

# Jornadas de Automática

## Aspirador quirúrgico autónomo para una intervención de cirugía laparoscópica

Rivas-Blanco, Irene.<sup>a,\*</sup>, Góngora-Rodríguez, Eva.<sup>a</sup>, López-Casado, Carmen<sup>a</sup>, Caballero-Roldán, Manuel

<sup>a</sup>Instituto Universitario de Investigación en Ingeniería Mecatrónica y Sistemas Ciberfísicos (IMECH.UMA), Universidad de Málaga, Andalucía Tech, 29070 Málaga, España.

**To cite this article:** Rivas-Blanco, I., Gongora-Rodriguez, E., Lopez-Casado, C., Caballero-Roldan, M., 2024. Surgical Robot for Autonomous Bleeding Suction.

Jornadas de Automática, 45. <https://doi.org/10.17979/ja-cea.2024.45.10924>

### Resumen

La automatización de tareas quirúrgicas representa un campo de investigación en auge. En las últimas décadas, la integración de la robótica y la inteligencia artificial en los entornos quirúrgicos ha mostrado un gran potencial para mejorar la precisión, eficiencia y seguridad de los procedimientos quirúrgicos. La capacidad de los sistemas para realizar tareas repetitivas con gran precisión y sin fatiga, combinada con su capacidad para procesar y analizar grandes volúmenes de datos en tiempo real, ofrece oportunidades sin precedentes para transformar la práctica quirúrgica. En este trabajo se pretende dar un paso más en el campo de los robots quirúrgicos autónomos desarrollando un asistente robótico para el aspirado automático de sangrado durante una intervención laparoscópica. Para ello se ha desarrollado un algoritmo de detección de sangrado basado en una red neuronal convolucional. Además, se ha automatizado un aspirador quirúrgico convencional, de manera que pueda realizar su función de forma automática acoplado al efector final de un brazo robótico.

*Palabras clave:* Robótica, Inteligencia artificial, Mecatrónica, Sistemas autónomos.

### Surgical Robot for Autonomous Bleeding Suction

#### Abstract

The automation of surgical tasks represents a growing field of research. In recent decades, the integration of robotics and artificial intelligence in surgical environments has shown great potential to improve the accuracy, efficiency and safety of surgical procedures. The ability of automated systems to perform repetitive tasks with high accuracy and without fatigue, combined with their ability to process and analyze large volumes of data in real time, offers unprecedented opportunities to transform surgical practice. The aim of this work is to take a step forward in the field of autonomous surgical robots by developing a robotic assistant for the automatic aspiration of bleeding during laparoscopic surgery. For this purpose, a bleeding detection algorithm based on a convolutional neural network has been developed. In addition, a conventional surgical aspirator has been automated so that it can perform its function automatically coupled to the end effector of a robotic arm.

*Keywords:* Robotics, Artificial intelligence, Mechatronics, Autonomous systems.

## 1. Introducción

Hoy en día, la cirugía mínimamente invasiva, o cirugía laparoscópica, se ha convertido en la práctica habitual en numerosas intervenciones quirúrgicas, con grandes beneficios tanto estéticos como de recuperación para los pacientes. Sin embargo, este tipo de intervenciones introduce nuevos retos para el

personal médico, que van desde la falta de visión directa y de sensación táctil hasta la limitación en el movimiento de las herramientas. La cirugía robótica ha permitido superar muchas de estas limitaciones así como mejorar las habilidades de los cirujanos gracias a instrumental más preciso y más intuitivo de manejar. A pesar de los elevados costes asociados, la demanda de la cirugía robótica sigue creciendo de forma

\*Autor para correspondencia: [irivas@uma.es](mailto:irivas@uma.es)  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

exponencial, y los sistemas de salud tanto públicos como privados están apostando por integrar sistemas robóticos en sus procedimientos Perez and Schwartzberg (2019). La eficiencia de estos sistemas frente a la cirugía convencional está ampliamente demostrada Singh et al. (2018). Sin embargo, a día de hoy este tipo de sistemas se limitan a replicar los movimientos que realiza un cirujano o cirujana en una consola de teleoperación. El uso de robots colaborativos, que puedan realizar cierto tipo de tareas de forma autónoma, permitiría reducir la carga mental del cirujano/a, permitiéndole concentrarse en las maniobras más complejas, mientras un asistente robótico realiza tareas auxiliares de apoyo. Además, en intervenciones convencionales, este tipo de tareas, que suelen ser muy repetitivas y tediosas, las realiza un cirujano/a auxiliar. Por tanto, la automatización de ciertas tareas permitiría liberar a este personal auxiliar, que podría dedicarse a otras tareas más complejas o estar disponible para otra intervención. Además, las tareas auxiliares, como el manejo del endoscopio o la retracción de órganos, requieren que la acción se mantenga durante un largo periodo de tiempo, por lo que cuando las ejecuta un humano es habitual que el cansancio y el estrés provoquen temblores en el instrumental o cambios indeseados de su posición. Es por ello que en los últimos años ha surgido un creciente interés en el desarrollo de metodologías que permitan a los robots colaborar de forma autónoma con el personal médico, dotándolos de las herramientas necesarias para tomar cierto tipo de decisiones y actuar con autonomía. Es decir, la tendencia actual de la robótica quirúrgica es el diseño de robots que no actúen solo como manos del cirujano, sino que actúen como compañeros.

El guiado del endoscopio es la tarea que tradicionalmente ha suscitado mayor interés para su automatización, ya que es una tarea sencilla que reduce considerablemente la carga mental del personal médico y le permite centrar toda su atención en el movimiento del instrumental quirúrgico. Los interfaces de comunicación directa, como comandos de voz Estebanez et al. (2011) Voros et al. (2010), movimientos de cabeza Stolzenburg et al. (2011) o guiado mediante la vista Noonan et al. (2010), han logrado relevar al asistente humano de esta tediosa tarea, proporcionando además mayor estabilidad a la imagen. Sin embargo, estos métodos requieren una atención continua del cirujano/a, que debe comandar en todo momento los movimientos de la cámara. En este sentido, el guiado de la cámara mediante técnicas de visión que siguen la punta de los instrumentos o mediante técnicas de aprendizaje son métodos que dotan al robot de mayor autonomía y no requiere la supervisión directa del cirujano Casals et al. (1996) Rivas-Blanco et al. (2018).

Otras tareas quirúrgicas que han sido objeto de automatización son aquellas que son comunes a numerosas intervenciones quirúrgicas y que tienen un alto grado de estandarización, como la retracción de órganos o tejido Attanasio et al. (2020) Nguyen et al. (2019) Seita et al. (2018), la sutura Pedram et al. (2017) Mikada et al. (2020), o el anudado Chen et al. (2016). El modelado de estas tareas se puede hacer manualmente de forma explícita mediante modelos y parámetros que definen un conjunto de relaciones geométricas y trayectorias a seguir, o de forma implícita mediante estrategias de aprendizaje automático, más conocidas como machine learning. Debido a la alta variabilidad que existe entre diferentes pacientes, órganos y tejidos, y el alto consumo de tiempo

y esfuerzo que requiere el primer enfoque, la estrategia más común para el modelado de tareas quirúrgicas es mediante técnicas de aprendizaje. Este enfoque tiene la ventaja de que es una metodología muy general que se puede aplicar a una amplia gama de problemas y sub-tareas, de modo que evita el complejo modelado de las propiedades físicas y biomecánicas de este tipo de entornos, y además está basado en observaciones reales obtenidas durante los entrenamientos Kassahun et al. (2016). La técnica más común de Machine Learning para la automatización de tareas quirúrgicas es el aprendizaje por demostración. Con este enfoque, el robot aprende a realizar una maniobra a través de un conjunto de observaciones o entrenamientos que realiza un cirujano experto Osa et al. (2014) Pérez del Pulgar (2015).

En los últimos años, las metodologías de automatización de tareas basadas en aprendizaje profundo, o Deep Learning, han crecido exponencialmente en todos los campos de la robótica, y la robótica quirúrgica no es una excepción. Este tipo de técnicas se fundamentan en el aprendizaje automático a partir un gran conjunto de datos, generalmente en forma de imágenes. En los últimos años, la comunidad científica ha realizado un gran esfuerzo por crear grandes bases de datos de intervenciones quirúrgicas, que puedan ser utilizadas para avanzar en el ámbito de la automatización en este tipo de entornos Rivas-Blanco et al. (2021). Así, existen numerosos trabajos que han desarrollado técnicas para el análisis automático de imágenes endoscópicas para clasificación y segmentación de instrumental quirúrgico Wang et al. (2017) Garcia-Peraza-Herrera et al. (2017) Sarikaya et al. (2017), así como para la detección de estructuras anatómicas más complejas, como la segmentación del hígado Fu et al. (2019) o la detección de pólipos en imágenes colonoscópicas Hwang et al. (2019). Las técnicas de aprendizaje profundo también se han utilizado para analizar las maniobras quirúrgicas con objeto de automatizar partes de los procedimientos quirúrgicos, y de crear sistemas capaces de supervisar los procedimientos y tomar cierto tipo de decisiones Petscharnig et al. (2018) Gao et al. (2020) Twinanda et al. (2017). Esta es la idea del proyecto europeo Smart Autonomous Robotic Assistant Surgeon (Saras), que pretende ir un paso más allá en los sistemas robóticos cognitivos mediante un asistente quirúrgico capaz de analizar la situación actual de un procedimiento para proporcionar asistencia colaborativa al personal médico automatizando ciertas tareas Setti et al. (2019).

En la presente propuesta se pretende avanzar en el campo de la robótica médica mediante la automatización de la aspiración de sangrado durante una intervención laparoscópica, una maniobra común a la mayoría de procedimientos quirúrgicos, y poco explorada hasta el momento. En la mayoría de las intervenciones quirúrgicas, las maniobras realizadas para completar el procedimiento provocan sangrados de las estructuras anatómicas, lo que conlleva que la zona de la intervención quede cubierta de sangre. Cuando esto sucede es necesario eliminarla mediante un aspirador quirúrgico para volver a hacer la zona visible, así como localizar la fuente del sangrado para cauterizarla.

## 2. Definición del escenario y arquitectura global

La Figura 1 muestra el escenario propuesto en este trabajo. En ella se muestra una imagen de un procedimiento quirúrgico habitual en la que aparecen las herramientas que utiliza el cirujano o cirujana para realizar la operación, el endoscopio que permite visualizar la zona de trabajo, y la torre de laparoscopia en la que se muestra la imagen endoscópica. Tanto el instrumental quirúrgico como el endoscopio pueden manejarse de forma manual o de forma teleoperada en caso de cirugía robótica. El asistente robótico está formado por un aspirador automático manejado por un brazo robótico.

El procedimiento de colaboración humano-máquina para el aspirado autónomo de sangrado implica: (1) la detección y caracterización de sangrado a partir del análisis de la imagen endoscópica, (2) la navegación autónoma del aspirador hasta la zona de sangrado sin colisionar con el resto de instrumental quirúrgico, y (3) la actuación del aspirador automático para limpiar la zona. Por tanto, el sistema propuesto deberá tener las siguientes funcionalidades:

- Algoritmo de detección del sangrado. Este algoritmo analizará la imagen endoscópica y detectará la presencia y zona de sangrado.
- Planificación de movimientos de alto nivel para llevar a cabo las acciones comandadas por el sistema supervisor. Este planificador se encargará tanto de comandar las primitivas de movimiento al brazo robótico para que alcance de forma segura la zona de sangrado, como de las primitivas características de la maniobra de aspirado: control de la fuerza de contacto de la herramienta, control de la fuerza de succión, etc.
- Interfaz humano-máquina (HMI) que permita al cirujano interactuar de forma directa con el sistema para comandar, corregir o modificar su comportamiento.

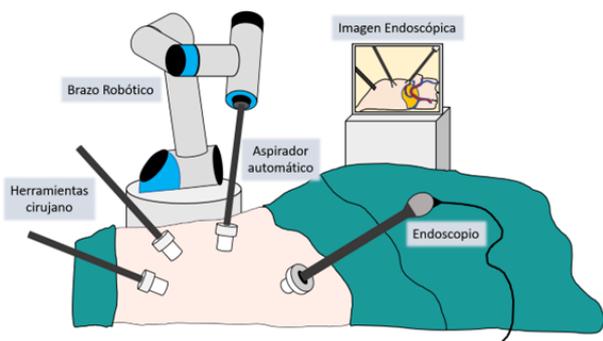


Figura 1: Sistema robótico colaborativo para el aspirado autónomo de sangrado durante una intervención laparoscópica.

La figura 2 muestra la arquitectura global de un asistente robótico autónomo para el aspirado de sangrado. El planificador global está formado por un algoritmo de detección de sangrado, que recibe la imagen endoscópica y devuelve la zona de sangrado, junto con un sistema de decisión que, a partir de la imagen endoscópica y la zona de sangrado detectada,

decide si el aspirador debe actuar o no. El sistema de planificación de movimientos es el encargado de comandar las primitivas de movimiento del brazo robótico, así como de activar y desactivar el aspirador. Este planificador de movimientos también recibe órdenes del dispositivo háptico que maneja el asistente, mediante el que se puede comandar el movimiento del aspirador o corregir su posición durante el funcionamiento autónomo del mismo. Por otro lado, la interfaz HMI es la consola del asistente, y está formada por unas gafas de realidad aumentada, que mostrarán tanto la imagen endoscópica como información del estado del sistema (zona de sangrado y actuación del aspirador), y un dispositivo háptico para comandar los movimientos del aspirador. Finalmente, el aspirador robótico autónomo está formado por un aspirador automático acoplado a un brazo robótico.

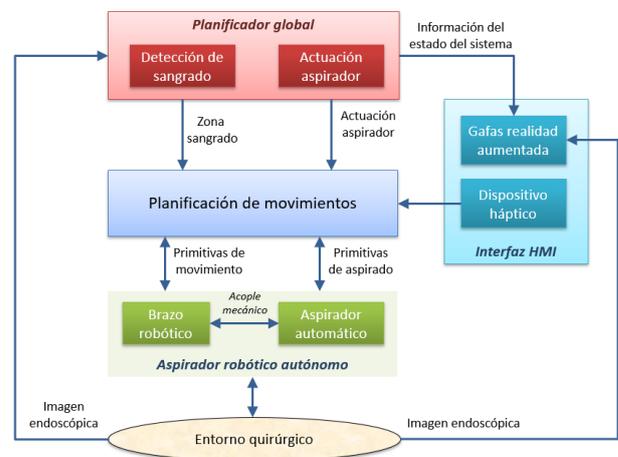


Figura 2: Arquitectura global de un asistente robótico autónomo para el aspirado de sangrado.

## 3. Diseño del aspirador automático

El aspirador automático se ha diseñado automatizando un aspirador quirúrgico convencional. En concreto, se ha utilizado la bomba de aspiración portátil New Aspirate de la compañía CA-MI junto con un tubo de aspiración de laparoscopia donado por el Hospital Materno-Infantil de Málaga. Para automatizar la función de aspirado se ha utilizado una electroválvula junto con un Arduino Mega 2560 Rev3. De esta manera, tal y como se muestra en la Figura 3, la electroválvula se conecta, de un lado con el tubo de aspiración y del otro con la bomba, permitiendo que el aspirado se produzca de forma automática a través del Arduino.

Para acoplar este sistema a un brazo robótico, en concreto a un robot Kuka modelo LBR iiwa 7 R800, se ha diseñado la pieza mostrada en la Figura 4. Esta pieza tiene un hueco interior para acoplar la electroválvula (modelo ST-DA 1/8" latón FKM de la marca JP Fluid control) y un orificio de salida para el tubo de aspiración. En su parte posterior, la pieza está diseñada para atornillarse al efector final del Kuka.

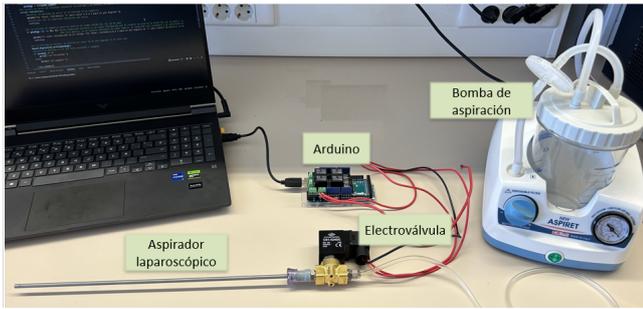


Figura 3: Conexión del aspirador automático.

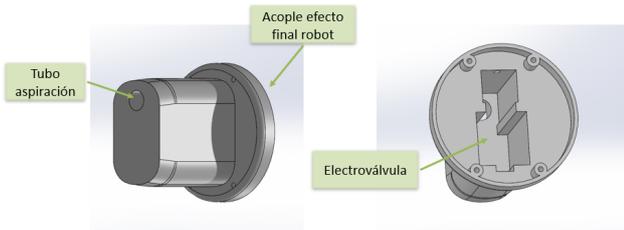


Figura 4: Arquitectura global de un asistente robótico autónomo para el aspirado de sangrado.

#### 4. Algoritmo de detección de sangrado

La detección de sangrado en imágenes endoscópicas es fundamental en el contexto de la aspiración autónoma durante intervenciones laparoscópicas. Una identificación precisa y rápida del sangrado no solo facilita la limpieza del área de intervención, sino que también permite localizar y controlar la fuente del sangrado, mejorando así la seguridad y eficiencia del procedimiento quirúrgico. Para abordar esta tarea, se ha desarrollado una red neuronal convolucional (CNN) basada en la arquitectura U-Net, reconocida por su efectividad en la segmentación de imágenes médicas Yin et al. (2022). Esta red es particularmente adecuada debido a su capacidad para capturar características globales y locales, permitiendo una segmentación precisa del sangrado.

En este trabajo se ha utilizado la base de datos presentada en (Rabbani et al., 2022), que contiene 750 imágenes de cirugías ginecológicas. Estas imágenes han sido etiquetadas con máscaras de la zona de sangrado por cirujanos junior revisadas por cirujanos experimentados. Para mejorar la generalización y aumentar el tamaño del conjunto de datos, se han aplicado las técnicas de aumentación de volteo horizontal y redimensionamiento de los datos, doblando el número de imágenes disponibles. Estas técnicas ayudan a simular diversas condiciones que se pueden encontrar en imágenes endoscópicas reales, aumentando así la robustez del modelo.

Para implementar la metodología se ha empleado Tensorflow y OpenCv. Durante la fase de preprocesamiento, las imágenes y máscaras han sido redimensionadas a un tamaño uniforme de 256x256 píxeles para normalizar las dimensiones de entrada al modelo. Las imágenes se cargan y se convierten a RGB, mientras que las máscaras asociadas se cargan en escala de grises, se normalizan y se binarizan. Seguidamente, se realiza una división de los datos en conjuntos de entrenamiento,

validación y prueba utilizando una proporción del 80 %, 10 % y 10 %, respectivamente. Para el entrenamiento se ha empleado la función de pérdida Binary Cross-Entropy, optimizada mediante el algoritmo Adam. El entrenamiento se ha llevado a cabo durante 45 épocas con un tamaño de lote de 16. Se ha elegido este conjunto de hiperparámetros para equilibrar la velocidad de convergencia con la estabilidad del entrenamiento. Todos los experimentos se han realizado en una máquina equipada con una GPU NVIDIA Tesla V100 DGX 32GB, con una media de tiempo de entrenamiento de 13 minutos.

Para mostrar el rendimiento del modelo se ha analizado la precisión (accuracy), obteniéndose un 98.9 % y 98.1 % en los conjuntos de validación y de prueba, respectivamente. Esto indica que el modelo es eficaz en distinguir áreas de sangrado de otras estructuras anatómicas. En la Figura 5 se muestran los resultados obtenidos para cuatro imágenes del conjunto de prueba. Las predicciones realizadas muestran que el modelo es capaz de segmentar adecuadamente las áreas de interés incluso en condiciones clínicas desafiantes.

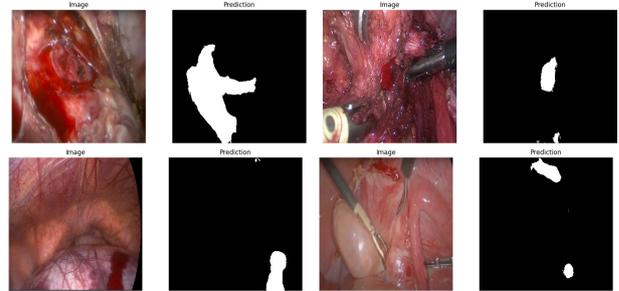


Figura 5: Resultado de la predicción de sangrado en imágenes del conjunto de prueba

La Figura 6 muestra la evolución de la función de pérdida y la precisión durante el entrenamiento de la red. La función de pérdida que se ha empleado es la entropía cruzada (cross-entropy loss), la cual disminuye constantemente a lo largo del proceso de entrenamiento. Inicialmente, la pérdida comienza en 0.25 y se reduce a 0.055, indicando que el modelo se ajusta progresivamente mejor a los datos de entrenamiento. La reducción constante en la pérdida sugiere que el modelo no está sobreajustando (overfitting) y que está aprendiendo patrones relevantes de los datos.

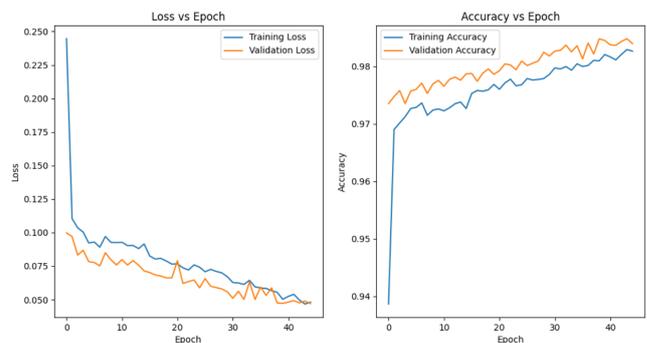


Figura 6: Evolución de la función de pérdida y la precisión durante el entrenamiento de la red.

## 5. Implementación

### 5.1. Interfaz Humano-Máquina

Como se ha indicado anteriormente, la Interfaz Humano-Máquina de este sistema está formado por unas gafas de realidad virtual (RV) y un dispositivo háptico. En concreto se ha utilizado el sistema Meta Quest 2 (Raymer et al., 2023) formado por unas gafas y dos controladores hápticos, utilizando solo uno de ellos como dispositivo háptico del sistema. Las gafas se van a utilizar como dispositivo de visualización, es decir, en las gafas se proyectará el escenario quirúrgico que transmite el endoscopio. Por otro lado, el dispositivo háptico se utilizará tanto para comandar la posición del aspirador como para activar la función de aspirado.

Aunque el sistema de RV utilizado permite su desarrollo en distintas plataformas, el entorno elegido ha sido Unity. Dentro de los múltiples paquetes que proporciona el equipo de Unity Technologies, los paquetes proporcionados por Unity Robotics hacen posible la comunicación vía ROS del sistema de RV con el brazo robótico. En concreto, el conector ROS-TCP permite la comunicación entre aplicaciones desarrolladas en Unity y nodos ROS, intercambiando *topics* como si fuese un nodo nativo. La información proporcionada por el dispositivo háptico al sistema global es por un lado la posición del mismo de manera diferencial y por otro lado, la habilitación del movimiento del brazo robótico a través del háptico. En la primera se transmite continuamente un *topic* que lleva información sobre la diferencia de posición (XYZ) entre instantes de tiempo consecutivos; en la segunda, se transmite un *booleano* que indica si el brazo robótico ha de desplazarse o no siguiendo el incremento de posición proporcionado por el primero.



Figura 7: Comunicación del sistema vía ROS mediante el conector ROS-TCP, que permite la comunicación entre Unity y el nodo del robot implementado en ROS.

### 5.2. Arquitectura software

En la Figura 8 se muestra la arquitectura software del sistema, basada en el sistema operativo ROS. En ella se muestran los nodos de ROS que componen el sistema junto con el tipo de información de entrada y salida de cada uno de ellos. Por un lado, el módulo de percepción está formado por el nodo *Cámara*, que envía la imagen del endoscopio al resto del sistema. El módulo HMI está formado por el sistema de realidad virtual, que incluye tanto las gafas de RV que reciben la imagen, como el dispositivo háptico que comanda el aspirador. El planificador global implementa el algoritmo de detección de sangrado, mientras que el planificador local es el encargado de calcular la posición del aspirador en función de la zona de sangrado detectada. Finalmente, la posición del aspirador se traduce en el correspondiente movimiento del robot mediante un controlador, que implementa el movimiento alrededor del

punto de fulcro, mientras que la activación del aspirador se recibe en el Arduino que controla la función de aspirado.

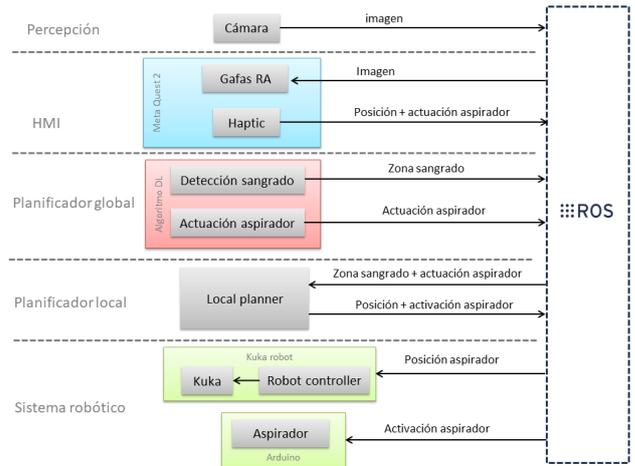


Figura 8: Arquitectura software del sistema.

## 6. Conclusiones

En este trabajo se ha presentado un asistente robótico autónomo para el aspirado de sangrado durante una intervención de cirugía laparoscópica. Se ha presentado tanto la arquitectura hardware como la arquitectura software basada en ROS del sistema. El diseño del aspirador automático permite comandar la aspiración mediante un Arduino, que conectado a ROS, permite integrar la función de aspirado en la arquitectura completa. Además, se propone una interfaz HMI basada en unas gafas de realidad virtual para mostrar la imagen del endoscopio y un dispositivo háptico para comandar el movimiento del aspirador. El modelo de segmentación de sangrado basado en la arquitectura U-Net ha demostrado ser efectivo para la tarea de segmentación automática, obteniéndose una precisión del 98 %. Este estudio demuestra el potencial de las redes neuronales convolucionales profundas en el ámbito médico, facilitando el análisis y diagnóstico de sangrados de manera más eficiente y precisa.

Como trabajo futuro, se pretende aumentar la funcionalidad de la interfaz incorporando información de utilidad para el personal médico en la imagen mostrada en las gafas de realidad virtual, así como desarrollar estrategias basadas en técnicas de aprendizaje para el movimiento autónomo del aspirador.

## Agradecimientos

Esta investigación ha sido financiada por el Ministerio de Ciencia e Innovación a través del Proyecto Nacional PID2021-125050OA-I00.

## Referencias

- Attanasio, A., Scaglioni, B., Leonetti, M., Frangi, A. F., Cross, W., Biyani, C. S., Valdastrì, P., 2020. Autonomous Tissue Retraction in Robotic Assisted Minimally Invasive Surgery - A Feasibility Study. *IEEE Robotics and Automation Letters* 5 (4). DOI: 10.1109/LRA.2020.3013914

- Casals, A., Amat, J., Laporte, E., 1996. Automatic Guidance of an Assistant Robot in Laparoscopic Surgery. *IEEE International Conference on Robotics and Automation Minneapolis*, 895–900.
- Chen, J., Lau, H., Xu, W., Ren, H., 2016. Towards transferring skills to flexible surgical robots with programming by demonstration and reinforcement learning. In: *2016 Eighth International Conference on Advanced Computational Intelligence (ICACI)*. IEEE, pp. 378–384.  
URL: <http://ieeexplore.ieee.org/document/7449855/>  
DOI: 10.1109/ICACI.2016.7449855
- Estebanez, B., del Saz-Orozco, P., García-Morales, I., Muñoz, V. F., 4 2011. Interfaz multimodal para un asistente robótico quirúrgico: uso de reconocimiento de maniobras quirúrgicas. *Revista Iberoamericana de Automática e Informática Industrial RIAI* 8 (2), 24–34.  
URL: <https://www.sciencedirect.com/science/article/pii/S1697791211700231>  
DOI: 10.1016/S1697-7912(11)70023-1
- Fu, Y., Robu, M. R., Koo, B., Schneider, C., van Laarhoven, S., Stoyanov, D., Davidson, B., Clarkson, M. J., Hu, Y., 2019. More unlabelled data or label more data? a study on semi-supervised laparoscopic image segmentation. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Vol. 11795 LNCS.  
DOI: 10.1007/978-3-030-33391-1\_20
- Gao, X., Jin, Y., Dou, Q., Heng, P. A., 2020. Automatic Gesture Recognition in Robot-assisted Surgery with Reinforcement Learning and Tree Search. In: *Proceedings - IEEE International Conference on Robotics and Automation*.  
DOI: 10.1109/ICRA40945.2020.9196674
- García-Peraza-Herrera, L. C., Li, W., Fidon, L., Gruijthuisen, C., Devreker, A., Attilakos, G., Deprest, J., Poorten, E. V., Stoyanov, D., Vercauteren, T., Ourselin, S., 2017. ToolNet: Holistically-nested real-time segmentation of robotic surgical tools. *IEEE International Conference on Intelligent Robots and Systems 2017-Septe*, 5717–5722.  
DOI: 10.1109/IR08.2017.8206462
- Hwang, M., Wang, D., Jiang, W. C., Pan, X., Fu, D., Hwang, K. S., Ding, K., 2019. An Adaptive Regularization Approach to Colonoscopic Polyp Detection Using a Cascaded Structure of Encoder–Decoders. *International Journal of Fuzzy Systems* 21 (7).  
DOI: 10.1007/s40815-019-00694-y
- Kassahun, Y., Yu, B., Tibebu, A. T., Stoyanov, D., Giannarou, S., Metzen, J. J. H., Vander Poorten, E., 4 2016. Surgical robotics beyond enhanced dexterity instrumentation: a survey of machine learning techniques and their role in intelligent and autonomous surgical actions. *International Journal of Computer Assisted Radiology and Surgery* 11 (4), 553–568.  
URL: <http://link.springer.com/10.1007/s11548-015-1305-z>  
DOI: 10.1007/s11548-015-1305-z
- Mikada, T., Kanno, T., Kawase, T., Miyazaki, T., Kawashima, K., 2020. Suturing support by human cooperative robot control using deep learning. *IEEE Access* 8.  
DOI: 10.1109/ACCESS.2020.3023786
- Nguyen, N. D., Nguyen, T., Nahavandi, S., Bhatti, A., Guest, G., 2019. Manipulating soft tissues by deep reinforcement learning for autonomous robotic surgery. In: *SysCon 2019 - 13th Annual IEEE International Systems Conference, Proceedings*.  
DOI: 10.1109/SYSCON.2019.8836924
- Noonan, D., Mylonas, G., Shang, J., Payne, C., Darzi, A., Yang, G.-Z., 9 2010. Gaze contingent control for an articulated mechatronic laparoscope. In: *2010 3rd IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechanics*. IEEE, pp. 759–764.  
URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5628078>  
DOI: 10.1109/BIOROB.2010.5628078
- Osa, T., Sugita, N., Mamoru, M., 2014. Online Trajectory Planning in Dynamic Environments for Surgical Task Automation. *Robotics: Science and Systems (RSS)*.
- Pedram, S. A., Ferguson, P., Ma, J., Dutson, E., Rosen, J., 5 2017. Autonomous suturing via surgical robot: An algorithm for optimal selection of needle diameter, shape, and path. In: *2017 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE, pp. 2391–2398.  
URL: <http://ieeexplore.ieee.org/document/7989278/>  
DOI: 10.1109/ICRA.2017.7989278
- Perez, R. E., Schwaitzberg, S. D., 5 2019. Robotic surgery: finding value in 2019 and beyond. *Annals of Laparoscopic and Endoscopic Surgery* 4 (0), 51–51.  
URL: <https://ales.amegroups.com/article/view/5205/htmlhttps://ales.amegroups.com/article/view/5205>  
DOI: 10.21037/ALES.2019.05.02
- Pérez del Pulgar, C., 2015. Smart navigation in surgical robotics. Ph.D. thesis, Universidad de Málaga.
- Petschamig, S., Schoffmann, K., Benois-Pineau, J., Chaabouni, S., Keckstein, J., 2018. Early and Late Fusion of Temporal Information for Classification of Surgical Actions in Laparoscopic Gynecology. In: *Proceedings - IEEE Symposium on Computer-Based Medical Systems*. Vol. 2018-June.  
DOI: 10.1109/CBMS.2018.00071
- Rabbani, N., Seve, C., Bourdel, N., Bartoli, A., 2022. Video-based Computer-aided Laparoscopic Bleeding Management: a Space-time Memory Neural Network with Positional Encoding and Adversarial Domain Adaptation. In: *Proceedings of Machine Learning Research*. Vol. 172.
- Raymer, E., MacDermott, , Akinbi, A., 2023. Virtual reality forensics: Forensic analysis of Meta Quest 2. *Forensic Science International: Digital Investigation* 47.  
DOI: 10.1016/j.fsidi.2023.301658
- Rivas-Blanco, I., Lopez-Casado, C., Perez-del Pulgar, C. J., Garcia-Vacas, F., Fraile, J. C., Munoz, V. F., 4 2018. Smart Cable-Driven Camera Robotic Assistant. *IEEE Transactions on Human-Machine Systems* 48 (2), 183–196.  
URL: <http://ieeexplore.ieee.org/document/8107576/>  
DOI: 10.1109/THMS.2017.2767286
- Rivas-Blanco, I., Perez-Del-Pulgar, C. J., Garcia-Morales, I., Munoz, V. F., Rivas-Blanco, I., 2021. A Review on Deep Learning in Minimally Invasive Surgery. *IEEE Access* 9, 48658–48678.  
DOI: 10.1109/ACCESS.2021.3068852
- Sarikaya, D., Corso, J. J., Guru, K. A., 2017. Detection and Localization of Robotic Tools in Robot-Assisted Surgery Videos Using Deep Neural Networks for Region Proposal and Detection. *IEEE Transactions on Medical Imaging* 36 (7), 1542–1549.  
DOI: 10.1109/TMI.2017.2665671
- Seita, D., Krishnan, S., Fox, R., McKinley, S., Canny, J., Goldberg, K., 2018. Fast and Reliable Autonomous Surgical Debridement with Cable-Driven Robots Using a Two-Phase Calibration Procedure. In: *Proceedings - IEEE International Conference on Robotics and Automation*.  
DOI: 10.1109/ICRA.2018.8460583
- Setti, F., Oleari, E., Leporini, A., Trojaniello, D., Sanna, A., Capitanio, U., Montorsi, F., Salonia, A., Muradore, R., 2019. A Multirobots Teleoperated Platform for Artificial Intelligence Training Data Collection in Minimally Invasive Surgery. In: *2019 International Symposium on Medical Robotics, ISMR 2019*.  
DOI: 10.1109/ISMR.2019.8710209
- Singh, H., Modi, H. N., Ranjan, S., Dilley, J. W., Airantzis, D., Yang, G. Z., Darzi, A., Lef, D. R., 10 2018. Robotic Surgery Improves Technical Performance and Enhances Prefrontal Activation During High Temporal Demand. *Annals of Biomedical Engineering* 46 (10), 1621–1636.  
URL: <https://link.springer.com/article/10.1007/s10439-018-2049-z>  
DOI: 10.1007/S10439-018-2049-Z/FIGURES/5
- Stolzenburg, J.-U., Franz, T., Kallidonis, P., Minh, D., Dietel, A., Hicks, J., Nicolaus, M., Al-Aown, A., Liatsikos, E., 3 2011. Comparison of the FreeHand® robotic camera holder with human assistants during endoscopic extraperitoneal radical prostatectomy. *BJU International* 107 (6), 970–974.  
URL: <http://doi.wiley.com/10.1111/j.1464-410X.2010.09656.x>  
DOI: 10.1111/j.1464-410X.2010.09656.x
- Twinanda, A. P., Shehata, S., Mutter, D., Marescaux, J., De Mathelin, M., Padoy, N., 2017. EndoNet: A Deep Architecture for Recognition Tasks on Laparoscopic Videos. *IEEE Transactions on Medical Imaging* 36 (1), 86–97.  
DOI: 10.1109/TMI.2016.2593957
- Voros, S., Haber, G.-P., Menudet, J.-F., Long, J.-A., Cinquin, P., 12 2010. ViKY Robotic Scope Holder: Initial Clinical Experience and Preliminary Results Using Instrument Tracking. *IEEE/ASME Transactions on Mechatronics*.  
URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5638147>  
DOI: 10.1109/TMECH.2010.2080683
- Wang, S., Raju, A., Huang, J., 2017. Deep learning based multi-label classification for surgical tool presence detection in laparoscopic videos. *Proceedings - International Symposium on Biomedical Imaging*, 620–623.  
DOI: 10.1109/ISBI.2017.7950597
- Yin, X. X., Sun, L., Fu, Y., Lu, R., Zhang, Y., 2022. U-Net-Based Medical Image Segmentation.  
DOI: 10.1155/2022/4189781