

Mejora de la detección de fibrilación auricular paroxística mediante un modelo semisupervisado basado en señales ECG

Sara Artal¹, Juan Pablo Martínez^{1,2}, Antonio Miguel¹, Julia Ramírez^{1,2,3}

¹Instituto de Investigación en Ingeniería de Aragón (I3A), Universidad de Zaragoza, Mariano Esquillor s/n, 50018, Zaragoza, Spain. Tel. +34-976762707, e-mail: 799653@unizar.es

²Centro de Investigación Biomédica en Red, Biomateriales, Bioingeniería y Nanomedicina, Spain

³William Harvey Research Institute, Queen Mary University of London, London, United Kingdom

Resumen

El objetivo de este trabajo es evaluar si un modelo de aprendizaje semisupervisado mejora el rendimiento de uno supervisado en el diagnóstico de fibrilación auricular paroxística, una tarea en la que los datos de entrenamiento son escasos y la proporción de casos está desequilibrada.

Introducción

La fibrilación auricular paroxística (FAP), una arritmia que aparece de forma intermitente, es una de las principales contribuyentes a la muerte cardiovascular. El electrocardiograma (ECG) es una herramienta crucial para la detección precoz de FAP. Recientemente, las redes neuronales (RN) han abierto nuevas oportunidades para el análisis de esta señal. Sin embargo, la necesidad de acceder a grandes cantidades de datos anotados, que son difíciles y costosas de obtener, así como la sensibilidad de estos modelos al desequilibrio de los datos, limitan los resultados de estos estudios [1] [2].

En otras aplicaciones, se ha visto que el preentrenamiento de una RN con datos no etiquetados, por ejemplo, mediante codificación predictiva contrastiva (CPC) [3], mejora el rendimiento de dicha RN cuando se cuenta con datos etiquetados limitados. En este trabajo, planteamos la hipótesis de que los resultados de una RN, entrenada con una cantidad reducida de datos para detectar FAP, puede mejorar notablemente partiendo de una RN entrenada para resolver tareas más simples con señales ECG no etiquetadas.

Materiales y Métodos

Materiales y preprocesado de las señales ECG

En este proyecto se han utilizado bases de datos disponibles en [PhysioNet](https://physionet.org/), remuestreadas a 500 Hz y preprocesadas para eliminar el ruido de línea de base.

Modelo de aprendizaje supervisado

Para la tarea supervisada se ha empleado la base de datos [AFPDB](https://physionet.org/), de donde 300 señales se han destinado a formar el conjunto de entrenamiento y 200 el de test. Se ha utilizado una RN convolucional compuesta por 6 capas convolucionales 1D de 128 unidades ocultas, con un tamaño de kernel de 3, así como un diezmado de 2. Entre las capas convolucionales se usó la normalización por lotes y la función de activación ReLU. Tras estas capas, se utilizó una capa LSTM bidireccional. Para realizar la clasificación se ha empleado una única capa totalmente conectada, cuya salida representa la probabilidad de un ECG dado de tener o no FAP. Para medir el desempeño del modelo durante la fase de test se ha obtenido la precisión, la curva ROC y el AUC (área encerrada bajo la curva ROC), y se ha establecido un umbral de sensibilidad de 0.750.

Modelo de aprendizaje no supervisado

Para esta tarea disponemos de 1.602.185 señales, de las cuales hemos usado 1.600.000 como conjunto de entrenamiento y 2.185 como conjunto de test. En el entrenamiento de este modelo no supervisado hemos usado 637.448 señales ECG (derivación I). La arquitectura del modelo CPC desarrollado consta de un codificador no lineal formado por 6 capas convolucionales 1D de 1.024 unidades ocultas que generan representaciones latentes (z) de menor resolución temporal, utilizando la normalización por lotes y la función de activación ReLU. La salida del codificador se introduce en una capa GRU, obteniendo la información de contexto (c , representación latente contextual), que se usará para hacer predicciones de k pasos futuros ($k=8$, una predicción diferente para cada k) [3]. La predicción se realiza mediante dos capas lineales con una ReLU entre ellas.

Modelo de aprendizaje semisupervisado

Este modelo combina los dos anteriores, utilizando las representaciones internas del modelo no supervisado, z y c , como entrada para el entrenamiento del modelo de aprendizaje

supervisado. Para ello, se ha modificado convenientemente el número de canales del modelo supervisado en la primera capa convolucional. En la parte supervisada, se ha utilizado un número de capas convolucionales entre 0 (regresión logística de la salida no supervisada) y 6 (correspondiente al modelo supervisado completo).

Resultados

En la tarea supervisada se ha obtenido una precisión de 0.565, un AUC de 0.692 y una especificidad de 0.534 (Tabla 1). En lo que respecta a los resultados de las diferentes tareas semisupervisadas, la tarea que consiguió mejores prestaciones fue la unión del modelo supervisado original y el modelo no supervisado, al pasar la variable *c* (representación latente contextual) como entrada al modelo supervisado, a la vez que se redujo el número de capas convolucionales de 6 a 2. De esta forma, se ha obtenido una precisión de 0.680, un AUC de 0.714 y una especificidad (*Sp*) de 0.579 (Tabla 1).

Discusión y Conclusiones

Este trabajo analiza la mejora producida por el uso de un modelo no supervisado de codificación predictiva en una tarea de diagnóstico de FAP. Se ha podido comprobar que dicho modelo es capaz de mejorar los resultados en la tarea original de aprendizaje supervisado, paliando la limitación y desequilibrio de los datos.

La implementación de esta técnica incorpora una mejora metodológica, aumentando la precisión y consistencia de nuestros resultados con una RN más simple. Además, al simplificar la arquitectura supervisada se reducen los requerimientos de tiempo y memoria durante el entrenamiento de los modelos, y se obtienen modelos más generalizables. No

obstante, el ahorro de costes no es aplicable a la fase de test, donde deben evaluarse ambos modelos, no supervisado y supervisado.

Actualmente, una de las dificultades en el uso de RN para la detección de FAP mediante señales ECG es contar con grandes volúmenes de datos. El método propuesto, abre la puerta al uso de RNs en problemas con pocas señales ECG disponibles (eventos cardíacos poco frecuentes). Nuestros hallazgos muestran el gran potencial de las RN para mejorar significativamente la predicción del riesgo cardíaco.

Agradecimientos

Este trabajo ha contado con el apoyo de los proyectos PID2021-128972OA-I00, PID2022-140556OB-I00 y CNS2023-143599 financiados por el Ministerio de Ciencia e Innovación (MCIN) y FEDER, y del Grupo T39-23R 2014-2020 de Interpretación de Señales Biomédicas y Simulación Computacional (BSICoS). SA reconoce la financiación de una beca para estudiantes de grado en el marco de su trabajo de fin de grado otorgada por el Instituto de Investigación en Ingeniería de Aragón. JR agradece el financiamiento de la beca RYC2021-031413-I de MCIN.

Referencias

- [1]. BUDA, M., et al. *A Systematic Study of the Class Imbalance Problem in Convolutional Neural Networks.*, //, 2017 Available from: <http://arxiv.org/abs/1710.05381>.
- [2]. LIU, H., et al. Self-Supervised ECG Pre-Training. *Biomedical Signal Processing and Control*, /09/01, 2021, vol. 70. pp. 103010 DOI 10.1016/j.bspc.2021.103010.
- [3]. OORD, A.v.d., et al. *Representation Learning with Contrastive Predictive Coding.*, //, 2018 Available from: <http://arxiv.org/abs/1807.03748>.

Tabla 1. Detección de FAP midiendo la precisión (Acc), el área bajo la curva (AUC) y la especificidad (Sp) para diferentes arquitecturas de modelos supervisados y semisupervisados.

Métrica	Señales de entrada	Capas convolucionales en el modelo supervisado						
		6	5	4	3	2	1	0
Acc	x (muestras)	0.565	0.565	0.525	0.490	0.575	0.575	0.420
	z	0.605	0.590	0.555	0.615	0.585	0.570	0.490
	c	0.485	0.630	0.590	0.580	0.680	0.670	0.520
AUC	x (muestras)	0.692	0.583	0.634	0.516	0.637	0.567	0.499
	z	0.634	0.605	0.589	0.633	0.642	0.653	0.547
	c	0.604	0.687	0.629	0.608	0.714	0.661	0.610
Sp	x (muestras)	0.534	0.364	0.523	0.318	0.398	0.364	0.307
	z	0.477	0.455	0.329	0.477	0.420	0.398	0.341
	c	0.523	0.568	0.421	0.455	0.579	0.546	0.432