

Jornadas de Automática

Sistema semiautomático de planificación quirúrgica para robots autónomos

Poveda-Perez, Marina^a, Manrique-Cordoba, Juliana^a, Lidon-Calvo, Sergio^a, Brotons-Lopez, María^a, Martorell-Llobregat, Carlos^b, Sabater-Navarro, José María.^{a*}

^a Unidad de Robótica Médica, Instituto de Bioingeniería, Universidad Miguel Hernández de Elche, Av. Universidad sn, 03202, España.

^b Unidad de Neurocirugía, Hospital General de Elche, 03202, España.

To cite this article: Poveda-Perez, Marina, Manrique-Cordoba, Juliana, Lidon-Calvo, Sergio, Brotons-Lopez, María, Martorell-Llobregat, Carlos, Sabater-Navarro, José María. 2025. Semi-automatic surgical planning system for autonomous robots. *Jornadas de Automática*, 46.
<https://doi.org/10.17979/ja-cea.2025.46.12148>

Resumen

Este artículo presenta un sistema semiautomático para la transferencia de la planificación quirúrgica robótica realizada en un entorno 2D/3D y que permite extender la información de posición en la trayectoria definida manualmente por un cirujano con información de orientación y velocidad, necesarias 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 efecto 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 UR5e. La validación se ha realizado en un caso de resección del segmento III del hígado, y los resultados muestran que el sistema es eficiente, preciso y adecuado para su uso en entornos de planificación quirúrgica.

Palabras clave: Planificación quirúrgica, robótica, planificación de trayectorias, autonomía de robots quirúrgicos.

Semi-automatic surgical planning system for autonomous robots

Abstract

This article presents a semi-automated system for the transfer of robotic surgical planning performed in a 2D/3D environment. It allows the position information on the trajectory manually defined by a surgeon to be extended with orientation and velocity information, necessary for its autonomous execution by a surgical robot. The system includes a neural network for the semi-automatic segmentation of liver tissues. To calculate the orientations and velocities of the robot's effector, the system relies on the calculation of normals to the anatomical surface of the segmented organ at each point along the trajectory. The presented solution has been implemented as a software plug-in within the 3D Slicer open-source project and integrated with ROS for transfer to a UR5e robot. Validation has been performed on a liver segment III resection case, and the results show that the system is efficient, accurate, and suitable for use in surgical planning environments.

Keywords: Surgical planning, robotics, path planning, autonomy of surgical robots.

1. Introducción

El desarrollo de sistemas autónomos en robótica quirúrgica representa uno de los desafíos más ambiciosos en la automatización médica. A pesar de los avances en precisión y control ofrecidos por plataformas quirúrgicas como da Vinci® o Versius®, la mayoría de los sistemas actuales se basan exclusivamente en la teleoperación, donde el cirujano

humano controla en tiempo real todos los movimientos del robot (Attanasio et al. 2021). Este esquema de control limita el potencial de autonomía y delegación de tareas. Para avanzar hacia escenarios en los que el robot ejecute de forma autónoma tareas quirúrgicas definidas previamente por el cirujano, es necesario transferir la planificación desde el entorno virtual al físico. En particular, y en lo referido a este trabajo, se requiere completar la planificación con

información de orientación y velocidades en los puntos de la trayectoria y garantizar su interpretabilidad por parte del sistema robótico.

La planificación quirúrgica se fundamenta tradicionalmente en el uso de imagen médica, principalmente en 2D (tomografía axial computarizada, resonancia magnética), que permite al especialista identificar estructuras anatómicas relevantes. A partir de estas imágenes, el cirujano puede definir trayectorias de acceso, puntos de interés clínico, márgenes de resección o regiones diana para intervención. Este proceso ha sido asistido por plataformas de visualización 3D que permite modelar el entorno anatómico. Sin embargo, incluso con el uso de estos softwares de visualización, la planificación se limita a coordenadas espaciales sin información explícita sobre la orientación requerida por un efecto robótico para ejecutar la acción.

Siendo que el primer paso en la planificación quirúrgica hace referencia a la segmentación de órganos, uno de los avances más significativos en la última década ha sido la incorporación de técnicas de inteligencia artificial, especialmente redes neuronales profundas, al proceso de segmentación anatómica. Herramientas como U-Net (Ronneberger, Fischer, and Brox 2015) han demostrado gran precisión y robustez en la segmentación automática de estructuras anatómicas, incluyendo órganos, vasos y lesiones. Estas técnicas han permitido reducir significativamente el tiempo de preparación preoperatoria y mejorar la reproducibilidad. En el caso del hígado, por ejemplo, se han desarrollado modelos entrenados con bases de datos clínicas que permiten segmentar el órgano y sus estructuras internas con alta fidelidad (Heimann et al. 2009).

A pesar de los avances, la transferencia de la planificación virtual al entorno quirúrgico sigue siendo un desafío clave en cirugía asistida por ordenador. El registro quirúrgico, es decir, la correspondencia espacial entre el modelo del paciente basado en imagen y su representación física en el quirófano, presenta múltiples dificultades, principalmente cuando se trabaja con órgano sólido deformable. Entre los métodos más empleados se encuentran el ajuste iterativo de puntos (ICP), la utilización de marcadores anatómicos (landmarks naturales) y la colocación de marcadores artificiales (fiduciales) (Mountney, Stoyanov, and Yang 2010; Ungi, Lasso, and Fichtinger 2016). Cada método presenta ventajas y limitaciones, especialmente en cuanto a precisión, invasividad y dependencia del operador. Además, la deformación de tejidos durante la cirugía dificulta un registro dinámico preciso, afectando la ejecución autónoma.

Este artículo presenta un sistema semiautomático que extiende la planificación quirúrgica tradicional añadiendo de forma automática la orientación en cada punto de una trayectoria quirúrgica definida manualmente sobre un entorno 2D/3D. La orientación se calcula a partir de las normales a la superficie anatómica segmentada, lo que proporciona una base geométrica robusta y adaptada a la morfología del órgano. El procedimiento ha sido implementado como un módulo desarrollado dentro del software libre 3D Slicer y

validado en un caso de planificación de cauterización hepática. La trayectoria completa —posición, orientación y velocidades de paso— se publica como un nodo en ROS, permitiendo su ejecución directa por un sistema robótico.

El resto del artículo se organiza de la siguiente manera. En la Sección 2 se describe el sistema propuesto y la metodología seguida, incluyendo los pasos de segmentación, planificación, cálculo de normales y publicación de la trayectoria. La Sección 3 presenta los resultados obtenidos en un caso de estudio real. En la Sección 4 se discuten las implicaciones clínicas y técnicas del sistema, así como sus limitaciones. Finalmente, la Sección 5 presenta las conclusiones y propone líneas futuras de investigación.

2. Materiales y métodos

2.1. Entorno de desarrollo

El sistema ha sido desarrollado en la plataforma de software libre 3D Slicer, ampliamente utilizada en entornos clínicos y de investigación para análisis y visualización de imágenes médicas. 3D Slicer permite la segmentación anatómica, reconstrucción tridimensional, fusión multimodal y planificación quirúrgica personalizada. Su arquitectura modular lo convierte en un entorno especialmente adecuado para la extensión de funcionalidades específicas en cirugía asistida por imagen (Fedorov et al. 2012).

Las extensiones desarrolladas para este trabajo han sido programadas en Python, aprovechando la integración directa que Slicer ofrece con potentes bibliotecas de procesamiento de imagen médica como VTK (Visualization Toolkit), ITK (Insight Segmentation and Registration Toolkit) e IGSTK (Image-Guided Surgery Toolkit). Estas bibliotecas permiten el tratamiento avanzado de volúmenes 3D, el cálculo eficiente de normales y la integración de modelos anatómicos segmentados con datos de navegación intraoperatoria.

Para la ejecución quirúrgica autónoma, la trayectoria planificada debe ser transferida al sistema robótico a través de una arquitectura de control. En este trabajo se ha utilizado Robot Operating System 1 (ROS), una infraestructura de middleware ampliamente adoptada en investigación robótica. ROS permite la interoperabilidad entre componentes heterogéneos, como sistemas de imagen médica y robots industriales. En nuestro caso, la integración se realiza con un brazo robótico UR5e de Universal Robots, utilizado como plataforma para tareas quirúrgicas simuladas. La arquitectura permite enviar mensajes desde el entorno Slicer a ROS, facilitando la ejecución robótica directa de la trayectoria quirúrgica planificada.

2.2. Descripción del flujo de trabajo

El flujo de trabajo (figura 1) desarrollado combina el uso de redes neuronales profundas con herramientas de planificación quirúrgica en 3D Slicer para facilitar la segmentación anatómica personalizada y la definición de trayectorias

quirúrgicas en cirugía hepática. A continuación, se describen los pasos principales:

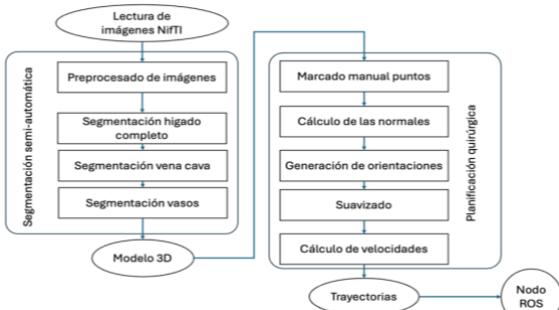


Figura 1: Esquema del flujo de trabajo del sistema semiautomático de planificación quirúrgica.

Paso 1: Adquisición y carga de imágenes médicas

En este trabajo se emplean volúmenes tridimensionales en formato NIfTI (.nii.gz), provenientes del conjunto de datos público LiTS17 (Bilic et al. 2023). Este formato almacena volúmenes e información espacial esencial para reconstrucción 3D precisa, como la orientación, resolución y espaciado entre cortes, lo cual resulta esencial para una reconstrucción 3D precisa. La tarea de segmentar el hígado y sus estructuras asociadas presenta un alto grado de complejidad, principalmente debido a la baja diferenciación en intensidades dentro de la escala Hounsfield (Islam, Khan, and Khan 2021) entre el hígado y órganos adyacentes como el estómago, el bazo o los riñones. Esta escasa discriminabilidad hace necesario aplicar una etapa de preprocesamiento rigurosa para facilitar el posterior aprendizaje automático.

Además, la alta vascularización del hígado añade dificultad al proceso de segmentación, ya que puede resultar complejo distinguir entre parénquima hepático y estructuras vasculares, especialmente cuando la calidad de imagen no es óptima. Este aspecto condiciona la precisión del modelo segmentado y, por tanto, puede afectar directamente al cálculo fiable de las orientaciones necesarias para la ejecución robótica.

Paso 2: Preprocesado de los volúmenes

Antes del entrenamiento de la red, se diseñó un pipeline de preprocesamiento robusto con MONAI (Medical Open Network for AI) (Cardoso et al. 2022) para adaptar los volúmenes del dataset LiTS17 a los requisitos de la arquitectura de la U-Net.

Este proceso incluyó la adición del canal de entrada, la normalización de intensidades, la conversión a tensores compatibles con PyTorch y el aseguramiento del tipo de datos correcto. Uno de los pasos más relevantes fue la interpolación trilineal (Spacingd), que homogeneiza la resolución espacial de todos los volúmenes a un tamaño de voxel estándar, permitiendo redimensionarlos suavemente a una forma fija de $512 \times 512 \times 512$ sin introducir artefactos.

El preprocesado incluyó también un suavizado gaussiano para mejorar la homogeneidad tisular sin perder precisión

anatómica. Esta normalización espacial y de intensidades garantiza una entrada coherente y estandarizada, esencial para la estabilidad del entrenamiento de redes convolucionales profundas.

Paso 3: Entrenamiento de la red neuronal de segmentación
Una vez preprocesados los volúmenes, se procede al entrenamiento de un modelo de segmentación basado en redes neuronales profundas. En este trabajo se utiliza una arquitectura U-Net tridimensional, ampliamente validada en el ámbito médico por su capacidad para capturar tanto contexto global como detalles locales mediante un diseño simétrico de codificador-decodificador con conexiones de salto.

El modelo se ha configurado para segmentar tres clases: fondo (0), hígado (1) y tumor (2). El entrenamiento se ha llevado a cabo utilizando la plataforma MONAI, en combinación con PyTorch, lo que ha permitido un desarrollo flexible y reproducible. Dado el fuerte desbalance entre clases —donde las regiones tumorales ocupan un volumen mucho menor que el fondo o el hígado— se ha empleado una función de pérdida compuesta, DiceCELoss, que combina el coeficiente de Dice con entropía cruzada, equilibrando precisión y sensibilidad durante el aprendizaje. Este entrenamiento supervisado permite a la red identificar patrones morfológicos y de intensidad que diferencian las estructuras de interés, generando segmentaciones precisas sobre nuevos volúmenes no vistos.

Paso 4: Corrección y refinamiento manual en 3D Slicer
Una vez obtenidas las segmentaciones automáticas de hígado y tumores, se importa el resultado en 3D Slicer para realizar una corrección manual de bordes y forma. Esta etapa permite afinar la segmentación de tumores y abordar estructuras más complejas como vasos sanguíneos intrahepáticos y la vena cava inferior, que se segmentan manualmente con el apoyo de los algoritmos y herramientas especializadas que ofrece 3D Slicer.

Paso 5: Construcción del modelo 3D anatómico

Las segmentaciones finales se utilizan para generar un modelo tridimensional del hígado y de las estructuras relevantes (tumores, vasos, vena cava). Sobre este modelo se lleva a cabo la planificación quirúrgica personalizada.

Paso 6: Marcado manual de puntos de planificación quirúrgica

Mediante las herramientas de anotación de 3D Slicer, el cirujano define una secuencia de puntos cartesianos sobre la superficie hepática, considerando criterios clínicos como la cercanía a vasos o márgenes oncológicos. Esta etapa define la trayectoria que seguirá el instrumento quirúrgico.

Paso 7: Cálculo de normales y orientación espacial

Para cada punto definido por el cirujano, se implementó un módulo específico en 3D Slicer que calcula la normal a la superficie hepática (figura 2). Este módulo permite extraer las coordenadas cartesianas del punto junto con los ángulos de orientación (roll, pitch, yaw) de la normal a la superficie,

generando una visualización gráfica de las orientaciones sobre el modelo y exportando todos los datos en formato CSV.

Se ha definido una codificación de los datos exportados con objeto de facilitar la comunicación con el robot. Esta codificación complementa la descripción cinemática de la trayectoria robótica, incorporando un indicador de si la herramienta (en este caso de cauterización) está activa y la velocidad expresada en milímetros por segundo (mm/s). De esta forma, cada línea del .csv tiene la estructura siguiente.

[Pos. Actual][Pos. Destino][Bool acción][Velocidad]

Donde el valor de [Bool acción] se utiliza para separar la trayectoria del tejido siguiendo la normal a la superficie (en caso de no estar activa) o avanzar sobre la superficie (en caso de estar activa). El valor de [Velocidad] se introduce directamente por el cirujano. El cálculo de este valor se considera un trabajo futuro a realizar.

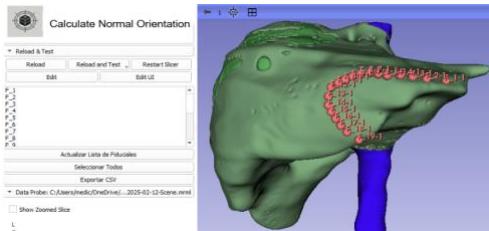


Figura 2: Plug-in desarrollado en Slicer para el cálculo de la normal a la superficie en cada punto landmark.

Paso 8: Evaluación y validación de orientaciones
Como parte del proceso de validación de las trayectorias, se implementó un procedimiento para comparar la orientación entre vectores normales consecutivos mediante cuaterniones (figura 3). El objetivo de esta comprobación es evitar cambios bruscos en la orientación del efecto final del robot. Este cálculo se realizó en 3D Slicer a través de un script en Python que identifica los nodos de tipo línea, extrae sus vectores direccional y calcula la rotación relativa entre ellos. A partir de los cuaterniones obtenidos, se extrae la magnitud escalar del ángulo de rotación θ de cada nueva orientación. Este ángulo sirve como métrica para evaluar la continuidad de la orientación a lo largo de la trayectoria, con el objetivo de detectar posibles variaciones bruscas que podrían afectar la precisión del robot durante la ejecución del procedimiento quirúrgico.

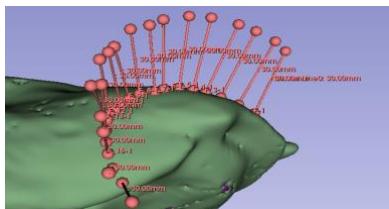


Figura 3: Visualización de las normales proyectadas y su uso como vectores de orientación del efecto robótico.

Paso 9: Transformación de la trayectoria a coordenadas robóticas

La transformación entre el sistema de referencia de Slicer y el quirófano se realiza mediante una matriz de registro rígido, obtenida a partir de un sistema de navegación óptica colocado en posición zenital que nos proporciona la pose del órgano a tratar con relación a la base del robot. En este trabajo se utilizó un sistema OptiTrack Trio V3 (figura 4). El sistema permite capturar la posición de marcadores ópticos fijos en la anatomía del paciente y en el robot, lo que permite calcular la transformación de forma precisa y no invasiva.

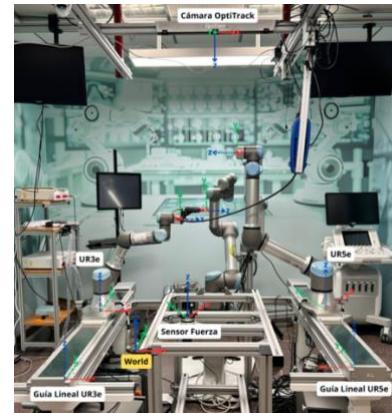


Figura 4: Sistemas de referencia utilizados para el registro quirúrgico.

Paso 10: Publicación en nodo ROS y ejecución robótica

La trayectoria se publica en un nodo ROS personalizado que interpreta los datos exportados desde Slicer y los transforma en comandos para el robot UR5. Cada punto incluye instrucciones completas de movimiento, permitiendo una ejecución continua y precisa de la tarea quirúrgica planificada.

3. Resultados

Para ilustrar la metodología propuesta, se muestra a continuación la planificación y transferencia de una trayectoria de resección del segmento III (sector lateral izquierdo) en un hígado obtenido de imágenes CT.

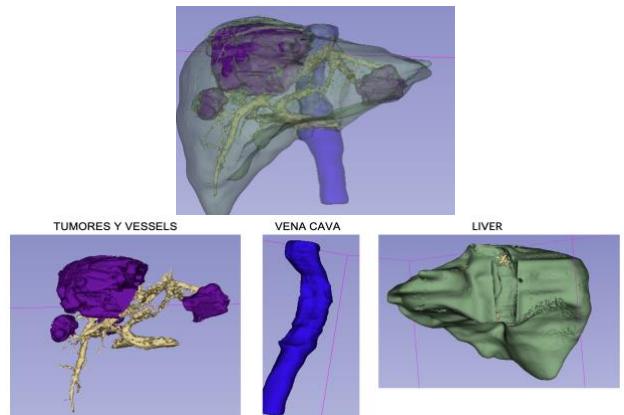


Figura 4: Resultado de la segmentación semiautomática multinivel.

En la Figura 5 se observa que tanto el volumen hepático como las estructuras críticas —incluyendo tumores, vasos intrahepáticos y la vena cava inferior— han sido correctamente identificados y representados. Esta

segmentación proporciona una base sólida para la planificación quirúrgica y demuestra la viabilidad del enfoque combinado automático-manual empleado.

Esta intervención seleccionada corresponde al grado más bajo de dificultad según el sistema de puntuación de Iwate (Barron et al. 2022), (figura 5), ampliamente utilizado para clasificar la complejidad de resecciones hepáticas laparoscópicas. Su simplicidad relativa permite centrar la validación en el proceso técnico de generación de la trayectoria autónoma más que en desafíos clínicos complejos.

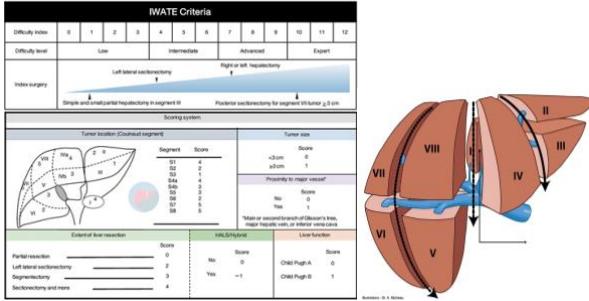


Figura 5: Ilustración de la anatomía del segmento III y criterio de Iwate.

La planificación fue llevada a cabo por un cirujano con experiencia, que utilizó el módulo personalizado en 3D Slicer para definir una secuencia de puntos cartesianos sobre la superficie del hígado. Estos puntos trazan el recorrido que seguiría el efecto final del robot durante la resección superficial del tejido tumoral (ver figura 6).

Una vez definidos manualmente los puntos sobre la superficie hepática, se ejecutó el módulo de cálculo automático de normales y orientación espacial en 3D Slicer. El sistema generó una trayectoria compuesta por 19 puntos (ver figura 3), cada uno con su posición cartesiana, orientación (expresada como ángulos roll, pitch y yaw), y velocidad asociada. Esta información se estructura automáticamente en un formato exportable compatible con el robot, incorporando también datos como la lógica de conexión entre puntos. Además, la trayectoria resultante es visualizable directamente en el entorno de 3D Slicer lo que permite validar de forma gráfica tanto la posición como la orientación de cada punto antes de su envío al sistema robótico.

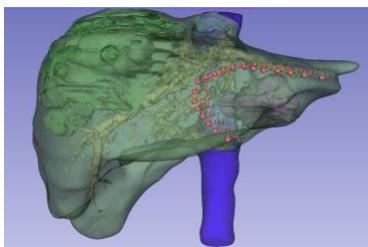


Figura 6: Vista de los puntos de planificación definidos por el cirujano sobre el modelo 3D del hígado.

Con respecto al paso 8, de evaluación y validación de orientaciones, se calculó la magnitud escalar de la rotación θ expresada en cuaterniones. En la Figura 7 se muestra la gráfica de estos valores, donde el eje X representa los pares

de posiciones sucesivas del robot y el eje Y el valor de θ en radianes. La visualización confirma una continuidad angular suave en la trayectoria, con valores bajos y estables incluso tras escalar el eje vertical para destacar variaciones. Esto garantiza movimientos precisos y estables del robot durante la cirugía. Es obvio que este resultado es dependiente de la curvatura de la superficie del órgano sólido, pero introduce un punto en el procedimiento que permitirá añadir criterios de suavidad en el caso de tejidos con otras geometrías particulares.

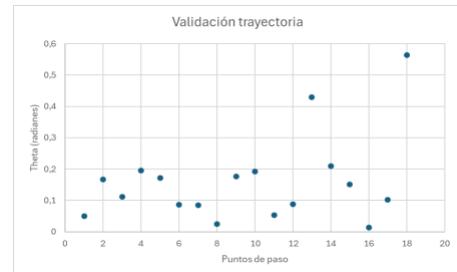


Figura 7: Gráfico de continuidad angular entre orientaciones sucesivas.

Además, durante la ejecución experimental con el robot UR5e, (figura 8), se verificó que la trayectoria enviada desde Slicer era interpretada correctamente en términos de poses y velocidades. La ejecución robótica se llevó a cabo sin errores de interpretación ni desviaciones perceptibles respecto al modelo simulado. El sistema demostró ser estable, reproducible y adecuado para su integración en un flujo quirúrgico real.

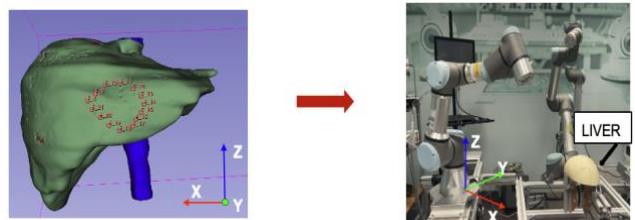


Figura 8: Esquema de la transferencia de la planificación a un sistema real

4. 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 efecto 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.

No obstante, debe señalarse que el rendimiento de la segmentación automática mediante U-Net es altamente sensible a la calidad de imagen. En particular, la

diferenciación de intensidades entre estructuras anatómicas adyacentes influye directamente en la fidelidad del modelo segmentado, lo cual repercute en la precisión del cálculo de normales y, por tanto, en la orientación del efecto robótico.

El caso de validación seleccionado —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 los 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 geométricamente 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.

5. Conclusiones y trabajo futuro

Este artículo ha presentado un sistema semiautomático para la planificación quirúrgica de trayectorias robóticas que incorpora orientación en cada punto definido manualmente por el cirujano. Basado en el cálculo de normales a superficies anatómicas segmentadas, el sistema completa la planificación con información esencial para la ejecución autónoma de tareas quirúrgicas. La implementación en 3D Slicer y su integración con ROS lo convierten en una herramienta práctica, flexible y extensible.

La validación en una resección hepática simple ha mostrado que el sistema es capaz de generar trayectorias suaves, continuas y geométricamente consistentes, reduciendo la intervención manual y minimizando el error humano en la orientación del efecto.

Como líneas futuras de trabajo se propone:
Validar el sistema en procedimientos de mayor complejidad según el índice de Iwate.

Incorporar modelos cinemáticos del robot en el cálculo de orientaciones.

Introducir restricciones clínicas, como la visibilidad del campo quirúrgico o la evitación de colisiones con instrumentos.

Aplicar el sistema en entornos quirúrgicos reales utilizando modelos animales o pacientes simulados.

Este trabajo constituye un paso hacia sistemas quirúrgicos más autónomos, donde la planificación se convierte en una descripción completa de la tarea, transferible, interpretable y ejecutable por robots sin intervención humana directa.

Agradecimientos

This research was funded by the Spanish Government—Agencia Estatal de Investigación (AEI) through the project PID2022-138206OB-C32 and by the Generalitat Valenciana through the project CIPROM/2022/16.

Referencias

- Attanasio, Aleks, Bruno Scaglioni, Elena De Momi, Paolo Fiorini, and Pietro Valdastri. 2021. “Autonomy in Surgical Robotics.” *Annual Review of Control, Robotics, and Autonomous Systems* 4(1): 651–79. doi:10.1146/annurev-control-062420-090543.
- Barron, John O., Danny Orabi, Amika Moro, Cristiano Quintini, Eren Berber, Federico N. Aucejo, Kazunari Sasaki, and Choon-Hyuck D. Kwon. 2022. “Validation of the IWATE Criteria as a Laparoscopic Liver Resection Difficulty Score in a Single North American Cohort.” *Surgical Endoscopy* 36(5): 3601–9. doi:10.1007/s00464-021-08561-4.
- Bilic, Patrick, Patrick Christ, Hongwei Bran Li, Eugene Vorontsov, Avi Ben-Cohen, Georgios Kaassis, Adi Szeksin, et al. 2023. “The Liver Tumor Segmentation Benchmark (LITS).” *Medical Image Analysis* 84: 102680. doi:10.1016/j.media.2022.102680.
- Cardoso, Manuel Jorge, Wenqi Li, Richard Brown, Nic Ma, Eric Kerfoot, Yiheng Wang, Benjamin Murray, et al. 2022. “MONAI: An Open-Source Framework for Deep Learning in Healthcare.” doi:10.48550/arXiv.2211.02701.
- Fedorov, Andriy, Reinhard Beichel, Jayashree Kalpathy-Cramer, Julien Finet, Jean-Christophe Fillion-Robin, Sonia Pujol, Christian Bauer, et al. 2012. “3D Slicer as an Image Computing Platform for the Quantitative Imaging Network.” *Magnetic Resonance Imaging* 30(9): 1323–41. doi:10.1016/j.mri.2012.05.001.
- Heimann, T., B. van Ginneken, M.A. Styner, Y. Arzhaeva, V. Aurich, C. Bauer, A. Beck, et al. 2009. “Comparison and Evaluation of Methods for Liver Segmentation From CT Datasets.” *IEEE Transactions on Medical Imaging* 28(8): 1251–65. doi:10.1109/TMI.2009.2013851.
- Islam, Mohammad, Kaleem Khan, and Muhammad Salman Khan. 2021. “Evaluation of Preprocessing Techniques for U-Net Based Automated Liver Segmentation.” doi:10.48550/arXiv.2103.14301.
- Mountney, Peter, Danail Stoyanov, and Guang-Zhong Yang. 2010. “Three-Dimensional Tissue Deformation Recovery and Tracking.” *IEEE Signal Processing Magazine* 27(4): 14–24. doi:10.1109/MSP.2010.936728.
- Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. 2015. “U-Net: Convolutional Networks for Biomedical Image Segmentation.” In , 234–41. doi:10.1007/978-3-319-24574-4_28.
- Ungi, Tamas, Andras Lasso, and Gabor Fichtinger. 2016. “Open-Source Platforms for Navigated Image-Guided Interventions.” *Medical Image Analysis* 33: 181–86. doi:10.1016/j.media.2016.06.011.