEEE. Retrieved from <https://doi.org/10.1109/IROS40897.2019.8967712>
- Orellana Guevara, C. (2020). Aprendizaje profundo en la formación docente: experiencia con estudiantes de Enseñanza de la Educación de la Universidad de Costa Rica. *Innovaciones Educativas*, 22(33), 208–221. Retrieved from <https://doi.org/10.22458/ie.v22i33.3125>
- ¿Qué ventajas me ofrece el robot Da Vinci? - Clinic Robotics. (2023). Retrieved 10 June 2025, from <https://clinicrobotics.com/blog/ventajas-ofrece-robot-da-vinci/>
- Radiocirugía estereotáctica - CyberKnife: MedlinePlus enciclopedia médica. (2024). Retrieved 10 June 2025, from <https://medlineplus.gov/spanish/ency/article/007274.htm>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation (pp. 234–241). Retrieved from https://doi.org/10.1007/978-3-319-24574-4_28
- Sabater-Navarro, J., Saltaren, R., Ibarra-Zannatha, J., Rodriguez Cheu, L., Vivas, A., Politti, J., ... Rubio, E. (2013). *ROBOTICA MEDICA – Notas prácticas para el aprendizaje de la robótica en bioingeniería*.
- Sanchez-Encinas, M., Rey-Biel, J., Alias, D., Noguero-Meseguer, R., Granell, J., Muguruza, I., ... Barba, R. (2023). Performance of a multidisciplinary robotic surgery program at a university hospital (2012–2022). *Journal of Robotic Surgery*, 17(6), 2869–2874. Retrieved from <https://doi.org/10.1007/s11701-023-01726-4>
- Savjani, R. (2021). nnU-Net: Further Automating Biomedical Image Autosegmentation. *Radiology: Imaging Cancer*, 3(1), e209039. Retrieved from <https://doi.org/10.1148/rycan.2021209039>
- Segment editor — 3D Slicer documentation. (octubre 2024). Retrieved 10 June 2025, from https://slicer.readthedocs.io/en/latest/user_guide/modules/segmenteditor.html

- Sherwani, F., Asad, M., & Ksm Kader Ibrahim, B. S. (2020). Collaborative Robots and Industrial Revolution 4.0 (IR 4.0) (pp. 1–5). Retrieved from <https://doi.org/10.1109/ICETST49965.2020.9080724>
- Sys, G., Eykens, H., Lenaerts, G., Shumelinsky, F., Robbrecht, C., & Poffyn, B. (2017). Accuracy assessment of surgical planning and three-dimensional-printed patient-specific guides for orthopaedic osteotomies. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, 231(6), 499–508. Retrieved from <https://doi.org/10.1177/0954411917702177>
- Vivas, A., & Sabater, J. M. (2021). UR5 Robot Manipulation using Matlab/Simulink and ROS. In *2021 IEEE International Conference on Mechatronics and Automation (ICMA)* (pp. 338–343). Retrieved from <https://doi.org/10.1109/ICMA52036.2021.9512650>
- Vrooijink, G. J., Abayazid, M., Patil, S., Alterovitz, R., & Misra, S. (2014). Needle path planning and steering in a three-dimensional non-static environment using two-dimensional ultrasound images. *The International Journal of Robotics Research*, 33(10), 1361–1374. Retrieved from <https://doi.org/10.1177/0278364914526627>
- Williams, M. A., McVeigh, J., Handa, A. I., & Lee, R. (2020). Augmented reality in surgical training: a systematic review. *Postgraduate Medical Journal*, 96(1139), 537–542. Retrieved from <https://doi.org/10.1136/postgradmedj-2020-137600>
- Wood, N. A., Schwartzman, D., Passineau, M. J., Moraca, R. J., Zenati, M. A., & Riviere, C. N. (2018). Beating-heart registration for organ-mounted robots. *The International Journal of Medical Robotics and Computer Assisted Surgery*, 14(4). Retrieved from <https://doi.org/10.1002/rcs.1905>
- Yang, G.-Z., Cambias, J., Cleary, K., Daimler, E., Drake, J., Dupont, P. E., ... Taylor, R. H. (2017). Medical robotics—Regulatory, ethical, and legal considerations for increasing levels of autonomy. *Science Robotics*, 2(4). Retrieved from <https://doi.org/10.1126/scirobotics.aam8638>