

Aplicación de Inteligencia Artificial en imágenes cardíacas

Eva Milara Hernando y David Palomino Fernández GIB 2019

Introducción

El análisis de la función cardíaca a través de la segmentación del miocardio y los ventrículos en imágenes de CMR es una de las tareas necesarias para poder establecer un diagnóstico. En las últimas décadas, se han desarrollado técnicas que permiten la automatización de esta tarea. A lo largo del siguiente proyecto, se van a plantear las diferentes técnicas de Deep Learning que existen actualmente para clasificar las imágenes en función de las patologías.

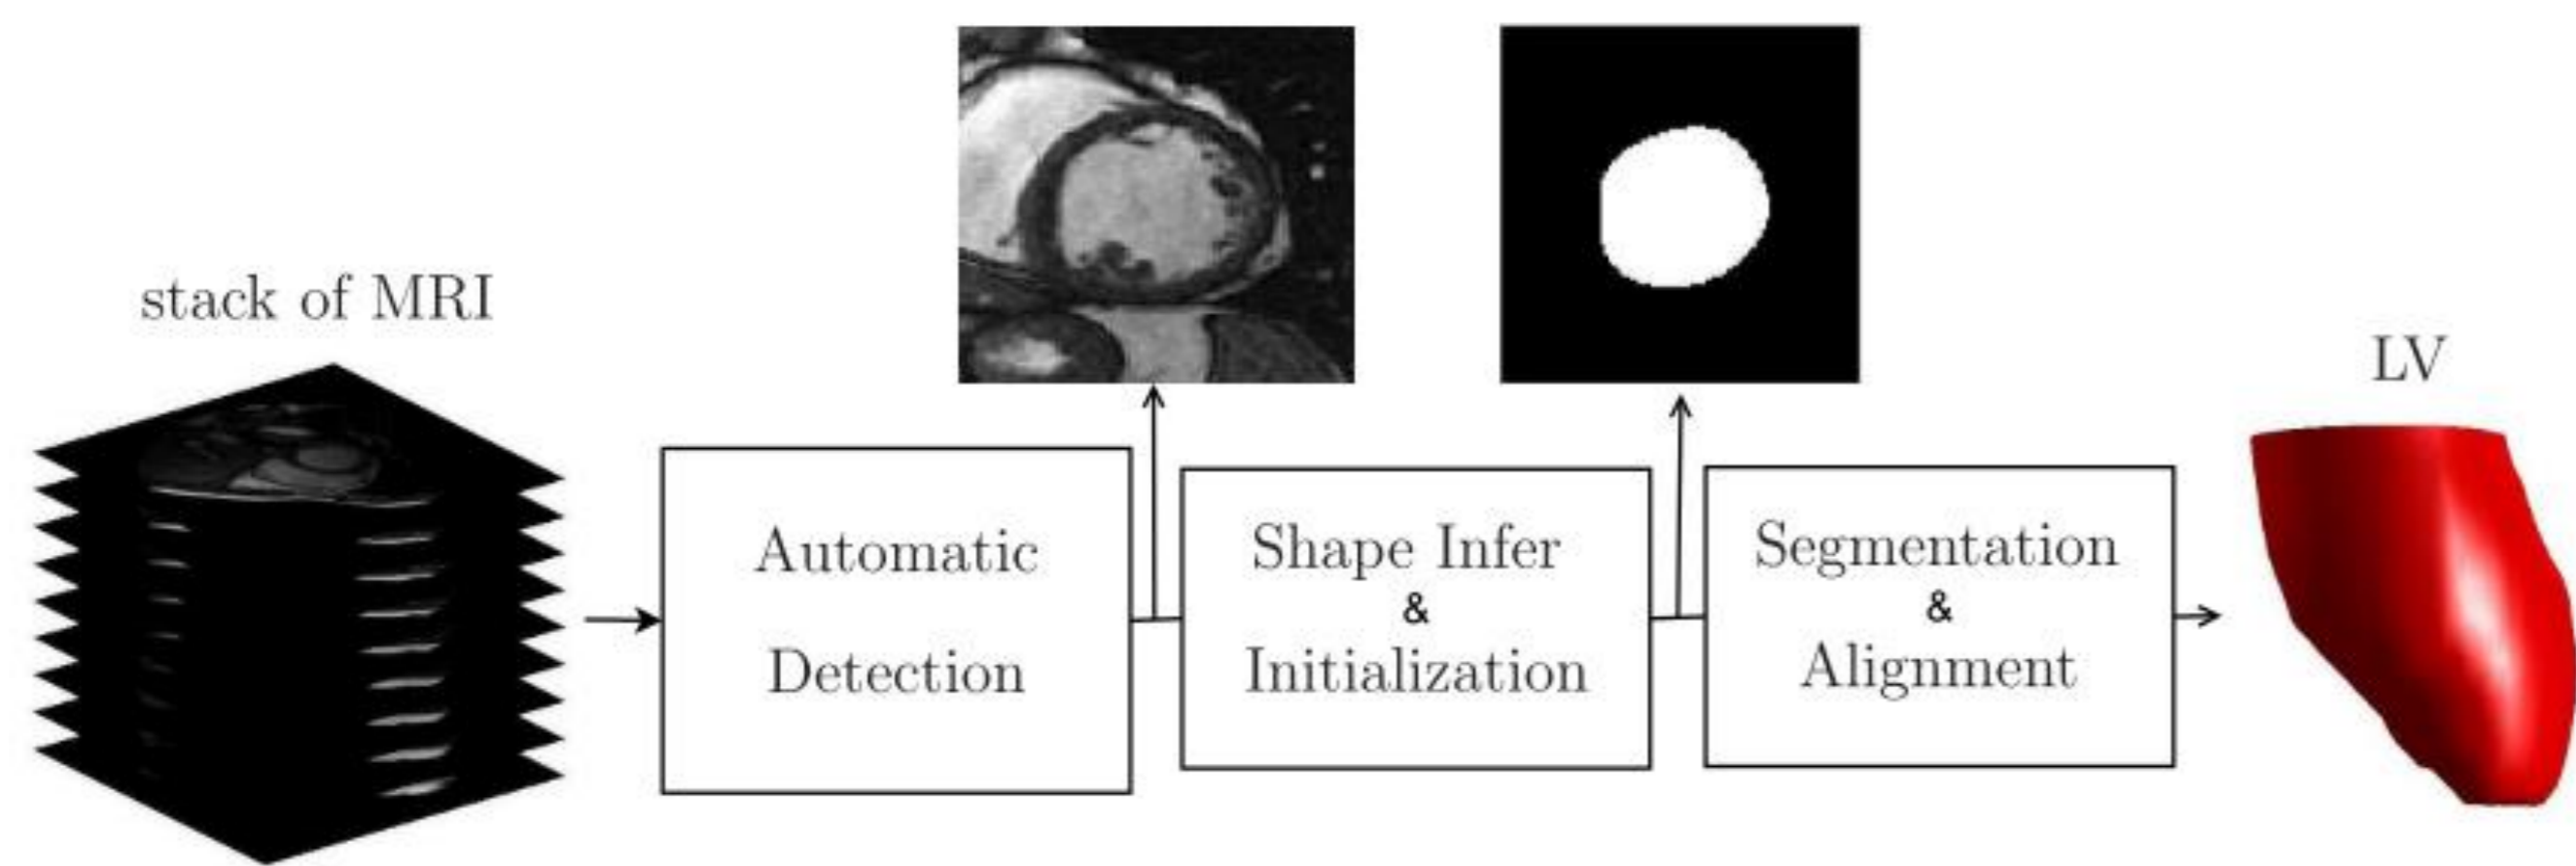


Fig 1. Diagrama de bloques de la segmentación del ventrículo izquierdo [2].

Ejemplo

El método con mejores resultados consiste en una segmentación de las estructuras de interés. Esta segmentación permite realizar la extracción de características de las imágenes. Se extraen dos tipos de características:

- Instantáneas: medidas en los momentos ES y ED. Aportan información de la forma local y global.
- Dinámicas: predice la posición de las estructuras anatómicas en todos los pasos de la CMRI. Permite conocer el volumen a lo largo de todo el ciclo cardíaco.

Estas características se usaron para generar un conjunto de 50 *multilayer perceptrons* (MLP) y un árbol de decisión para la clasificación de patologías.

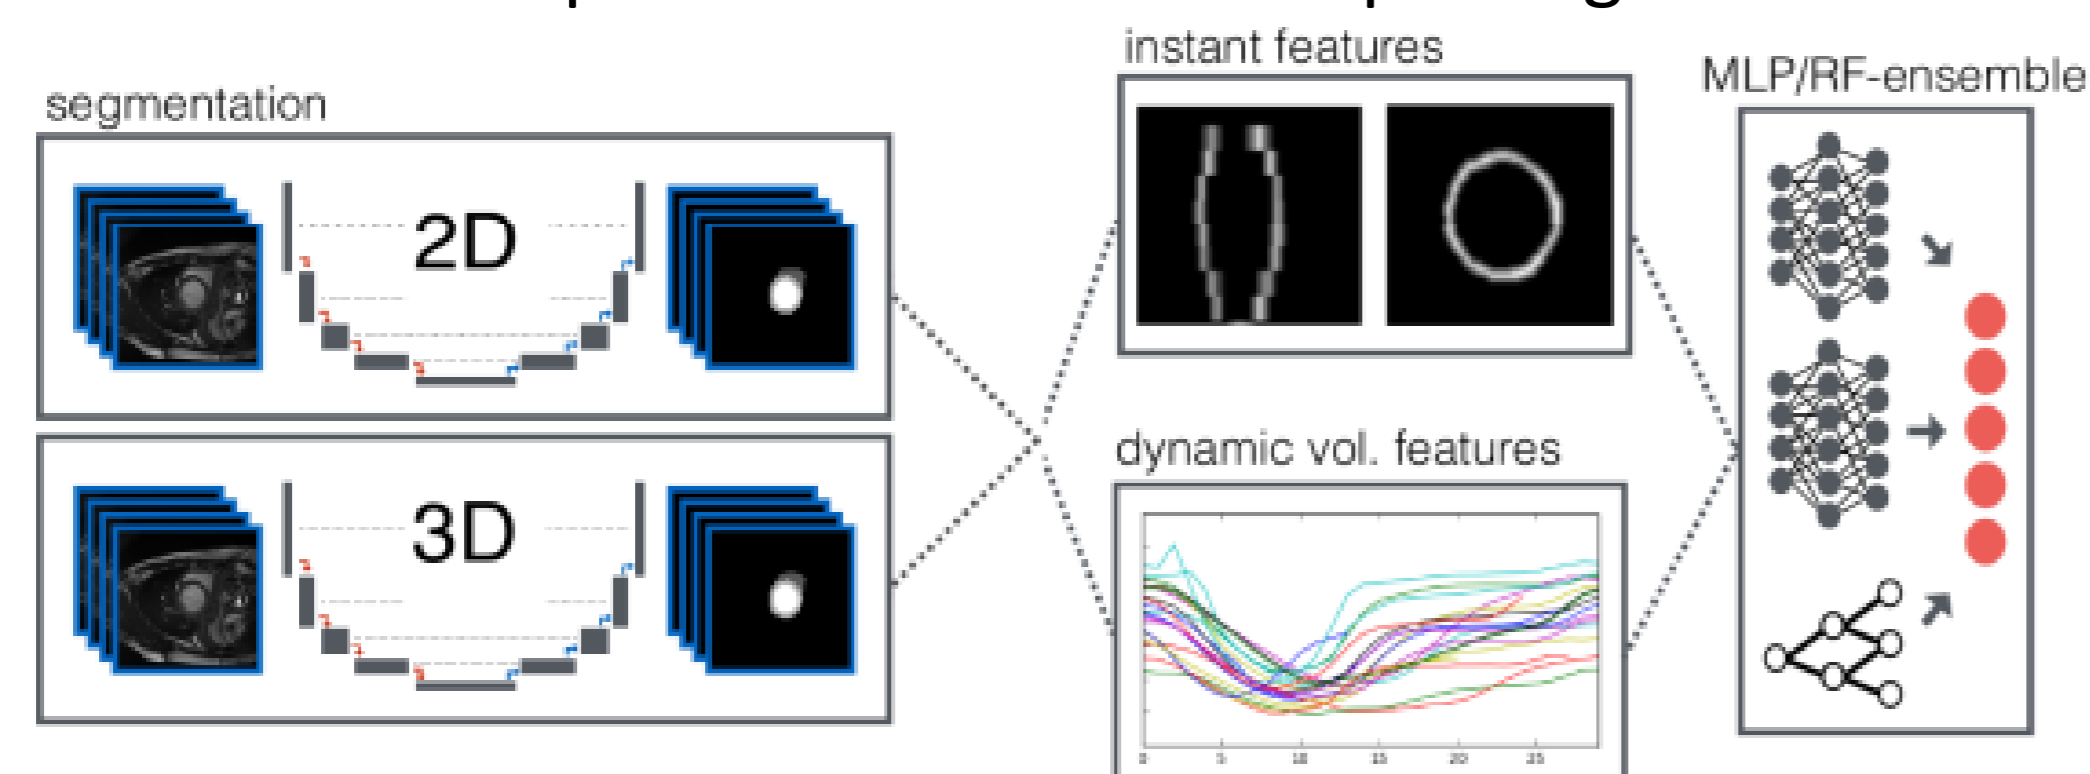


Fig 6. Pipeline del mejor de los métodos [4].

Para comprobar la eficiencia de la clasificación del método, se genera la matriz de confusión de los resultados comparados con la evaluación de los expertos clínicos. De esta manera, se comprueba que el método supera el 90% de efectividad a la hora de llevar a cabo la clasificación patológica, ya que consigue clasificar correctamente 46 de los 50 sujetos.

| | NOR | DCM | HCM | MINF | RVA |
|------|-----|-----|-----|------|-----|
| NOR | 10 | 0 | 0 | 0 | 0 |
| DCM | 0 | 9 | 0 | 1 | 0 |
| HCM | 1 | 0 | 9 | 0 | 0 |
| MINF | 0 | 2 | 0 | 8 | 0 |
| RVA | 0 | 0 | 0 | 0 | 10 |

Fig 7. Matriz de confusión de la clasificación patológica [4].

Conclusiones

- Las secuencias sincronizadas por ECG permiten un análisis preciso de las funciones ventriculares izquierda y derecha. La segmentación del endocardio ventricular y el epicardio permite el cálculo de diferentes parámetros, como masa miocárdica, grosor miocárdico, volúmenes ventriculares sistólicos y diastólicos. Estas mediciones son una parte integral de la interpretación del examen por el radiólogo y son necesarias para el diagnóstico de muchas cardiomiopatías.
- Los métodos de aprendizaje automático pueden clasificar con éxito los datos del paciente y obtener resultados de segmentación altamente precisos. Por ello, los métodos de Deep Learning evaluados alcanzan una precisión de hasta el 92% en la clasificación.
- Estos métodos obtienen una buena segmentación del ventrículo izquierdo, pero no es demasiado eficiente con el ventrículo derecho ya que es la región más difícil de clasificar incluso para los expertos.
- Las técnicas de inteligencia artificial bien entrenadas pueden obtener unos resultados mejores que las obtenidas por un experto.
- Los métodos *Deep Learning* son capaces de mejorar los resultados en cuanto al índice *Dice*. Sin embargo, aún están a 2-3 mm en términos de *dH*. Este hecho se debe a que las zonas apicales y basales son más difíciles de segmentar debido al efecto de volumen parcial causado por las estructuras del alrededor.




Fig 8. Resultado degenerado típico en la base del corazón. Imagen input, muestra base y predicción, respectivamente [1].

Materiales

- Redes neuronales CNN (*Convolutional Neural Network*).




Fig 2. Arquitectura del sistema CNN [3].

- Mapa ACDC (*Automatic Cardiac Diagnosis Challenge*). Este *dataset* está compuesto por las imágenes de CMR de 150 pacientes. En estas imágenes, las estructuras de interés han sido segmentadas por expertos clínicos en los instantes de volumen sistólico final (ES) y diastólico final (ED). Está compuesto por cinco grupos: sujetos sanos (NOR), infarto de miocardio (MINF), cardiomiopatía dilatada (DCM), cardiomiopatía hipertrófica (HCM) y anomalías en ventrículo derecho (ARV).

Metodología y resultados

Se han evaluado 10 métodos para la automatización del proceso en función de la correlación que obtengan con una muestra base (ACDC) en cuanto a los valores de índices *Dice* y *dH* (estadísticos que permiten evaluar la similitud entre dos muestras y la máxima distancia entre *subsets*, respectivamente):

| Methods * | ED | | | | | | ES | | | | | |
|-------------------------|-------|----------------|-------|----------------|-------|----------------|-------|----------------|-------|----------------|-------|----------------|
| | LV | | RV | | Myo | | LV | | RV | | Myo | |
| | D | d _H | D | d _H | D | d _H | D | d _H | D | d _H | D | d _H |
| Isensee et al. [44] | 0.968 | 7.4 | 0.946 | 10.1 | 0.902 | 8.7 | 0.931 | 6.9 | 0.899 | 12.2 | 0.919 | 8.7 |
| Baumgartner et al. [43] | 0.963 | 6.5 | 0.932 | 12.7 | 0.892 | 8.7 | 0.911 | 9.2 | 0.883 | 14.7 | 0.901 | 10.6 |
| Jang et al. [45] | 0.959 | 7.7 | 0.929 | 12.9 | 0.875 | 9.9 | 0.921 | 7.1 | 0.885 | 11.8 | 0.895 | 8.9 |
| Zotti et al. [52] | 0.957 | 6.6 | 0.941 | 10.3 | 0.884 | 8.7 | 0.905 | 8.7 | 0.882 | 14.1 | 0.896 | 9.3 |
| Khened et al. [46] | 0.964 | 8.1 | 0.935 | 14.0 | 0.889 | 9.8 | 0.917 | 9.0 | 0.879 | 13.9 | 0.898 | 12.6 |
| Wolterink et al. [50] | 0.961 | 7.5 | 0.928 | 11.9 | 0.875 | 11.1 | 0.918 | 9.6 | 0.872 | 13.4 | 0.894 | 10.7 |
| Jain et al. [47] | 0.955 | 8.2 | 0.911 | 13.5 | 0.882 | 9.8 | 0.885 | 10.9 | 0.819 | 18.7 | 0.897 | 11.3 |
| Rohé et al. [48] | 0.957 | 7.5 | 0.916 | 14.1 | 0.867 | 11.5 | 0.900 | 10.8 | 0.845 | 15.9 | 0.869 | 13.0 |
| Tziritis-Grinias [49] | 0.948 | 8.9 | 0.863 | 21.0 | 0.794 | 12.6 | 0.865 | 11.6 | 0.743 | 25.7 | 0.801 | 14.8 |
| Yang et al. [51] | 0.864 | 47.9 | 0.789 | 30.3 | N/A | N/A | 0.775 | 53.1 | 0.770 | 31.1 | N/A | N/A |

Fig 3. Tabla de comparación de los métodos evaluados [1].

La mayoría de métodos tienen una precisión mayor de 0.9. Estos métodos no solo sirven para segmentar automáticamente, si no que también pueden diagnosticar de forma automática la patología del paciente. También se puede utilizar para medir el volumen diastólico y otros parámetros usados como indicadores patológicos, y así clasificar los pacientes en los cinco grupos.

PERCENTAGE OF PATIENTS WITH AN EF ERROR LOWER THAN 5%

| Methods | LV | RV |
|-------------------------|------|------|
| Isensee et al. [44] | 92 % | 68 % |
| Jang et al. [45] | 88 % | 60 % |
| Robe et al. [48] | 88 % | 34 % |
| Zotti et al. [52] | 84 % | 60 % |
| Khened et al. [46] | 84 % | 56 % |
| Baumgartner et al. [43] | 84 % | 54 % |
| Wolterink et al. [50] | 80 % | 38 % |
| Jain et al. [47] | 68 % | 54 % |
| Tziritis-Grinias [49] | 66 % | 38 % |
| Yang et al. [51] | 58 % | 32 % |

La mayoría de los métodos son capaces de predecir de forma precisa el volumen de eyección ventricular izquierdo en el 87% de los pacientes. Este porcentaje se ve reducido al 59% en el caso del ventrículo derecho.

Fig 4. Porcentaje de casos con un error menor del 5% para cada uno de los métodos [1].

Los métodos de *Deep Learning* son capaces de superar las predicciones de estos valores por parte de los profesionales clínicos. Como se puede observar, los métodos de *Deep Learning* mejoran la variabilidad intersujeto, en relación al índice *Dice*. El método que mejores resultados obtuvo mejora incluso la variabilidad intrasujeto en el cálculo de dichos flujos ventriculares.

| Methods * | ED | | | | | | ES | | | | | |
|--|-------|----------------|-------|----------------|-------|----------------|-------|----------------|-------|----------------|-------|----------------|
| | LV | | RV | | MYO | | LV | | RV | | MYO | |
| | D | d _H | D | d _H | D | d _H | D | d _H | D | d _H | D | d _H |
| O _{1a} vs O ₂ (inter-obs) | 0.956 | 5.6 | 0.930 | 12.6 | 0.870 | 6.7 | 0.898 | 8.1 | 0.866 | 14.0 | 0.891 | 7.6 |
| O ₂ vs O _{1b} (inter-obs) | 0.950 | 6.2 | 0.931 | 12.1 | 0.868 | 7.2 | 0.895 | 8.5 | 0.861 | 14.1 | 0.886 | 8.0 |
| O _{1a} vs O _{1b} (intra-obs) | 0.967 | 4.0 | 0.957 | 7.6 | 0.900 | 5.1 | 0.941 | 5.4 | 0.930 | 9.1 | 0.917 | 6.0 |
| Average DL methods vs GT | 0.965 | 7.6 | 0.947 | 13.2 | 0.906 | 10.1 | 0.927 | 9.2 | 0.886 | 15.2 | 0.898 | 10.9 |
| Isensee et al. [44] vs GT | 0.968 | 7.4 | 0.946 | 10.1 | 0.902 | 8.7 | 0.931 | 6.9 | 0.896 | 12.1 | 0.919 | 8.7 |
| O _{1a} vs O ₂ (inter-obs) | 0.956 | 4.4 | 0.938 | 7.7 | 0.867 | 5.0 | 0.913 | 5.5 | 0.890 | 8.7 | 0.894 | 5.5 |
| O ₂ vs O _{1b} (inter-obs) | 0.953 | 4.9 | 0.937 | 8.6 | 0.864 | 5.5 | 0.905 | 5.8 | 0.898 | 9.4 | 0.886 | 6.1 |
| O _{1a} vs O _{1b} (intra-obs) | 0.971 | 3.1 | 0.960 | 5.8 | 0.905 | 3.6 | 0.950 | 3.9 | 0.940 | 6.9 | 0.923 | 4.4 |
| Average DL methods vs GT | 0.972 | 3.7 | 0.951 | 8.1 | 0.896 | 5.2 | 0.929 | 4.2 | 0.899 | 9.9 | 0.915 | 6.1 |
| Isensee et al. [44] vs GT | 0.972 | 3.7 | 0.969 | 6.4 | 0.910 | 4.6 | 0.945 | 4.2 | 0.912 | 8.6 | 0.930 | 5.1 |

* ED: End diastole; ES: End systole; LV: Endocardial contour of the left ventricle; RV: Endocardial contour of the right ventricle; Myo: Myocardium contours; D: Dice Index; d_H: Hausdorff distance; GT: Ground-truth.

Fig 5. Estudio para comprobar la precisión de los métodos *Deep Learning* frente a la variabilidad inter e intrasujeto [1].

Referencias

- O. Bernard, A. Lalande, C. Zotti, F. Cervenansky, X. Yang, and P.-A. Heng, "Deep Learning Techniques for Automatic MRI Cardiac Multi-Structures Segmentation and Diagnosis: Is the Problem Solved?," *IEEE Trans. Med. Imaging*, vol. 37, no. 11, pp. 2514–2524, 2018.
- M. Avendi, A. Kheradvar, and H. Jafarikhani, "A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac MRI," California, 2016.
- O. Emad, I. A. Yassine, and A. S. Fahmy, "Automatic localization of the left ventricle in cardiac MRI images using deep learning Left Ventricle Segmentation in MRI images View project," in *IEEE Engineering in Medicine and Biology Society*, 2015, vol. 15.
- F. Isensee et al., "Automatic Cardiac Disease Assessment on cine-MRI via Time-Series Segmentation and Domain Specific Features," Heidelberg, 2018.



POLITÉCNICA
"Ingeniamos el futuro"

CAMPUS
DE EXCELENCIA
INTERNACIONAL

ETSIT
ESCUELA TÉCNICA SUPERIOR DE INGENIEROS DE TELECOMUNICACIÓN

