

# Clasificación de señales de ECG arrítmicas en el espacio de características entropía-complejidad-tiempo de retraso de embebido

Pablo Martínez Coq, Andrea Rey, Walter Legnani

Universidad Tecnológica Nacional, Facultad Regional Buenos Aires, Centro de Procesamiento de Señales e Imágenes (CPSI), Medrano 951 (C1179AAQ), Ciudad Autónoma de Buenos Aires, Argentina

[pmartinez@frba.utn.edu.ar](mailto:pmartinez@frba.utn.edu.ar)

Recibido el 18 de julio de 2022, aprobado el 29 de julio de 2022

## Resumen

La muerte súbita es consecuencia final de una arritmia severa. Así, la detección precoz de las arritmias es relevante. Se propone calcular para cada señal de ECG, el tiempo de retraso de embebido individualizado, la entropía de permutación y la complejidad estadística formando un espacio tridimensional de características, utilizado para entrenar un clasificador basado en la técnica de *Random Forest*. Los valores obtenidos de los parámetros de calidad de la clasificación son muy satisfactorios, permitiendo discriminar entre grupos de pacientes con ECG arrítmicos o con ritmos normales, presentando así una metodología prometedora en la definición de nuevos marcadores para la detección de patologías cardiovasculares.

**PALABRAS CLAVE:** ECG - SEÑALES CON ARRITMIA CARDÍACA - ENTROPÍA DE PERMUTACIÓN - TIEMPO DE RETRASO DE EMBEBIDO - CLASIFICACIÓN DE SEÑALES

## Abstract

Sudden death is a final consequence of a severe arrhythmia. Therefore, early detection of arrhythmias is relevant. It is proposed to calculate for each ECG signal, the individualized embedding time delay, the permutation entropy and the statistical complexity forming a three-dimensional feature space, used to train a classifier based on the Random Forest technique. The obtained values of the quality classification parameters are remarkable, and allow the discrimination between groups of patients with arrhythmic ECG or with normal rhythms, showing a promising efficiency in the definition of new markers for the detection of cardiovascular pathologies.

**KEYWORDS:** ECG - ARRRHYTHMIC CARDIAC SIGNALS - PERMUTATION ENTROPY - EMBEDDING TIME DELAY - SIGNAL CLASSIFICATION

## Introducción

De acuerdo con la Organización Mundial de la Salud, durante el año 2019 se produjeron 55,4 millones de muertes en todo el mundo. El 55 % de éstas se concentraron en tan sólo 10 causas. Las cardiopatías isquémicas, junto a los accidentes cerebro vasculares, englobaron el 27 % de estos decesos.

El término arritmia en sí mismo no significa una irregularidad del ritmo cardíaco, ya que pueden producirse arritmias regulares con absoluta estabilidad tales como el *flutter* o la taquicardia, siendo que ambas se encuentran dentro del rango de frecuencias cardíacas normales. La Sociedad Cardiológica Americana (American Heart Association) describe que algunas arritmias llegan a ser tan breves (una pausa temporal o un latido prematuro) que la frecuencia o el ritmo cardíaco general no se ve afectado a un nivel clínico. Sin embargo, si las arritmias poseen mayor duración, éstas pueden hacer que la frecuencia cardíaca se vuelva demasiado lenta, rápida o errática, reduciendo la eficacia de la función cardíaca. Para Goldstein *et al*, (1994), la mayor relevancia de las arritmias está relacionada con una asociación a la muerte súbita cardíaca. Es importante destacar que las arritmias frecuentes, especialmente la fibrilación, pueden producir embolias y derivar en graves consecuencias. Si bien su presencia no es frecuente en los niños, la mayoría de las mismas aumenta progresivamente con el paso de la edad (Gray *et al*, 2019).

El registro de un electrocardiograma, de ahora en más ECG, es una forma simple, masiva y no invasiva de representación de la actividad eléctrica del corazón. En este tipo de práctica una arritmia puede ser detectada o no, debido a que existen casos donde un paciente presenta un cambio en su ritmo cardíaco, el cual podría sugerir la presencia de una arritmia, sin reflejarse este indicio en el registro del ECG. Ante esta problemática, el empleo de la teoría de la información y el análisis de los sistemas dinámicos cobran relevancia, proporcionando herramientas que podrían posibilitar la obtención de resultados útiles en la detección de la patología en análisis. En base a estas consideraciones, en el presente trabajo se plantea la labor de caracterizar el grado de organización o complejidad de la serie de tiempo obtenida a partir del ECG de una sola derivación (Camm *et al*, 1996; Khan, 2008; Bayés de Luna, 2008); para efectuar la detección de la patología en análisis.

Se ha reportado que la complejidad de la información proveniente del corazón y del cerebro pueden ser procesadas y analizadas para diferenciar entre estados de salud y estados de enfermedad, e incluso, predecir en ciertas oportunidades un ataque cardíaco o uno epiléptico (Gray, 2011; Kantz *et al*, 2012; Henry y Judge, 2019). Así, algunos cuantificadores de la teoría de la información se utilizan para calcular la cantidad de información de series temporales provenientes de ECGs, permitiendo distinguir comportamientos regulares, caóticos o aleatorios.

En este trabajo se presenta un criterio para la selección de los parámetros del método propuesto por Bandt y Pompe (2002) para el cálculo de la Función de Densidad de Probabilidad, FDP de ahora en adelante, de la serie de tiempo proveniente de un ECG, y a partir de ésta, la Entropía Normalizada de Shannon y la Complejidad Estadística basada en la divergencia de Jensen-Shannon.

Seguidamente, con estos cuantificadores informacionales, junto con el tiempo de retraso de embebido, se construye un espacio de características empleado en modelos de clasificación con el objetivo de discriminar pacientes que presentan arritmias de aquellos que tienen un ritmo cardíaco sinusal o normal. Como proyecto futuro, se espera que este conjunto reducido de variables pueda incluirse en dispositivos de empleo en clínica médica cotidiana, con el fin de asistir a los profesionales de la salud en el seguimiento de sus pacientes.

## Metodología

Si bien el concepto de entropía surge en el marco de la aparición y estudio de la máquina de vapor durante el siglo XIX, su relación con las señales y la teoría de la información, visto como una herramienta para medir el grado de información en la teoría de la comunicación, es un aporte de Shannon (1948).

En la actualidad, se ha convertido en una de las nociones más emblemáticas empleadas para cuantificar la información contenida en un sistema dinámico.

Esta definición fue extendida luego por Kolmogorov (1958), a los sistemas dinámicos y a la complejidad computacional, siendo posteriormente modificada por Sinai (1959), quien la utilizó en la codificación simbólica del espacio de fases. Olivares y colaboradores (2019) proporcionan una serie de interpretaciones del concepto de entropía derivados de una amplia gama de temas científicos y tecnológicos tales como: el desorden, el volumen del espacio de estado, o la falta de información para predecir el siguiente valor en una serie de datos.

Dada una serie de tiempo  $X(t)=\{x_i:t=1,\dots,M\}$ , donde  $M$  es el número de valores observados, la función de densidad de probabilidad discreta asociada a  $X$  está dada por  $P=\{p_i:i=1,\dots,N\}$ , donde  $N$  representa los estados accesibles del sistema bajo estudio, y que satisface  $\sum_{i=1}^N p_i = 1$ . La Entropía de Shannon está definida por la siguiente expresión:

$$S[P] = - \sum_{i=1}^N p_i \ln(p_i). \quad (1)$$

La expresión (1) puede verse como una medida de la incertidumbre relacionada con el proceso físico descrito por  $P$ . Cuando  $S[P]=0$ , significa que la estructura subyacente es completamente determinista, implicando el máximo conocimiento del proceso en esa instancia. En el caso opuesto, como sucede en presencia de un proceso estocástico no correlacionado o una distribución uniforme, la máxima incertidumbre evidencia que el conocimiento del sistema dinámico es mínimo, determinando que todos los estados del sistema tienen la misma probabilidad de ocurrencia, la cual puede modelarse como una distribución uniforme dada por  $P_e=\{p_i=1/N, i=1,\dots,N\}$  (Sinai, 1959; Brissaud, 2005; Zunino *et al*, 2012). Luego, la Entropía Normalizada de Shannon se define como:

$$H[P] = \frac{S[P]}{S[P_e]}, \quad (2)$$

resultando evidente que  $0 \leq H[P] \leq 1$ .

Para introducir una definición de complejidad en el campo de la Física, es crucial considerarla como un indicador tanto de la aleatoriedad como de la presencia de estructuras correlacionadas de la serie de tiempo generada por un sistema dinámico dado (Rosso *et al*, 2010). López-Ruiz *et al*, (1995) sugieren la inclusión de un tipo de distancia a una FDP conocida o de referencia, para el cálculo de la complejidad. Por lo tanto, el desequilibrio con respecto a dicha distribución de referencia, se define por:

$$Q[P] = Q_0 \cdot D[P, P_e], \quad (3)$$

donde  $Q_0$  es una constante de normalización calculada como:

$$Q_0 = - 2 \left[ \frac{N+1}{N} \ln \ln (N + 1) - 2 \ln \ln (2N) + \ln \ln (N) \right]^{-1}. \quad (4)$$

y  $D$  es una distancia estocástica, que en este trabajo es considerada como la divergencia de Jensen-Shannon dada por:

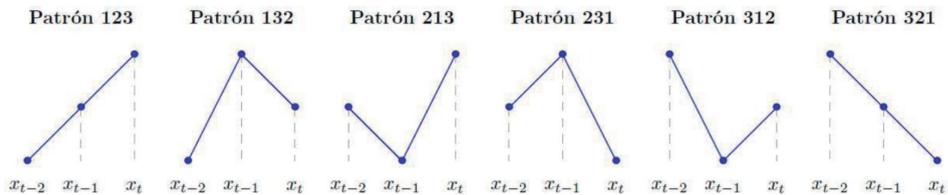
$$D_{SJ}[P, P_e] = S \left[ \frac{P+P_e}{2} \right] - \frac{S[P]}{2} - \frac{S[P_e]}{2}. \quad (5)$$

Se puede observar que el desequilibrio se hace nulo cuando la distribución de la serie temporal se asemeja a una nube de puntos uniformemente distribuidos, y que se maximiza cuando la serie temporal es periódica. Así, la complejidad puede medirse como una combinación entre la información inherente al sistema y una estimación del desequilibrio respecto a una distribución predeterminada.

Explicitamente, usando las expresiones (2) y (3), la complejidad se puede expresar de la siguiente manera:

$$C[P] = Q[P] \cdot H[P]. \quad (6)$$

En este punto es importante destacar que esta definición de complejidad no requiere hacer ninguna suposición respecto del sistema que genera la señal en estudio; solamente se basa en la estructura de ordenamiento temporal contenida en la expresión (6). Por lo tanto, esta medida de complejidad estadística permite identificar diferentes niveles de periodicidad y caos (Zunino *et al.*, 2012). Dado que ambas medidas de información se calculan en términos de una FDP, en este trabajo se utiliza el enfoque propuesto por Bandt y Pompe (2002). Esta metodología consiste en la obtención de las probabilidades relacionadas con las permutaciones de los patrones ordinales (ver Figura 1) formadas por la secuencia de puntos que componen la señal en estudio.



**Fig. 1. Patrones ordinales con una dimensión de embebido igual a 3**

Para el cálculo de la FDP de una serie de tiempo  $X(t)$ , es necesario definir dos parámetros denominados dimensión de embebido  $m \in \mathbb{N}$  ( $m > 1$ ) y tiempo de retraso  $\tau \in \mathbb{N}$ , el cual representa la longitud del intervalo entre dos observaciones consecutivas en el remuestreo, obteniéndose  $M-m+1$  particiones superpuestas de longitud  $m$  que se construyen de la siguiente forma:

$$S \rightarrow \left( x_{s-(m-1)\tau}, x_{s-(m-2)\tau}, x_{s-(m-3)\tau}, \dots, x_{s-\tau}, x_s \right), \quad (7)$$

con  $s=m, m+1, \dots, M$ . Para cada  $s$ , las permutaciones del conjunto  $\{0, 1, \dots, m-1\}$  se simbolizan por  $\pi_j = (r_0, r_1, \dots, r_{m-1})$  y están dadas por el ordenamiento

$$x_{s-\tau r_{m-1}} \leq x_{s-\tau r_{m-2}} \leq \dots \leq x_{s-\tau r_0}.$$

Para cada  $j=1, \dots, m!$ , la permutación  $\pi_j$  tiene la siguiente probabilidad de ocurrencia:

$$p_j = \frac{\#\{s \text{ es de tipo } \pi_j\}}{M-m+1}. \quad (8)$$

Se requiere que  $M \gg m!$  para asegurar una estadística confiable y una disimilitud adecuada para sistemas deterministas y estocásticos (Kowalski *et al*, 2007).

Si la FDP dada en la expresión (8) se reemplaza en la expresión (2), se obtiene una extensión de la entropía de Shannon denominada entropía de permutación de Shannon (EP). Una de las principales ventajas de esta técnica radica en que no se requiere de un modelo estadístico para la distribución de puntos de la señal, por lo que no son necesarias suposiciones sobre la naturaleza del proceso subyacente. Además, es frecuente que los modelos que se asumen presenten importantes cantidades de valores atípicos.

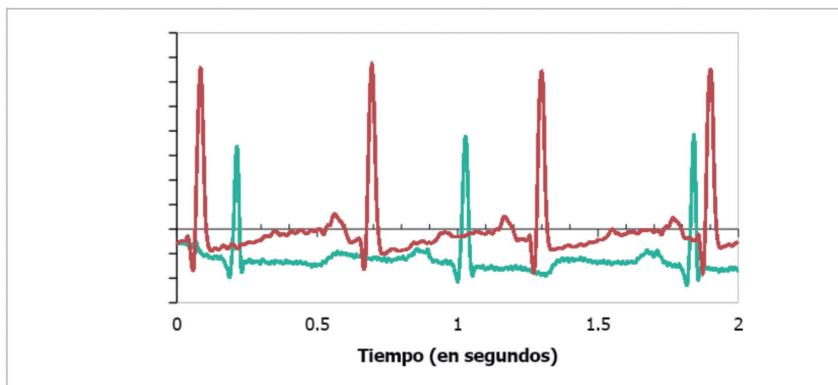
El conjunto de series de tiempo provenientes de los registros de ECG analizadas en este trabajo se obtuvieron de la plataforma *PhysioNet*, la cual está administrada por el Laboratorio de Fisiología Computacional del Instituto Tecnológico de Massachusetts y se encuentra disponible en el sitio <https://physionet.org/>. Este conjunto se compone de 18 registros de ECG provenientes de pacientes con ritmos sinusales normales que no presentan arritmias cardíacas significativas, y 48 registros de ECG provenientes de pacientes con arritmias cardíacas (Goldberger *et al*, 2000). De este último grupo, 37 de ellos se encontraban bajo los efectos de diversas medicaciones (Moody y Mark, 2001).

Dado que los registros originales de la base de datos de los ECG provenientes de pacientes arritmicos, tienen una duración aproximada de 30 minutos (alrededor de  $6,5 \times 10^5$  muestras), y que los provenientes de pacientes con ritmo cardíaco normal tienen una duración aproximada de 24 horas, se consideraron sólo las primeras  $6,5 \times 10^5$  muestras de este último grupo (aproximadamente 85 minutos por registro). Estas características se resumen en la Tabla 1.

**Tabla 1. Características generales de la base de datos de ECG**

	Ritmo cardíaco normal	Arritmias Cardíacas
Registros Femeninos	13 pacientes	22 pacientes
Registros Masculinos	5 pacientes	26 pacientes
Frecuencia de muestreo	128Hz	360Hz
Tamaño de registro [minuto / muestras]	85 / $6,5 \times 10^5$	30 / $6,5 \times 10^5$

En la Figura 2 se muestra un ejemplo de una señal de ECG proveniente de un paciente con ritmo cardíaco normal y otra de un registro de ECG de un paciente con arritmia cardíaca.



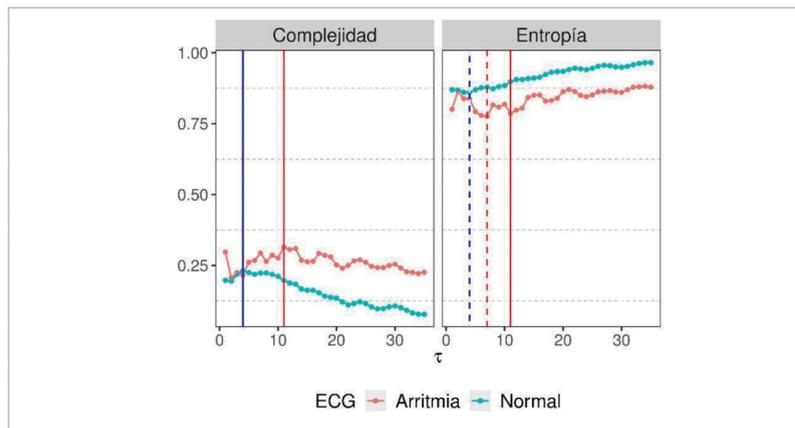
**Fig. 2. Ejemplo de señales de ECG. En verde, la señal 16273 obtenida de la base de datos MIT-BIH Normal sinus rhythm, y en rojo la señal 100 proveniente de la base de datos MIT-BIH Arrhythmia data base**

## Parte experimental

### Selección del tiempo de retraso de embebido

Como se mencionó anteriormente, para el cálculo de la EP se requieren dos parámetros. Debido a la longitud de las series de tiempo en estudio, se eligió la dimensión de embebido  $m=6$ . Este valor se tomó, además, teniendo en consideración que con el mismo se puede obtener una cantidad razonable de permutaciones ( $6!$ ) para formular la estadística a partir de la cual se calcula la FDP, a la vez que no se requiere de un excesivo tiempo de cálculo.

Para la selección del tiempo de retraso de embebido  $\tau$  se suelen adoptar valores sugeridos en las pruebas experimentales desarrolladas por científicos e investigadores a partir de la literatura disponible, aunque se pueden presentar inconvenientes tales como una fuerte dependencia del valor de la EP con la frecuencia de muestreo (Popov *et al*, 2013). Por otro lado, Martínez Coq y colaboradores (2019), buscando identificar señales de ECG mediante EP y complejidad estadística, basaron sus cálculos en la elección  $\tau=15$  y obtuvieron buenos resultados. Debido a la inexistencia de un criterio único para la selección del valor de  $\tau$  y con el objetivo de emplear una metodología objetiva de elección de dicho parámetro con el fin de mejorar los resultados obtenidos en el trabajo antes citado, se realizó una exploración en literatura específica donde se emplea alguna clase de algoritmo de selección automática del tiempo de retraso de embebido; como son los trabajos de Myers y Khasawneh (2019 y 2021) y de Riedl *et al*, (2013). La implementación de estos algoritmos arrojó valores similares a los reportados en los trabajos previamente citados, referidos a señales de ECG. En los trabajos de referencia se sugiere un rango de valores del tiempo de retraso de embebido que posee una dependencia con la naturaleza de la señal, sugiriendo diferentes rangos para señales sintéticas, para electroencefalogramas y para electrocardiogramas. Por el contrario, la alternativa a aplicar en el presente trabajo busca la independencia de este factor. Explícitamente, la complejidad se calcula de acuerdo a lo expresado en la expresión (6) a partir de la EP, fijando  $m=6$ , y variando  $\tau$  en el rango desde 1 hasta 35. Luego, adaptando la técnica propuesta por Zunino *et al*, (2012), la elección del tiempo de retraso de embebido se establece como aquél que maximiza la medida de complejidad estadística. En dicho artículo, se denota este valor con  $\tau_{Cmax}$ , mientras que  $\tau_{Hmin}$  indica el tiempo de retraso de embebido inferior o igual al de  $\tau_{Cmax}$  que minimiza la EP. La Figura 3 ilustra este procedimiento para dos señales de ECG particulares, una con ritmo cardíaco normal (rojo) y otra con arritmia cardíaca (azul). Las líneas verticales continuas indican  $\tau_{Cmax}$  y las punteadas  $\tau_{Hmin}$ .



**Fig. 3.** Valores de  $\tau_{Cmax}$  (líneas continuas) y de  $\tau_{Hmin}$  (líneas punteadas) para dos ejemplos de ECG, uno con ritmo normal y uno correspondiente a un caso de arritmia. En el caso del ECG normal, ambos valores coinciden

## Definición del espacio de características

El espacio de características a partir del cual el clasificador aprenderá se define de la siguiente forma. Para cada señal de ECG de la base de datos considerada, se halla  $\tau_{C_{max}}$  de acuerdo a lo descrito anteriormente. Cabe destacar que el tiempo de retraso de embebido se considera como una característica individual de la señal, es decir como un rasgo más del clasificador, aspecto que le da a este enfoque una visión innovadora con relación al método de cálculo de la EP. Posteriormente, la EP y la medida de complejidad estadística se calculan utilizando este valor de  $\tau$  para cada señal. En lo sucesivo la EP se denotará con la letra  $H$  y la medida de complejidad estadística basada en la divergencia de Jentsen-Shannon con la letra  $C$ . Por tanto, a cada señal de ECG se le asociará un punto en el plano  $H \times C$ . Martín *et al.*, (2006) señalaron que, para un determinado valor de  $H$ , los posibles valores de  $C$  están acotados entre dos curvas denotadas por  $C_{min}$  y  $C_{max}$ . Finalmente, cada señal se etiqueta como "Normal" o "Arritmia" en referencia a la base de datos original. Esto significa que el grupo de pacientes se puede dividir en dos clases. Este proceso se resume en la Tabla 2.

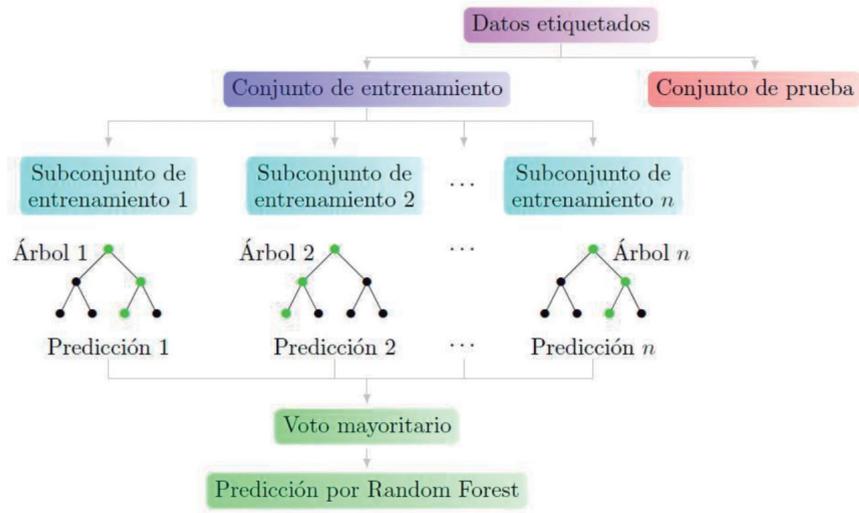
**Tabla 2. Construcción del espacio de características**

	$\tau$	$H$	$C$	Etiqueta del ECG
Señal 1	$\tau_1$	$H(m = 6, \tau = \tau_1)$	$C(m = 6, \tau = \tau_1)$	$L_1$
Señal 2	$\tau_2$	$H(m = 6, \tau = \tau_2)$	$C(m = 6, \tau = \tau_2)$	$L_2$
⋮	⋮	⋮	⋮	⋮
Señal $n$	$\tau_n$	$H(m = 6, \tau = \tau_n)$	$C(m = 6, \tau = \tau_n)$	$L_n$

## Modelos de clasificación

El enfoque para mejorar la clasificación de un ECG utilizando técnicas de aprendizaje automático se ha venido utilizando desde hace varios años, como se puede apreciar en trabajos como Sannino y de Pietro (2018), Nalbantov *et al.*, (2020), Reyna *et al.*, (2020), Mathews *et al.*, (2018), Murat *et al.*, (2020), Rajkumar *et al.*, (2019), Ebrahimi *et al.*, (2020), Teplitzky *et al.*, (2020), entre otros, los cuales aportan diversos antecedentes concretos para la implementación de un esquema de clasificación de registros de ECG con el objetivo de detectar y predecir ciertos tipos de patologías cardíacas. Los trabajos precedentes tuvieron en cuenta diferentes características de la señal, mayormente en el dominio temporal y frecuencial, junto con el uso de redes neuronales artificiales y otras metodologías de clasificación.

En el presente estudio se considera la técnica supervisada conocida como *Random Forest (RF)* cuyo esquema de funcionamiento se presenta en la Figura 4 (cf. Liaw, 2001). *Random Forest* es un método que utiliza conjuntos de árboles de decisión en divisiones con vectores generados aleatoriamente o subconjuntos aleatorios de datos de entrenamiento, y calcula la puntuación en función de estos diferentes componentes (Breiman, 2001). En el contexto de clasificación, la predicción realizada por esta técnica resulta de la clase más frecuente en el conjunto de predicciones obtenidas por cada árbol de decisión. Al ser un modelo de conjunto, la varianza se reduce en comparación con el entrenamiento de un solo árbol. La poda que se emplea al usar un solo árbol para evitar un posible sobreajuste, no es necesaria en esta técnica ya que las muestras utilizadas para entrenar los árboles individuales en el bosque son solamente empleadas en el comienzo del algoritmo.



**Fig. 4. Esquema del funcionamiento del algoritmo *Random Forest***

Para implementar este clasificador se utilizó el paquete "*RandomForest*" (Liaw y Wiener, 2002) del lenguaje R (*R Core Team*, 2021). La selección de este algoritmo de clasificación se basó en su eficiencia en la implementación computacional, en su aptitud para clasificaciones binarias, en el mínimo requerimiento de parámetros para funcionar y en que no requiere el ajuste de los mismos obligatoriamente y por su reducido riesgo de sobreajuste. En la Tabla 3 se presentan las combinaciones de las variables del espacio de características que definen los modelos que se aplicarán.

**Tabla 3. Modelos de calificación en términos del espacio de características**

Modelo	Espacio de características
H	Solo Entropía
C	Solo Complejidad
HC	Entropía y Complejidad
$\tau$ HC	$\tau$ , Entropía y Complejidad

### Indicadores de calidad de los modelos

Para comparar el desempeño de los modelos de clasificación propuestos anteriormente, cada espacio de características descrito en la Tabla 3, se divide el espacio de características aleatoriamente en un conjunto de entrenamiento construido aleatoriamente con el 70 % de la muestra, y un conjunto de prueba que contiene al 30 % restante. La etiqueta positiva se asigna a los registros de ECG arrítmicos. De esta manera, las posibles predicciones pueden dividirse en los siguientes casos: verdadero positivo (VP), verdadero negativo (VN), falso positivo (FP) o falso negativo (FN).

Los indicadores de calidad en la clasificación que se utilizan son la exactitud, el AUC que es el área bajo la curva característica de operación del receptor (ROC), y el F1-score. La exactitud se define como la proporción de datos correctamente predichos y está dada por la expresión:

$$\frac{VP+VN}{VP+FP+VN+FN} \quad (9)$$

El AUC brinda información sobre qué tan bien funciona el modelo, puesto que su va-

lor indica la probabilidad de que se pueda distinguir entre las clases positiva y negativa (Fawcett, 2006). Su rango de variación es desde 0, cuando todas las predicciones son incorrectas, hasta 1 en el caso en que todas las predicciones son correctas. Finalmente, el F1-score es la media armónica entre la precisión dada por  $VP/(VP+FP)$  y la exhaustividad definida por  $VP/(VP+FN)$ . Por tanto, este puntaje puede calcularse de acuerdo a la expresión:

$$F1 = 2 \frac{\text{precisión} \cdot \text{exhaustividad}}{\text{precisión} + \text{exhaustividad}} \quad (10)$$

Debido a la aleatoriedad en la selección de los conjuntos de entrenamiento y de prueba o testeo, se utiliza una simulación de Montecarlo de 1000 ensayos para analizar el promedio de las medidas de calidad de la predicción, con el fin de no incurrir en una dependencia de los datos. El diagrama de flujo conceptual para el enfoque de esta nueva propuesta se presenta en la Figura 5.

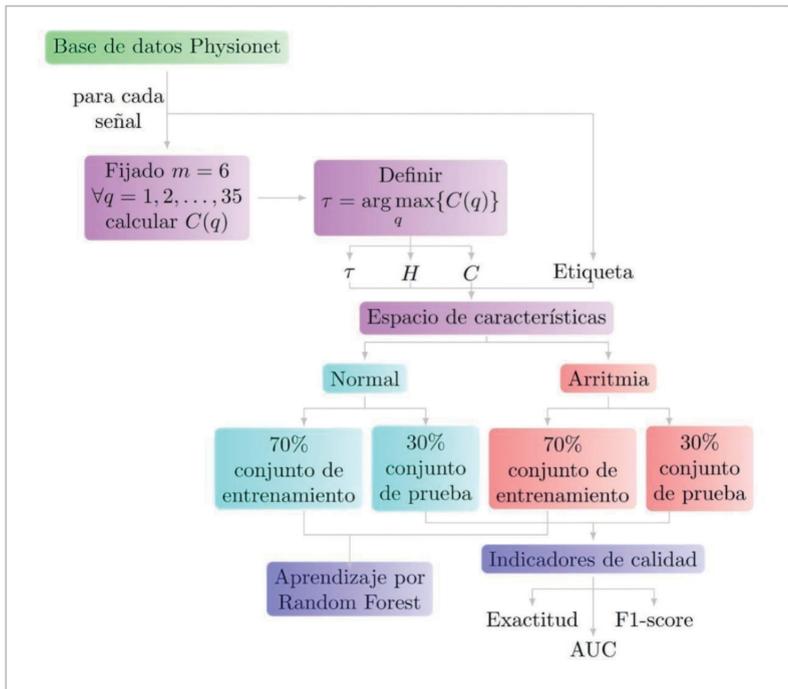
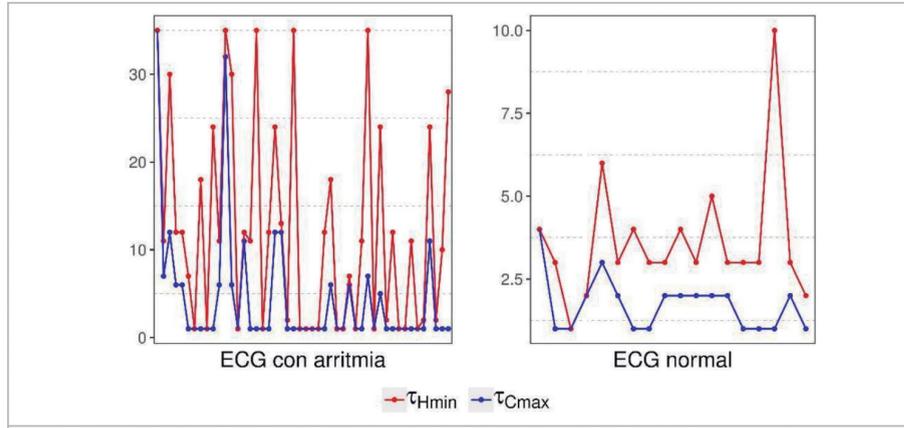


Fig. 5. Diagrama de flujo de la metodología propuesta

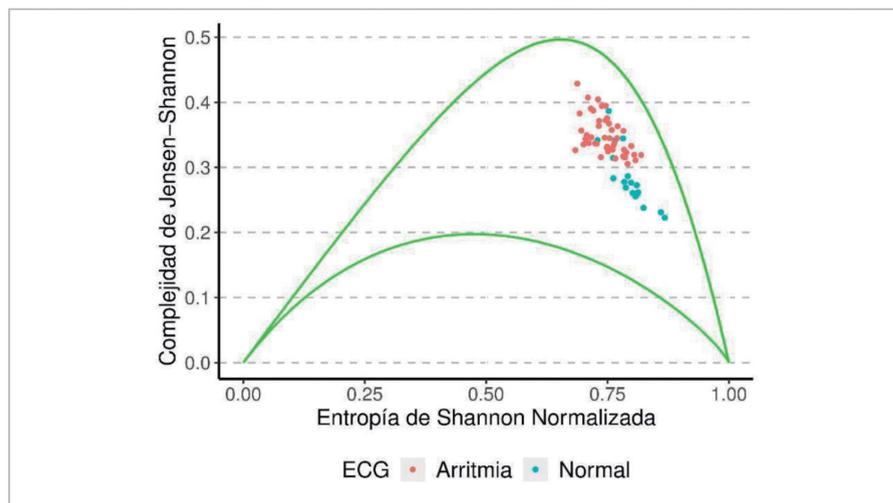
## Resultados y discusión

En la Figura 6 se puede observar que los valores de  $\tau_{Hmin}$  y  $\tau_{Cmax}$  se encuentran muy próximos para el grupo de las señales de ECG pertenecientes a pacientes con ritmo cardíaco sinusal normal. Esta característica es consistente con la ubicación de los puntos en el plano  $H \times C$  (ver Figura 7). Esta particularidad permite explicar la mayor diferencia de estos valores en el grupo de señales de ECG de pacientes con arritmia diagnosticada. Los resultados obtenidos concuerdan con los rangos reportados por Zunino et al, (2012) para ECG.

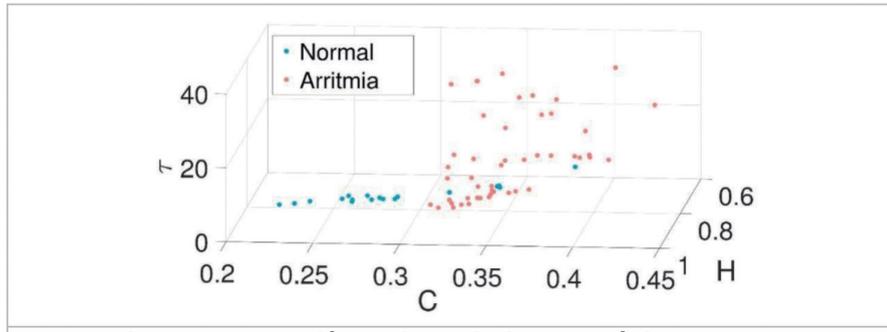


**Fig. 6. Valores de  $\tau_{Hmin}$  y  $\tau_{Cmax}$  para ambos grupos de interés, donde los ECG encuentran representados de acuerdo a su orden de aparición en la base de datos de *Physionet***

Comenzando con la formulación del conjunto de características calculado a partir de las series temporales de ECG de pacientes con ritmo cardíaco normal y con arritmias provenientes de la base de datos de *Physionet*, se calculan la entropía de permutación de Shannon y la complejidad estadística empleando un valor de tiempo de retraso de embebido individual para cada señal. Luego, a partir de los valores de estas variables, se construyen las diferentes combinaciones para conformar los espacios de características como se describe en la Tabla 3. Como se observa en la Figura 8, y se detalla en la Figura 7, las señales de ECG de ritmo sinusal normal muestran, en su forma de onda, valores de EP mayores y una medida de complejidad estadística menor en relación con el grupo de pacientes arrítmicos. Además, se confirma el desplazamiento de la nube de puntos de los pacientes con arritmias cardíacas hacia el espacio de una medida de mayor complejidad estadística y de una EP menor, característica previamente reportada por Martínez Coq *et al*, (2019). Todos los puntos se representan en el plano  $H \times C$  dentro del área limitada por las dos curvas límite  $C_{min}$  y  $C_{max}$ . Los que provienen del grupo de señales de ECG con arritmias permanecen por encima de la zona donde existen los  $k$ -ruidos, con un valor aproximado de  $k=2,5$ , tal como lo exponen Rosso *et al*, (2013). Por otro lado, el grupo de las señales de ECG de ritmo cardíaco normal se encuentra cerca de la región caracterizada por los procesos aleatorios.



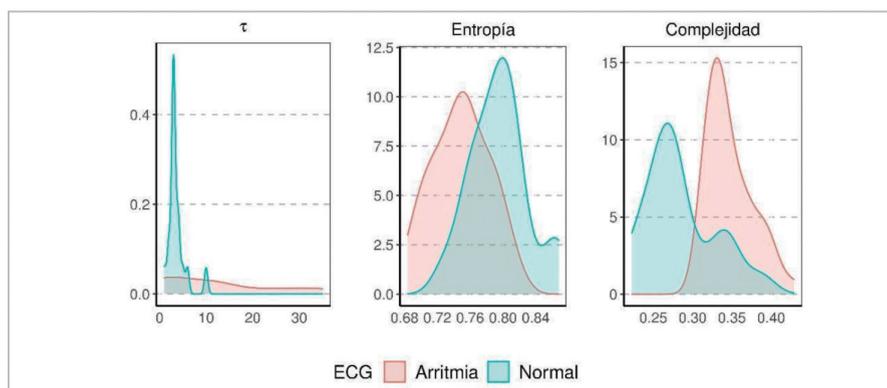
**Fig. 7. Representación en el plano  $H \times C$ , junto con las curvas límite  $C_{min}$  y  $C_{max}$ .**



**Fig. 8.** Representación en el espacio de características  $H \times C \times \tau$

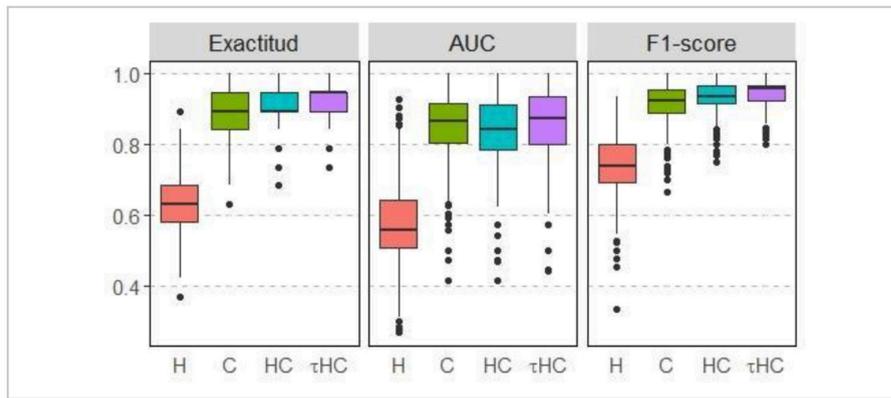
Se supone que un sistema dinámico que desarrolla un comportamiento caótico, presenta cierto grado de orden en su evolución frente a un sistema que es meramente estocástico. Mientras tanto, el ruido, característico de los procesos aleatorios, no introduce orden, sino que su dinámica no se rige por ninguna función de distribución conocida.

En el sector izquierdo de la Figura 9 se aprecia que los valores del tiempo de retraso de embebido para el caso de muestras de ECG normales se distribuyen dentro del intervalo  $[1, 10]$ , mostrando una mayor concentración dentro del intervalo  $[3, 4]$ , como lo sugieren otros algoritmos propuestos por Myers *et al.*, (2019, 2021) y Riedl *et al.*, (2013). Por otra parte, las muestras de las señales de ECG de pacientes con arritmias se asemejan a un comportamiento uniforme con una frecuencia de aparición más alta dentro del intervalo  $[1, 2]$ . Los resultados obtenidos son ligeramente diferentes de los reportados previamente por Martínez Coq *et al.*, (2019), donde  $\tau$  se fijó en 15 para todas las señales bajo análisis. A pesar de que los picos en las distribuciones de la EP están separados como se evidencia en el gráfico central de la Figura 9, la fuerte superposición entre las dos distribuciones es notoria. Por otro lado, las distribuciones para la medida de complejidad estadística que se presentan en el lado derecho de la Figura 9, muestran una clara separación entre sus picos. Sin embargo, el grupo de los ECGs de ritmo cardíaco normal también presentan un segundo pico modal cuya posición está alineada con el pico del grupo de paciente con arritmia. Esta característica puede interpretarse como cierto grado de deficiencia en la calidad de la clasificación del grupo de ECG de pacientes con ritmo normal. Como consecuencia de estas tres distribuciones, la medida de complejidad estadística y el tiempo de retraso de embebido demuestran ser las variables del conjunto de datos más significativas para entrenar el clasificador.

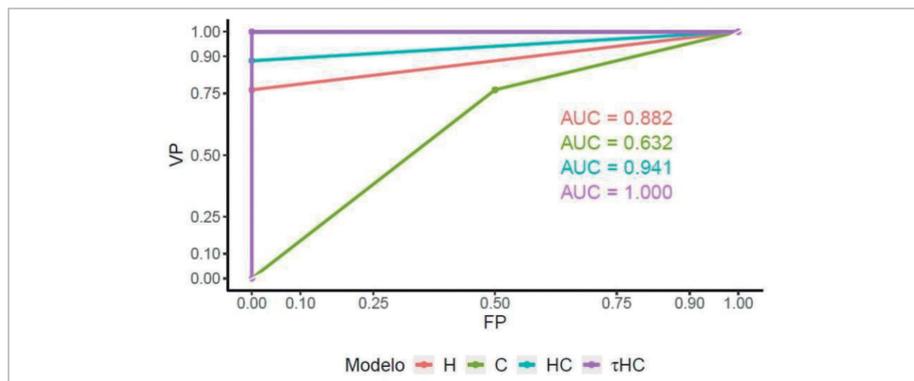


**Fig. 9.** Distribución de cada característica de acuerdo al tipo de ECG

En la Figura 10 se muestran los diagramas de caja o *boxplots* (en inglés) para las medidas de calidad de los modelos de clasificación cuando se realiza una simulación de Montecarlo de 1000 ensayos. Además, como se puede ver en Tabla 4, al incorporar más características en el clasificador, se hallan mejores valores de exactitud, de AUC y de F1-score. El clasificador de mejor rendimiento se alcanza cuando el tiempo de retraso de embebido, la PE y la medida de complejidad estadística se consideran como variables del conjunto de características. En este caso, los valores medios obtenidos son 0,921 para la exactitud, 0,870 para el AUC y 0,946 para el F1-score. Esta mejora en el rendimiento del clasificador también se observa al comparar el AUC (ver Figura 11), que muestra un ejemplo donde su valor es 1 cuando el tiempo de retraso de embebido, la PE y la medida de complejidad estadística se consideran como variables de características. Este valor es aproximadamente un 58 % superior al mínimo alcanzado por las otras posibles combinaciones de características. Asimismo, se observa que, al incorporar el tiempo de retraso de embebido como variable en el espacio de características, no sólo aumenta el AUC, sino que el punto de corte se aleja de la línea de clasificación aleatoria (bisectriz en el gráfico de la ROC).



**Fig. 10. Distribución de los indicadores de calidad para cada uno de los modelos de clasificación luego de una simulación de Montecarlo de 1000 ensayos**



**Fig. 11. Ejemplos de las curvas ROC y las diferentes AUC dependiendo del modelo de clasificación utilizado**

Tabla 4. Valores estadísticos descriptivos para los indicadores de calidad de los modelos luego de una simulación de Montecarlo de 1000 ensayos

<b>Modelo</b>	<b>Medida</b>	<b>Exactitud</b>	<b>AUC</b>	<b>F1-score</b>
<b>H</b>	<b>Mínimo</b>	<b>0,368</b>	<b>0,267</b>	<b>0,333</b>
	<b>Mediana</b>	<b>0,632</b>	<b>0,560</b>	<b>0,741</b>
	<b>Media</b>	<b>0,634</b>	<b>0,572</b>	<b>0,737</b>
	<b>Máximo</b>	<b>0,895</b>	<b>0,929</b>	<b>0,938</b>
<b>C</b>	<b>Mínimo</b>	<b>0,632</b>	<b>0,417</b>	<b>0,667</b>
	<b>Mediana</b>	<b>0,895</b>	<b>0,864</b>	<b>0,923</b>
	<b>Media</b>	<b>0,878</b>	<b>0,856</b>	<b>0,913</b>
	<b>Máximo</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
<b>HC</b>	<b>Mínimo</b>	<b>0,684</b>	<b>0,417</b>	<b>0,750</b>
	<b>Mediana</b>	<b>0,895</b>	<b>0,842</b>	<b>0,938</b>
	<b>Media</b>	<b>0,905</b>	<b>0,843</b>	<b>0,936</b>
	<b>Máximo</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
<b><math>\tau</math>HC</b>	<b>Mínimo</b>	<b>0,737</b>	<b>0,441</b>	<b>0,800</b>
	<b>Mediana</b>	<b>0,947</b>	<b>0,875</b>	<b>0,960</b>
	<b>Media</b>	<b>0,921</b>	<b>0,870</b>	<b>0,946</b>
	<b>Máximo</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>

## Conclusiones

Un primer aspecto a resaltar como resultado de este trabajo es que el tiempo de retraso de embebido presenta una menor dispersión para el grupo de señales de ECG de ritmo cardíaco normal con respecto al grupo de las señales de ECG que presentan arritmias. Este hallazgo podría estar relacionado con un mayor grado de autocorrelación del primer grupo de señales respecto del segundo. La incorporación del tiempo de retraso de embebido individualizado para cada señal de ECG, se convierte en una implementación objetiva de este parámetro que usualmente se fija en un valor único para todo el conjunto de señales dado.

Con respecto a los resultados obtenidos con los algoritmos de clasificación, la metodología basada en *Random Forest* en señales de ECG de derivaciones unipolares de pacientes con ritmo cardíaco normal y arritmico, mostró la obtención de resultados satisfactorios cuando se la emplea con un espacio de características constituido por la entropía de permutación de Shannon, la complejidad estadística de Jensen-Shannon y el tiempo de retraso de embebido. Para la selección del mejor resultado se tuvieron en cuenta los valores de los indicadores de calidad de clasificación, calculados luego de haber realizado 1000 simulaciones de Montecarlo, tomándose la decisión en función del valor más alto alcanzado por todos los indicadores en conjunto.

La metodología propuesta tiene una notable sencillez conceptual y muestra una prometedora eficacia en la clasificación y detección de patologías cardiovasculares. Independientemente de la elección de cualquier modelo de clasificación, la posición en el plano  $H \times C$  de los diferentes regímenes dinámicos: determinista, caótico, y estocástico; ha sido ampliamente reportada por Rosso *et al.*, (2013), y Zanin y Olivares (2021). El hecho de seleccionar el tiempo de retraso de embebido para cada señal de ECG, después de una búsqueda bibliográfica rigurosa, agrega una nueva dimensión que define un espacio tridimensional  $H \times C \times \tau$ . Este innovador punto de vista podría ofrecer una alternativa prometedora para diferenciar con mayor grado de detalle ciertos comportamientos dinámicos, con el fin de contribuir a una mejor caracterización de los mismos.

Dada la practicidad de hacer uso de un solo canal de derivación del ECG, sumado a la eficiencia computacional de los algoritmos, la metodología propuesta es posible de incorporar en diversos dispositivos de diagnóstico portables, asistiendo de esa manera al seguimiento ambulatorio de los pacientes.

De todas formas, para consolidar la presente propuesta es imprescindible extender el estudio utilizando bases de datos más amplias y realizando las interconsultas correspondientes con profesionales de ciencias de la salud.

## Referencias

- BANDT, C. y POMPE, B., (2002). Permutation entropy: a natural complexity measure for time series, *Physical Review Letters*, 88(17), 174102.
- BAYÉS DE LUNA, A., (2008). *Basic electrocardiography: normal and abnormal ECG patterns*, John Wiley & Sons.
- BRISAUD, J. B., (2005). The meanings of entropy, *Entropy*, 7(1), 68-96.
- CAMM, A. J.; MALIK, M.; BIGGER, J. T.; BREITHARDT, G.; CERUTTI, S.; COHEN, R. J. y SINGER, D. H., (1996). Heart rate variability: standards of measurement, physiological interpretation and clinical use, Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology.
- EBRAHIMI, Z.; LONI, M.; DANESHTALAB, M. y GHAREHBAGHI, A., (2020). A review on deep learning methods for ECG arrhythmia classification, *Expert Systems with Applications: X*, 7, 100033.
- GOLDBERGER, A. L.; AMARAL, L. A.; GLASS, L.; HAUSDORFF, J. M.; IVANOV, P. C.; MARK, R. G. y STANLEY, H. E., (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals, *Circulation*, 101(23), e215-e220.
- GOLDSTEIN, S.; SOLDEVILA, J. G. y BAYÉS DE LUNA, A., (1994). *Sudden cardiac death*, Futura Publishing Company.
- GRAY, B.; ACKERMAN, M. J.; SEMSARIAN, C. y BEHR, E. R., (2019). Evaluation after sudden death in the young: a global approach, *Circulation: Arrhythmia and Electrophysiology*, 12(8), e007453.
- GRAY, R. M., (2011). *Entropy and information theory*, Springer Science & Business Media.
- FAWCETT, T., (2006). An introduction to ROC analysis, *Pattern Recognition Letters*, 27(8), 861-874.
- HENRY, M.; JUDGE, G., (2019). Permutation entropy and information recovery in nonlinear dynamic economic time series, *Econometrics*, 7(1), 10.
- KANTZ, H.; KURTHS, J. y MAYER-KRESS, G., (EDS), (2012). *Nonlinear analysis of physiological data*, Springer Science & Business Media.
- KHAN, M. G., (2008). *Rapid ECG interpretation*, Totowa, NJ: Humana Press.
- KOLMOGOROV, A. N., (1958). New metric invariant of transitive dynamical systems and endomorphisms of Lebesgue spaces, In *Doklady of Russian Academy of Sciences* (Vol, 119, p, N5).
- KOWALSKI, A. M.; MARTÍN, M. T.; PLASTINO, A. y ROSSO, O. A., (2007). Bandt–Pompe approach to the classical-quantum transition, *Physica D: Nonlinear Phenomena*, 233(1), 21-31.
- LIAW, L., (2001). Random forests, *Machine learning*, 45(1), 5-32
- LIAW, A. y WIENER, M., (2002)., *Classification and regression by Random Forest*, *R news*, 2(3), 18-22.
- LÓPEZ-RUIZ, R.; MANCINI, H. L. y CALBET, X., (1995). A statistical measure of complexity, *Physics Letters A*, 209(5-6), 321-326.
- MARTÍN, M. T.; PLASTINO, A. y ROSSO, O. A., (2006). Generalized statistical complexity measures: Geometrical and analytical properties, *Physica A: Statistical Mechanics and its Applications*, 369(2), 439-462
- MARTÍNEZ COQ, P.; LEGNANI, W. y ARMENTANO, R., (2019). Detection of arrhythmic cardiac signals from ECG recordings using the entropy–complexity plane, In *Multi-disciplinary Digital Publishing Institute Proceedings* (Vol, 46, No, 1, p, 8).
- MATHEWS, S. M.; KAMBHAMETTU, C. y BARNER, K. E., (2018). A novel application of deep learning for single-lead ECG classification, *Computers in Biology and Medicine*, 99, 53-62.
- MOODY, G. B. y MARK, R. G., (2001). The impact of the MIT-BIH arrhythmia database, *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45-50.
- MYERS, A. D. y KHASAWNEH, F. A., (2019). Delay Parameter Selection in Permutation Entropy Using Topological Data Analysis, *ArXiv preprint arXiv:1905.04329*.

- MYERS, A. y KHASAWNEH, F. A., (2020). On the automatic parameter selection for permutation entropy, *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 30(3), 033130.
- MURAT, F.; YILDIRIM, O.; TALO, M.; BALOGLU, U. B.; DEMIR, Y. y ACHARYA, U. R., (2020). Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review, *Computers in Biology and Medicine*, 120, 103726.
- NALBANTOV, G.; IVANOV, S. y VAN PREHN, J., (2020). Multi-Class Classification of Pathologies Found on Short ECG Signals, In *2020 Computing in Cardiology* (pp, 1-4), IEEE.
- OLIVARES, F.; SOUZA, L.; LEGNANI, W.; ROSSO, O. A., (2019). Informational time causal planes: A tool for chaotic map dynamic visualization, In *Nonlinear Systems-Theoretical Aspects and Recent Applications*, Intech Open.
- POPOV, A.; AVILOV, O.; KANAYKIN, O., (2013). Permutation entropy of EEG signals for different sampling rate and time lag combinations, In *2013 Signal Processing Symposium (SPS)* (pp, 1-4), IEEE.
- R CORE TEAM, (2021). R: A language and environment for statistical computing, R Foundation for Statistical Computing, Vienna, Austria, URL <https://www.R-project.org/>.
- RAJKUMAR, A.; GANESAN, M.; LAVANYA, R., (2019). Arrhythmia classification on ECG using Deep Learning, In *2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)* (pp, 365-369), IEEE.
- REYNA, M. A.; ALDAY, E. A. P.; GU, A.; LIU, C.; SEYEDI, S.; RAD, A. B. y CLIFFORD, G. D., (2020). Classification of 12-lead ECGs: The Physionet/ computing in cardiology challenge 2020, In *2020 Computing in Cardiology* (pp, 1-4), IEEE.
- RIEDL, M.; MÜLLER, A. y WESSEL, N., (2013). Practical considerations of permutation entropy, *The European Physical Journal Special Topics*, 222(2), 249-262.
- ROSSO, O. A.; DE MICCO, L.; LARRONDO, H. A.; MARTÍN, M. T. y PLASTINO, A., (2010). Generalized statistical complexity measure, *International Journal of Bifurcation and Chaos*, 20(03), 775-785.
- ROSSO, O. A.; OLIVARES, F.; ZUNINO, L.; DE MICCO, L.; AQUINO, A. L.; PLASTINO, A. y LARRONDO, H. A., (2013). Characterization of chaotic maps using the permutation Bandt-Pompe probability distribution, *The European Physical Journal B*, 86(4), 1-13.
- SANNINO, G. y DE PIETRO, G., (2018). A deep learning approach for ECG-based heart-beat classification for arrhythmia detection, *Future Generation Computer Systems*, 86, 446-455.
- SHANNON, C. E., (1948). A mathematical theory of communication, *ACM SIGMOBILE Mobile Computing and Communications Review*, 5(1), 3-55.
- SINAI, I., (1959). On the concept of entropy for a dynamic system, *Doklady Akademii Nauk SSSR*, 124(4), 768-771.
- TEPLITZKY, B. A.; MCROBERTS, M. y GHANBARI, H., (2020). Deep learning for comprehensive ECG annotation, *Heart Rhythm*, 17(5), 881-888.
- ZANIN, M. y OLIVARES, F., (2021). Ordinal patterns-based methodologies for distinguishing chaos from noise in discrete time series, *Communications Physics*, 4(1), 1-14.
- ZUNINO, L.; SORIANO, M. C. y ROSSO, O. A., (2012). Distinguishing chaotic and stochastic dynamics from time series by using a multiscale symbolic approach, *Physical Review E*, 86(4), 046210.