

Cascaded 2-stage 3D U-Net for Couinaud hepatic segmentation

Velez, L. Fabricio¹ , Nari, Gustavo² , and Gonzalez-Montoro, Nehuen¹ 

¹ Facultad de Ciencias Exactas, Físicas y Naturales, Universidad Nacional de Córdoba, Av. Vélez Sarsfield 1611, Córdoba, Argentina

² Hospital Tránsito Cáceres de Allende, Buchardo 1250, Córdoba, Argentina
fabricio.velez@mi.unc.edu.ar, nehuen.gonzalez@unc.edu.ar

Abstract. This work proposes a deep learning framework for the automatic segmentation of the liver and its eight Couinaud segments from computed tomography (CT) volumes using a cascaded learning strategy. The proposed approach decomposes the segmentation task into two sequential stages. First, a binary 3D U-Net model identifies the liver region within the abdominal CT volume. Then, a second 3D U-Net performs multi-class segmentation of the Couinaud segments using the CT volume restricted to the predicted liver region.

By removing irrelevant anatomical structures from the input of the second model, the proposed cascade simplifies the learning problem and allows the network to focus on intrahepatic anatomical patterns. This design reduces contextual variability and encourages specialization of the segmentation model for the internal organization of the liver.

The proposed pipeline achieved a Dice score of 97.63 % and an IoU of 95.39 % for liver segmentation, and a Dice score of 81.56 % and an IoU of 70.41 % for Couinaud segment segmentation on the test set. These results suggest that cascaded learning strategies can improve hierarchical anatomical segmentation tasks in volumetric medical imaging.

Keywords: Liver segmentation, Couinaud classification, Deep Learning, Computed Tomography, 3D U-Net

U-Net 3D de dos etapas en cascada para la segmentación hepática según Couinaud

Abstract. En este trabajo se propone un enfoque basado en aprendizaje profundo para la segmentación automática del hígado y de sus ocho segmentos anatómicos según la clasificación de Couinaud utilizando un esquema de aprendizaje en cascada. El enfoque propuesto descompone la tarea de segmentación en dos etapas secuenciales. En primer lugar, un

modelo 3D U-Net binario identifica la región hepática dentro del volumen de CT abdominal. Posteriormente, un segundo modelo 3D U-Net realiza la segmentación multiclase de los segmentos de Couinaud utilizando como entrada la CT restringida a la región hepática previamente identificada.

Al eliminar estructuras anatómicas irrelevantes del volumen de entrada del segundo modelo, la estrategia propuesta simplifica el problema de aprendizaje y permite que la red se concentre en los patrones anatómicos intrahepáticos. Esta restricción espacial reduce la variabilidad del contexto presente en las imágenes abdominales y favorece la especialización del modelo en la segmentación de las estructuras internas del hígado.

El pipeline propuesto obtuvo un coeficiente Dice de 97.63 % e IoU de 95.39 % para la segmentación hepática, y un Dice de 81.56 % e IoU de 70.41 % para la segmentación de los segmentos de Couinaud en el conjunto de prueba.

Keywords: Segmentación hepática, Couinaud, Deep Learning, Tomografía computada, U-Net 3D

1 Introducción

Durante la última década, el uso de inteligencia artificial (IA) para el análisis de imágenes médicas ha sido ampliamente investigado y utilizado. La segmentación automática de las imágenes se presenta como una herramienta clave para el diagnóstico, la planificación quirúrgica y el seguimiento de patologías, permitiendo identificar estructuras anatómicas de forma precisa y reproducible.

En particular, los métodos basados en aprendizaje profundo han demostrado un desempeño sobresaliente en tareas de detección, clasificación y segmentación de estructuras anatómicas (Litjens et al., 2017; Singh et al., 2020).

Las redes neuronales convolucionales (CNN) han demostrado ser eficaces en el análisis de imágenes médicas. Entre sus arquitecturas más importantes se encuentra U-Net, propuesta por (Ronneberger et al., 2015), posteriormente, variantes tridimensionales como 3D U-Net (Çiçek et al., 2016) permitieron extender este enfoque a datos volumétricos, como los estudios obtenidos mediante tomografía computada (CT).

En la práctica clínica, la delimitación manual de los segmentos hepáticos a partir de estudios de CT es una tarea compleja, que requiere experiencia y demanda un tiempo considerable. Esta situación plantea la necesidad de desarrollar herramientas automáticas que asistan a los profesionales de la salud y optimicen los flujos de trabajo clínicos.

Este proyecto surge a partir de una problemática identificada en el área de cirugía del Hospital Tránsito Cáceres de Allende de la ciudad de Córdoba. En el marco del trabajo conjunto con el equipo médico, observamos la complejidad que implica la planificación prequirúrgica de resecciones hepáticas.

En el contexto local, existen antecedentes que muestran el interés clínico por incorporar herramientas de reconstrucción anatómica en cirugía hepática. (López et al., 2022) describen la utilización de reconstrucciones e impresiones tridimensionales para la planificación preoperatoria de cirugías hepáticas. En dicho trabajo, los autores destacan que estos modelos facilitaron la comprensión de la relación espacial entre las estructuras anatómicas y mejoraron la orientación prequirúrgica. Esto mismo se puede ver en otros trabajos (Banchini et al., 2024).

Un desafío importante en la segmentación de imágenes de CT abdominal radica en la gran cantidad de información contextual presente en las imágenes. Estructuras como costillas, pulmones, estómago y otros órganos abdominales introducen patrones visuales que no están directamente relacionados con la organización interna del hígado. Cuando un único modelo intenta aprender simultáneamente la localización del órgano y la segmentación de sus subdivisiones anatómicas, esta variabilidad contextual puede incrementar la complejidad del problema de aprendizaje.

Una estrategia posible para abordar esta dificultad consiste en descomponer la tarea de segmentación en etapas secuenciales. Este tipo de estrategias ha sido explorado en diversas aplicaciones de imágenes médicas como una forma de simplificar problemas de segmentación complejos y favorecer la especialización de los modelos.

En este contexto, el presente trabajo propone un sistema basado en aprendizaje profundo para la segmentación automática del hígado y de sus segmentos anatómicos según la clasificación de Couinaud a partir de imágenes de CT. El enfoque propuesto utiliza estrategias de *ensemble learning*, específicamente un esquema en cascada compuesto por dos modelos basados en arquitectura 3D U-Net: un primer modelo encargado de la segmentación hepática binaria y un segundo modelo dedicado a la segmentación multiclase de los segmentos hepáticos dentro de la región previamente identificada.

2 Antecedentes

La segmentación automática en imágenes médicas ha sido objeto de investigación durante varias décadas. En el caso particular del hígado, la segmentación precisa del órgano y de sus subdivisiones anatómicas resulta fundamental para la planificación de resecciones hepáticas y el análisis volumétrico del órgano.

El desarrollo de técnicas de aprendizaje profundo ha impulsado significativamente los avances en segmentación de imágenes médicas. La arquitectura U-Net, propuesta por (Ronneberger et al., 2015), representó un punto de inflexión en este campo.

De manera general, (Liu et al., 2021) presentan una revisión de los principales métodos de segmentación de imágenes médicas basados en aprendizaje profundo. Los autores destacan las arquitecturas convolucionales y señalan que, a pesar de los avances logrados, aún existen desafíos importantes asociados a la disponibilidad limitada de datos médicos anotados, la presencia de ruido y artefactos en las imágenes y la necesidad de fortalecer la colaboración entre especialistas clíni-

cos y científicos del aprendizaje automático. Esta interacción interdisciplinaria resulta especialmente relevante en el campo de la ingeniería biomédica.

En el caso específico de la segmentación de las secciones hepáticas definidos por la clasificación de Couinaud, (Tian et al., 2019) propusieron un método automático denominado GLC-UNet para la segmentación de estos segmentos a partir de volúmenes de CT. Este trabajo constituye uno de los antecedentes más relevantes para esta tarea específica.

Por otra parte, investigaciones más recientes han explorado el uso de estrategias basadas en *ensemble learning* y combinaciones de modelos para mejorar el desempeño de los sistemas de aprendizaje profundo en aplicaciones médicas. (Rane et al., 2024) presentan una revisión de estos enfoques, destacando que la combinación de múltiples modelos o etapas de procesamiento puede contribuir a aumentar la precisión.

(Xie et al., 2023) desarrollaron un método utilizando una arquitectura 3D U-Net entrenada sobre estudios de CT en fase portal y estrategias basadas en *ensemble learning*. El enfoque propuesto utiliza una estrategia de procesamiento en cascada similar a la implementada en este proyecto.

Existen investigaciones previas que ya habían explorado estrategias de segmentación en cascada. Por ejemplo, (Christ et al., 2017) propusieron un enfoque en dos etapas para la segmentación automática del hígado y de tumores hepáticos utilizando redes neuronales convolucionales profundas. De manera similar, (Roth et al., 2018) emplearon este tipo de estrategia para mejorar la segmentación en imágenes de CT. Estos trabajos tempranos muestran que la segmentación en múltiples etapas puede facilitar el proceso de aprendizaje del modelo y mejorar su desempeño.

Trabajos recientes exploran la utilidad de la IA para el diagnóstico de cáncer hepático y para la planificación de resecciones hepáticas. Métodos basados en aprendizaje profundo han demostrado ser capaces de asistir en detección de lesiones, segmentación de estructuras y el análisis volumétrico del órgano ((Mesaoudi et al., 2025; L. Wang et al., 2024)).

Estos trabajos muestran el potencial de las arquitecturas basadas en aprendizaje profundo para la segmentación automática del hígado y sus estructuras internas.

3 Conjunto de Datos

El desarrollo del presente trabajo se basó en el conjunto de datos del desafío MICCAI 2018 - Liver Tumor Segmentation Challenge (Task 8: Hepatic Vessel) (Medical Segmentation Decathlon, 2018). Este dataset contiene estudios de CT en formato NIfTI, junto con anotaciones asociadas a estructuras hepáticas.

Dado que el objetivo de este trabajo no se limita a la segmentación del hígado, sino que incluye la identificación de los segmentos hepáticos según la clasificación de Couinaud, se incorporaron máscaras adicionales derivadas del trabajo de (Tian et al., 2019), correspondientes a los ocho segmentos del hígado.

Debido a que estas anotaciones no se encuentran disponibles para la totalidad de los estudios, el conjunto final utilizado quedó conformado por 193 pacientes.

A partir de este conjunto, los datos se dividieron en dos subconjuntos: 161 pacientes destinados al entrenamiento de los modelos y 32 pacientes reservados para evaluación. De los 161 pacientes disponibles, 145 fueron asignados al conjunto de entrenamiento y 16 al conjunto de validación.

Las imágenes del dataset se encuentran expresadas directamente en unidades Hounsfield (HU), por lo que no fue necesario aplicar transformaciones adicionales de intensidad. Sin embargo, debido a la ausencia de parámetros de ventaneo explícitos, se definió un rango uniforme de intensidades de $[-200, 250]$ HU a partir de un análisis exploratorio, con el objetivo de resaltar el contraste del parénquima hepático como se ve en la Figura 1.




Fig. 1. Análisis del efecto del ventaneo sobre la distribución de intensidades.

Con el fin de adaptar los datos a arquitecturas de segmentación tridimensional, los estudios fueron reorganizados en subvolumenes de tamaño fijo, compuestos por conjuntos de cortes axiales consecutivos. En particular, se generaron volúmenes de 32 slices, permitiendo equilibrar el contexto espacial disponible

para el modelo con las limitaciones de memoria computacional. Luego de la generación de subvolumenes de 32 slices, la partición resultó en un total de 234 imágenes para entrenamiento y 26 imágenes para validación. Se guardaron 32 archivos para el conjunto de test.

Durante este proceso, se aplicaron operaciones de *padding* y recorte para garantizar dimensiones consistentes entre los volúmenes. La selección de los subvolumenes priorizó regiones con presencia significativa del hígado, incluyendo también zonas de transición para preservar la variabilidad anatómica.

4 Arquitectura Propuesta

La estrategia central del sistema propuesto en este proyecto se basa en un esquema en cascada, donde dos modelos de segmentación son aplicados de manera secuencial. Este enfoque puede interpretarse como una forma de *ensemble learning*, en la que el resultado generado por un primer modelo es utilizado como entrada para un segundo modelo especializado.

En la primera etapa, un modelo basado en arquitectura 3D U-Net recibe como entrada los volúmenes de tomografía computada previamente preprocesados y realiza la segmentación binaria del hígado. El resultado de este modelo es una máscara tridimensional que identifica la región correspondiente al hígado dentro del volumen abdominal, como se observa en la Figura 2.




Fig. 2. Esquema del sistema en cascada U-Net 3D utilizado. Primero se realiza la segmentación binaria del hígado y posteriormente se aplica el modelo multiclase para la segmentación de los segmentos de Couinaud dentro de la región hepática.

En la segunda etapa, un segundo modelo se utiliza para realizar la segmentación multiclase de los segmentos hepáticos definidos por la clasificación de Couinaud. A diferencia del primer modelo, este segundo modelo no recibe directamente la imagen CT completa, sino la CT multiplicada por la máscara hepática predicha por el primer modelo. Esta máscara mantiene las mismas dimensiones espaciales que el volumen original, pero contiene únicamente la información correspondiente a la región del hígado, eliminando el resto de las estructuras anatómicas presentes en la tomografía.




Fig. 3. Esquema de la arquitectura U-Net 3D del modelo de segmentación binaria de hígado.

De esta manera, el segundo modelo se entrena para segmentar exclusivamente las subdivisiones internas del órgano, lo que permite reducir la complejidad del problema y focalizar el aprendizaje en las estructuras anatómicas de interés.

Cabe destacar que ambos modelos fueron entrenados de manera independiente. El modelo de segmentación hepática binaria se entrenó utilizando como referencia las máscaras del hígado, mientras que el modelo multiclase se entrenó utilizando las máscaras correspondientes a los segmentos de Couinaud. Durante la etapa de inferencia, los modelos se aplican de manera secuencial, conformando el pipeline en cascada que constituye la estrategia principal del sistema desarrollado.

Esta decisión de diseño reduce la cantidad de información presentada al segundo modelo. Al restringir la entrada del segundo modelo solamente a la región hepática, el modelo puede concentrar su capacidad de aprendizaje en los patrones espaciales e intensidades asociados a los segmentos del hígado.

Desde la perspectiva del aprendizaje automático, esta estrategia simplifica el problema de segmentación al reducir la variabilidad del espacio de entrada y guiar al modelo hacia las estructuras anatómicas de interés. Como resultado, el segundo modelo puede especializarse en la segmentación intrahepática en lugar de aprender simultáneamente la localización del órgano y la subdivisión anatómica del mismo.

La arquitectura U-Net extendida a su versión 3D es la utilizada para estos modelos, con el objetivo de procesar información volumétrica proveniente de estudios CT. Se reemplazan las operaciones bidimensionales por convoluciones

y operaciones de pooling tridimensionales, permitiendo capturar información contextual en las tres dimensiones espaciales del volumen.

Para este trabajo los modelos realizados reciben como entrada volúmenes de tamaño $[B, 1, D, H, W]$ y producen mapas de segmentación del mismo tamaño espacial, el primer valor corresponde al batch size utilizado durante el entrenamiento, que en este caso es igual a 1 debido a las limitaciones de memoria, y el tercer valor corresponde a la profundidad del volumen. Se adopta una estructura *encoder-decoder* simétrica compuesta por cuatro niveles de contracción, un bloque central (*bottleneck*) y cuatro niveles de expansión, como se ver en la Figura 3.

Cada nivel del encoder está formado por bloques de doble convolución tridimensional ($3 \times 3 \times 3$), seguidos de normalización y activación ReLU, junto con operaciones de MaxPooling3D para reducir la resolución espacial. El número de mapas de características se incrementa progresivamente a partir de un valor base de 16 filtros, ajustado en función de las restricciones de memoria del hardware utilizado.

En la etapa de expansión, el decoder utiliza convoluciones transpuestas tridimensionales para realizar el *upsampling*, combinando la información mediante *skip connections* con los niveles correspondientes del encoder.

La capa de salida consiste en una convolución $1 \times 1 \times 1$ que proyecta los mapas de características al número de clases requerido. En el caso de la segmentación de Couinaud, el modelo genera nueve canales de salida correspondientes al fondo y a los ocho segmentos hepáticos.

Esta arquitectura se utiliza como base para ambos modelos que componen el sistema final: el modelo de segmentación hepática binaria y el modelo multiclase de segmentación de los segmentos de Couinaud. La diferencia está en las imágenes que son utilizadas para el entrenamiento.

5 Esquema de Entrenamiento

El sistema final que se puede observar en la Figura 2, se implementa mediante un pipeline en cascada compuesto por: un modelo de segmentación hepática binaria y un modelo multiclase para la segmentación de los segmentos de Couinaud. El modelo binario se aplica en una primera etapa para obtener la máscara del hígado, la cual se utiliza posteriormente para restringir espacialmente la entrada del modelo multiclase.

El entrenamiento de ambos modelos se realizó utilizando volúmenes de 32 slices, ya que esta configuración permitió un adecuado balance entre contexto espacial y costo computacional.

La optimización se llevó a cabo mediante el algoritmo Adam, evaluando distintas combinaciones de tasa de aprendizaje (1×10^{-5} , 1×10^{-4} y 1×10^{-3}) y criterios de detención temprana (*early stopping*), 15 y 30 épocas. Dando lugar a seis modelos entrenados por etapa, manteniendo constantes el resto de los hiperparámetros.

Todos los modelos fueron entrenados por un máximo de 300 épocas, utilizando *automatic mixed precision* (AMP) y *gradient clipping* con norma máxima igual a 1.0 para mejorar la estabilidad del entrenamiento.

La segmentación hepática binaria se entrenó utilizando una función de pérdida *Binary Cross-Entropy with Logits*, incorporando ponderación positiva para compensar el desbalance entre voxels de hígado y fondo. Por otra parte, la segmentación multiclase se entrenó utilizando una combinación de *Categorical Cross-Entropy* y *Generalized Dice Loss*, ponderadas de forma equivalente, junto con pesos por clase para mitigar el desbalance.

La selección del modelo final en cada etapa se realizó en función del mejor desempeño en el conjunto de validación, utilizando como métrica principal el coeficiente Dice.

6 Resultados y Discusión

El desempeño del sistema fue evaluado utilizando el coeficiente de Dice y la métrica *Intersection over Union* (IoU). La Tabla 1 presenta los resultados obtenidos para el pipeline completo en el conjunto de prueba interno.

Tarea	Dice %	IoU %
Segmentación de hígado	97,63	95,39
Segmentación de Couinaud	81,56	70,41

Table 1. Desempeño del pipeline de segmentación en cascada.

Los resultados muestran un alto grado de superposición entre las máscaras predichas y las anotaciones de referencia para la segmentación del hígado, con un valor **Dice** de **97,63 %**. Para la segmentación multiclase de los segmentos hepáticos se obtuvo un **Dice** de **81,56 %**, lo que indica que el sistema es capaz de capturar adecuadamente la estructura anatómica de los segmentos según la clasificación de Couinaud.

En la Figura 4 se presenta el archivo *hepaticvessel_301*, perteneciente al conjunto de prueba interno, que corresponde al mejor desempeño obtenido por el modelo con un valor de Dice promedio de 92,67 %.

Previo a la implementación de la arquitectura en cascada, se entrenaron modelos monolíticos para segmentar los segmentos de Couinaud sin segmentación previa del hígado (U-NET 3D multiclase).

Se evaluaron diferentes configuraciones, incluyendo diferentes tasas de aprendizaje, criterio de *early stopping* y diferentes combinaciones de funciones de pérdida basadas en *Cross Entropy* y *Dice Loss*. De los 12 modelos entrenados, el mejor desempeño presentó un Dice promedio a nivel de Couinaud de 0.6027 y a nivel de hígado (uniendo las máscaras de los segmentos) de 0.7918.




Fig. 4. Mejor caso del modelo concatenado en el conjunto de testeo interno. Vista axial, coronal y sagital. Comparación entre Ground Truth y predicción del modelo.

Esto muestra que el desempeño alcanzado por la arquitectura en cascada es superior al de una arquitectura monolítica multiclase. Mientras que en el caso monolítico los valores de Dice para la segmentación de los segmentos de Couinaud se mantienen alrededor de 0.540.60, en el modelo en cascada alcanza un Dice de 81.56 %.

Estos resultados demuestran la viabilidad del enfoque en cascada propuesto para la segmentación automática del hígado y sus segmentos anatómicos a partir de imágenes de tomografía computada. En la Figura 5 podemos observar los resultados del sistema propuesto en casos clínicos reales de la ciudad de Córdoba.




Fig. 5. Ejemplos de segmentación predicha por el sistema en casos clínicos reales de la ciudad de Córdoba.

En los casos clínicos reales analizados, el modelo en cascada mostró un buen desempeño en la segmentación del órgano. En cuanto las secciones dle mismo, el sistema también logra reproducir de manera razonable la organización intra-

hepática. Aunque, se observaron dificultades en las zonas de transición entre las regiones superior e inferior del hígado. A pesar de esto, este proyecto es un primer paso hacia el desarrollo de herramientas de apoyo para la práctica clínica, capaces de asistir a los médicos en la visualización y análisis durante la planificación prequirúrgica.

7 Conclusiones

El enfoque propuesto basado en una estrategia en cascada compuesta por dos modelos 3D U-Net entrenados de manera independiente, permite alcanzar un alto desempeño en la segmentación del hígado, con un Dice de 97,63 %, y una segmentación consistente de los segmentos hepáticos con un Dice promedio de 81,56 %.

La principal ventaja del enfoque propuesto se basa en la descomposición del problema de segmentación en dos tareas más simples, al restringir la entrada del modelo multiclase a la región hepática, se reduce la influencia de estructuras anatómicas externas presentes en las imágenes de CT abdominal, permitiendo que el modelo se especialice en la identificación de las estructuras intrahepáticas.

Estos resultados sugieren que los enfoques en cascada pueden constituir una estrategia efectiva para abordar problemas de segmentación anatómica en imágenes médicas. Si bien el Dice promedio obtenido para la segmentación de los segmentos hepáticos (81,56 %) es inferior al máximo valor reportado por (Tian et al., 2019) de 92,46 %, resulta comparable con enfoques recientes (Lee et al., 2026; Z. Wang et al., 2022) sobre el mismo conjunto de datos, que informan valores de aproximadamente 84 % , lo que respalda la validez del método propuesto.

8 Agradecimientos

Este trabajo utilizó recursos computacionales del (Centro de Computación de Alto Desempeño - Universidad Nacional de Córdoba, 2024), integrante del Sistema Nacional de Computación de Alto Desempeño (SNCAD) del Ministerio de Ciencia, Tecnología e Innovación de la República Argentina.

References

- Banchini, F., Capelli, P., Hasnaoui, A., Palmieri, G., Romboli, A., & Giuffrida, M. (2024). 3-d reconstruction in liver surgery: A systematic review. *HPB*, 26(10), 1205–1215. <https://doi.org/10.1016/j.hpb.2024.06.006>
- Centro de Computación de Alto Desempeño - Universidad Nacional de Córdoba. (2024). Centro de computación de alto desempeño [Accessed: 2026-06-29]. <https://ccad.unc.edu.ar/>

- Christ, P. F., Elshaer, M. E. A., Ettlinger, F., Tatavarty, S., Bickel, M., Bilic, P., Rempfler, M., Armbruster, M., Hofmann, F., Sommer, W., Ahmadi, S. A., & Menze, B. (2017). Automatic liver and tumor segmentation of CT and MRI volumes using cascaded fully convolutional neural networks. <https://doi.org/10.48550/arXiv.1702.05970>
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., & Ronneberger, O. (2016). 3D U-Net: Learning dense volumetric segmentation from sparse annotation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI 2016)*, 424–432. https://doi.org/10.1007/978-3-319-46723-8_49
- Lee, J., et al. (2026). Automatic liver couinaud segmentation from computed tomography scans with a gradient-enhanced hierarchical cascade deep learning network. *Computerized Medical Imaging and Graphics*, 118, 102481. <https://doi.org/10.1016/j.compmedimag.2025.102481>
- Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Liu, X., Song, L., Liu, S., & Zhang, Y. (2021). A review of deep-learning-based medical image segmentation methods. *Sustainability*, 13(3), 1224. <https://doi.org/10.3390/su13031224>
- López, A. E., Nari, G. A., Layun, J. L., Mariot, A. D., López, F. G., & Elías, M. E. D. (2022). Implementation of three-dimensional printed models in hepatic surgery. *Revista Argentina de Cirugía*, 114(3), 262–268. <https://revista.aac.org.ar/index.php/RevArgentCirug/article/view/563>
- Medical Segmentation Decathlon. (2018). Medical segmentation decathlon [Accessed: 2026-06-29]. <https://medicaldecathlon.com/>
- Messaoudi, H., Abbas, M., Badic, B., Salem, D. B., Belaid, A., & Conze, P.-H. (2025). Automatic future remnant segmentation in liver resection planning. *International Journal of Computer Assisted Radiology and Surgery*, 20(5), 837–845. <https://doi.org/10.1007/s11548-025-03331-2>
- Rane, N., Choudhary, S. P., & Rane, J. (2024). Ensemble deep learning and machine learning: Applications, opportunities, challenges, and future directions. *Studies in Medical and Health Sciences*, 1(2), 18–41. <https://doi.org/10.48185/smhs.v1i2.1225>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. <https://doi.org/10.48550/arXiv.1505.04597>
- Roth, H. R., Lu, L., Farag, A., Sohn, A., & Summers, R. M. (2018). Spatial aggregation of holistically-nested convolutional neural networks for automated pancreas segmentation. *Medical Image Analysis*, 45(1), 94–107. <https://doi.org/10.1016/j.media.2018.01.006>
- Singh, S. P., Wang, L., Gupta, S., et al. (2020). 3D deep learning on medical images: A review. *Sensors*, 20(18), 5097. <https://doi.org/10.3390/s20185097>

- Tian, J., Liu, L., Shi, Z., & Xu, F. (2019). Automatic couinaud segmentation from CT volumes on liver using GLC-UNet. *Machine Learning in Medical Imaging (MLMI 2019)*, 274–282. https://doi.org/10.1007/978-3-030-32692-0_32
- Wang, L., Fatemi, M., & Alizad, A. (2024). Artificial intelligence techniques in liver cancer. *Frontiers in Oncology*, 14. <https://doi.org/10.3389/fonc.2024.1415859>
- Wang, Z., et al. (2022). Automatic couinaud liver segmentation using cascaded deep learning and portal vein landmark detection. *Computers in Biology and Medicine*, 145, 105400. <https://doi.org/10.1016/j.compbimed.2022.105400>
- Xie, T., et al. (2023). Deep learning for fully automated segmentation and volumetry of couinaud liver segments and future liver remnant on CT. *Quantitative Imaging in Medicine and Surgery*, 13(5), 3180–3193. <https://doi.org/10.21037/qims-22-1008>