

# Cardiac Ischemia Detection using Parameters Extracted from the Intrinsic Mode Functions

Carolina Fernández Biscay , María Paula Bonomini , Miguel Eduardo Zitto , Rosa Piotrkowski  and Pedro David Arini 

**Abstract**—Cardiac ischemia is the main cause of death in the world, thus the importance of prevention and early detection of these events. Traditionally, ischemia is detected by analyzing the alteration of the ST level in the electrocardiogram (ECG). In this study, we propose two new parameters extracted from the ECG to improve the cardiac ischemia detection. For this, the signal was decomposed using the Empirical Mode Decomposition, and the Intrinsic Mode Functions related to the frequency band of the ST level were selected. From these modes, two parameters were obtained: the Hjorth Activity and the frequency amplitude, using the Hilbert Transform. With these parameters, two analyses were done. First, the parameters obtained during normal periods were compared with those obtained during ischemic events. Second, a temporal series was obtained with both parameters, where the detection was done using an adaptive threshold. Results were obtained using all the patients with MLIII lead of the European ST-T Database. Parameters differed significantly across ischemic and non ischemic episodes, obtaining a sensitivity and positive predictive value of 88%, after removing noisy records. Also, a multi-lead detection was performed in patients with MLIII and V4 leads. The sensitivity and positive predictive value obtained were 92% and 80%, respectively.

**Index Terms**—Electrocardiogram, Empirical Mode Decomposition, Hilbert Transform, Hjorth Activity.

## I. INTRODUCCIÓN

La Organización Mundial de la Salud reportó que la principal causa de defunciones en el mundo es la cardiopatía isquémica, siendo esta patología la responsable del 16% de las muertes en 2019. Esta tendencia continúa en aumento, ya que en el 2000 aproximadamente 2 millones de defunciones fueron por isquemias cardíacas, mientras que en el 2019 fueron casi 9 millones [1]. Por este motivo se pone especial esfuerzo en la prevención y en la detección temprana de esta enfermedad.

### A. Isquemia Cardíaca

La isquemia cardíaca se caracteriza por la disminución parcial o total del flujo sanguíneo que nutre y oxigena al tejido cardíaco. Este cuadro puede producir un área de necrosis denominada infarto. La detección temprana y precisa de la

isquemia miocárdica brinda la posibilidad de evitar llegar a esta etapa crítica.

### B. Detección de Isquemia Cardíaca

Tradicionalmente, para la detección de isquemias cardíacas se utiliza el Electrocardiograma (ECG). El ECG es un estudio no invasivo que registra la actividad eléctrica del corazón a través de electrodos ubicados en la superficie del cuerpo [2]. Un latido del corazón se representa en el ECG como se puede observar en la Fig. 1. El tiempo que transcurre desde el final de la despolarización ventricular hasta el comienzo de la repolarización ventricular u onda T se denomina segmento ST. Cuando la perfusión cardíaca se encuentra dentro de rangos normales, el potencial de este segmento es isoelectrico en relación al potencial del segmento PR. No obstante, ante la presencia de una isquemia miocárdica se puede producir tanto una elevación como una disminución del potencial eléctrico del segmento ST en relación al segmento PR. Este comportamiento se explica a partir de la disminución de sangre que nutre al tejido miocárdico, resultando en una despolarización diferencial de los potenciales de membrana en comparación con los potenciales de membrana en las regiones no isquémicas [3]. En la Fig. 2a puede observarse un ejemplo de latido normal, mientras que en las Fig. 2b y 2c se presentan dos ejemplos de latidos durante episodios isquémicos, con elevación y depresión del segmento ST, respectivamente.




Fig. 1. ECG de un latido normal. Se indica el segmento PR, desde el fin de la despolarización auricular (onda P) hasta el inicio de la despolarización ventricular (complejo QRS). El segmento ST es el período desde el fin de la despolarización ventricular hasta el inicio de la repolarización ventricular (onda T).

Como las isquemias se producen de manera transitoria, para detectarlas comúnmente se realizan registros Holter o ECG de larga duración en donde se realiza un registro continuo de entre 24 a 48 h, utilizando 2 o 3 derivaciones, mientras el paciente realiza su actividad normal. Esto hace que el registro tenga mucho más ruido que un ECG de reposo [4]. En este contexto, la detección automática del desnivel ST se dificulta.

Carolina Fernández Biscay, M. Paula Bonomini y Pedro D. Arini trabajan en el Instituto Argentino de Matemática "Alberto P. Calderón", CONICET, Ciudad Autónoma de Buenos Aires, Argentina, y en el Instituto de Ingeniería Biomédica, Facultad de Ingeniería, Universidad de Buenos Aires, Argentina.

Rosa Piotrkowski, trabaja en el Instituto de Tecnologías Emergentes y Ciencias Aplicadas (ITECA), UNSAM-CONICET, Escuela de Ciencia y Tecnología, Centro de Matemática Aplicada (CEDEMA), Argentina y Facultad de Ingeniería, Universidad de Buenos Aires, Argentina.

Miguel Eduardo Zitto, trabaja en la Facultad de Ingeniería, Universidad de Buenos Aires, Argentina, y en la Universidad Tecnológica Nacional, Regional Buenos Aires, Buenos Aires, Argentina.

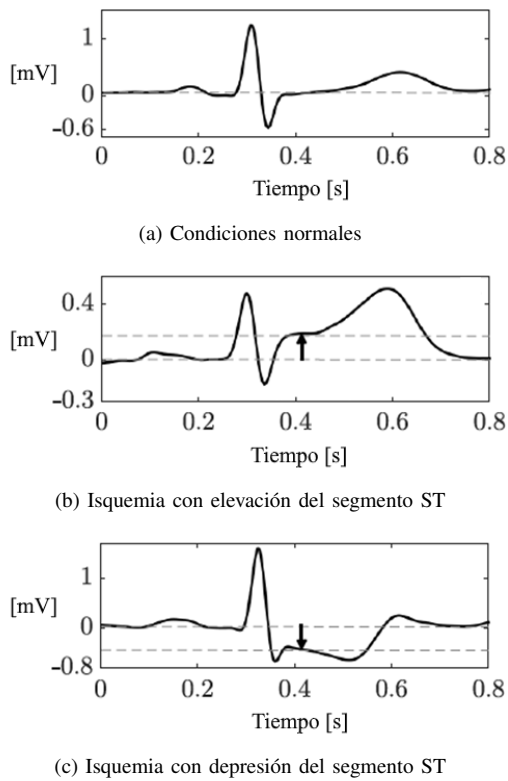


Fig. 2. Latidos con distintos niveles del segmento ST. En a) se muestra un ejemplo de latido normal, donde el segmento ST es isoelectrico al igual que el segmento PR. En b) y c) se observan dos latidos isquémicos con un aumento y disminución del segmento ST, respectivamente.

### C. Estado del Arte

Se han utilizado diversas técnicas para la detección automática de isquemias miocárdicas. Tradicionalmente se estudió en el dominio temporal analizando cambios en el segmento ST y en la morfología de la onda T [5] [6] [7]. En lo referido a la aplicación de métodos de análisis de sistemas estocásticos, se ha utilizado la Transformada de Karhunen-Loève con el mismo propósito [8] [9] [10]. A su vez, la Transformada Wavelet ha demostrado ser útil para encontrar los puntos característicos de la señal de ECG [11] y para extraer parámetros como la entropía a distintos niveles frecuenciales [12]. También se ha utilizado el Análisis de Componentes Principales para clasificar cada segmento ST como normal o anormal [13].

Luego de la extracción de parámetros, el método más simple para definir el comienzo y fin de un evento isquémico es la utilización de un umbral, fijo [5] o adaptativo [8] [7] o incluso un conjunto de umbrales que definan una zona de resguardo [14], reduciendo de este modo la cantidad de falsos positivos.

Otros métodos para clasificar latidos isquémicos y no isquémicos, luego de un proceso de extracción de características, son las redes neuronales [8] [13] y máquinas de soporte vectorial [15].

### D. Objetivos y Organización del Trabajo

Si bien se han utilizado muchos métodos para mejorar la detección de eventos isquémicos, este continúa siendo un problema no resuelto [16] [17]. El objetivo de este trabajo

es presentar nuevos parámetros relacionados con los planos temporal y frecuencial para mejorar la detección de eventos isquémicos, independizándonos de los puntos característicos de las ondas, los cuales inducen a errores en la medición de parámetros.

El artículo se organizó en cinco secciones. Primero, la sección Materiales, donde se encuentra la información sobre la base de datos que se utilizó para validar los resultados. Luego, Metodología, donde se explican las herramientas matemáticas aplicadas y las distintas etapas involucradas en el diseño del detector de isquemia. La sección de Resultados, la cual brinda la información sobre el desempeño del detector diseñado. A continuación se encuentra la sección de Discusión, donde se tratan distintos temas relacionados con el diseño del detector, su evaluación, y comparación con los resultados obtenidos en otros trabajos. Por último, en Conclusión se resumen los resultados más relevantes y aportes del presente trabajo.

## II. MATERIALES

Para evaluar el rendimiento del detector se utilizaron registros de la base de datos European ST-T Database (EDB) [18]. Estos registros son de acceso libre en el sitio web de Physionet [19]. La EDB contiene registros de ECG de larga duración de 2 derivaciones. Cada registro presenta las 2 derivaciones donde mejor se evidenciaron las isquemias. Cada señal, de 2 h de duración, contiene anotaciones realizadas por especialistas marcando el comienzo y fin de los eventos isquémicos. En este trabajo se analizaron primero los pacientes con señales correspondientes a la derivación MLIII y luego los que tenían las dos derivaciones MLIII y V4, simultáneamente.

## III. MÉTODOS

En la Fig. 3 se muestra un diagrama de flujo con las cinco etapas del trabajo que se detallan a continuación.

### A. Descomposición Empírica de Modos

Como etapa de preprocesamiento, a cada señal de ECG se le aplica la Descomposición Empírica de Modos, del inglés Empirical Mode Decomposition (EMD). Esta es una técnica que se utiliza para descomponer señales en Funciones Intrínsecas de Modos. Una Función Intrínseca de Modo, del inglés Intrinsic Mode Function (IMF), tiene la particularidad de ser una función oscilatoria simple, cuya amplitud y frecuencia se modifican en el tiempo. De este modo, es posible obtener su frecuencia en un instante de tiempo. La ventaja de la EMD es que puede utilizarse para señales no lineales y no estacionarias, tal como el ECG [20].

Las IMFs deben cumplir con los siguientes criterios:

- La cantidad de máximos y mínimos locales debe diferir en no más de 1.
- Deben tener valor medio local igual a 0.

El algoritmo de iteración para obtener las IMFs se ilustra en la Fig. 4, y se detalla a continuación en tres puntos:

- Se calculan los máximos y mínimos locales de la señal de entrada,  $x[n]$ , y luego se interpolan mediante un

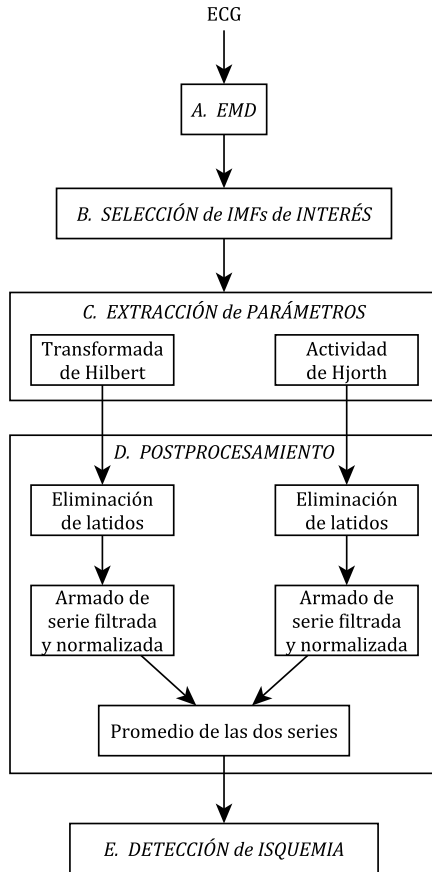


Fig. 3. Diagrama de flujo del detector de isquemia. Se divide en una etapa de preprocesamiento, basada en la Descomposición Empírica de Modos (EMD) y la posterior extracción de las Funciones Intrínsecas de Modos (IMFs) de interés, una etapa de extracción de parámetros (Actividad de Hjorth y Amplitud de la Transformada de Hilbert), seguido de un postprocesamiento de la serie obtenida a partir de los parámetros y, por último, una etapa de detección de isquemias realizado con un umbral adaptativo.

spline cúbico, computando la envolvente superior,  $u[n]$ , e inferior,  $l[n]$ , respectivamente.

- 2) Se obtiene el valor medio local entre las envolventes muestra a muestra:  $m[n] = (u[n] + l[n])/2$
- 3) Se resta el valor medio a la señal de entrada,  $h[n] = x[n] - m[n]$ , y se verifica si  $h[n]$  cumple con los criterios a) y b) para ser considerada una IMF.

Si no es una IMF, el algoritmo se reinicia en el punto 1), utilizando como señal de entrada a  $h[n]$ . Este proceso se itera hasta que  $h[n]$  sea una IMF, o hasta llegar al número máximo de iteraciones definido desde el inicio. Cuando ocurre esto, se guarda ese modo,  $IMF_i[n] = h[n]$ , donde  $i$  es el número de las IMFs encontradas hasta ese momento. Luego, se le resta esa IMF a la señal de entrada,  $g[n] = x[n] - IMF_i[n]$ , y el proceso vuelve a comenzar con la nueva señal  $g[n]$ , hasta encontrar una nueva IMF. Esto se repite hasta que la señal obtenida  $g[n]$  es un residuo, es decir, una señal monótona o que posee a lo sumo un extremo. Un ejemplo del proceso de iteración se ilustra en la Fig. 5.

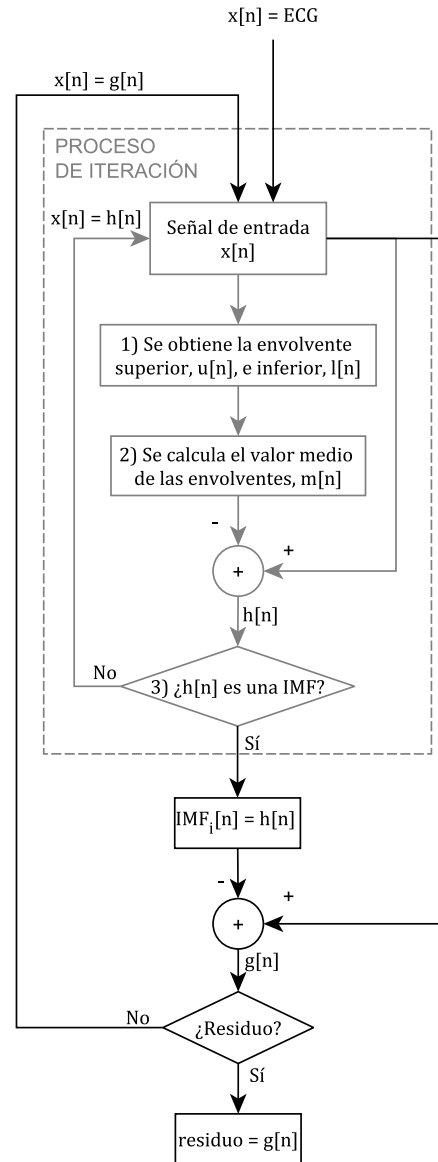


Fig. 4. Diagrama de flujo del algoritmo de EMD, formado por un proceso de iteración para extraer las IMF de la señal.

### B. Selección de las IMFs

Una vez finalizada la descomposición se seleccionan los modos de interés, que en nuestro caso son los IMFs 8, 9 y 10. Esto se realiza porque se verificó, a través de la transformada de Hilbert, que en estos modos estaba el contenido de la señal correspondiente a la banda de frecuencia entre 0,5 y 5 Hz, donde se encuentra la información del segmento ST [21].

### C. Extracción de Parámetros

Luego de seleccionar los modos se extraen dos parámetros: la Actividad de Hjorth [22] y la Amplitud de la Transformada de Hilbert.

1) *Actividad de Hjorth*: Para calcular este parámetro, los modos 8, 9 y 10 se suman y se obtiene una única señal




Fig. 5. Proceso de iteración del algoritmo de EMD sobre una señal ejemplo. En el panel superior se muestra en línea continua una señal,  $x[n]$ , en líneas cortadas se graficaron las envolventes,  $u[n]$  y  $l[n]$ , y en línea de puntos la media entre las envolventes,  $m[n]$ . En el panel medio se grafica la media de las envolventes,  $m[n]$ , y en el panel inferior el resultado de restar la media a la señal original,  $h[n] = x[n] - m[n]$ .

que llamamos  $s[n]$ . Como puede observarse en la Ec. 1, la actividad de Hjorth representa la varianza local de la señal,  $N$  es una ventana que incluye 10 latidos cardíacos consecutivos.

$$Act[n] = \frac{1}{N} \sum_{j=n-N/2}^{n+N/2} (s[j] - \bar{s})^2 \quad (1)$$

2) *Amplitud de la Transformada de Hilbert*: La ventaja de obtener las IMFs de la señal es que a estas funciones se les puede aplicar la transformada de Hilbert y pueden expresarse mediante exponenciales complejas. Como se puede ver en la Ec. 2, la parte real de dicha expresión son las IMFs.

$$IMF_i[n] = Re\{a[n] \cdot e^{i\phi[n]}\} \quad (2)$$

Donde,  $a[n]$  y  $\phi[n]$  son la amplitud y la fase instantánea de la señal bajo análisis. De esta manera, se obtiene la amplitud y frecuencia instantánea (derivada de la fase instantánea) para cada modo, y se realiza la sumatoria del contenido en frecuencias de los modos de interés, obteniendo así una única amplitud a lo largo del tiempo,  $Hil[n]$ .

#### D. Postprocesamiento

Una vez obtenidas las dos series de parámetros, actividad de Hjorth y amplitud de la transformada de Hilbert, se realiza una etapa de eliminación de latidos. Para ello, se utilizan las marcas obtenidas por el detector de QRS ARISTOTLE [23], y se eliminan todos los latidos que no fueran normales. Por otro lado, se realiza una eliminación de latidos ruidosos a partir de cambios abruptos en la línea de base como hizo García et al. [7]. Así, se eliminan los latidos cuando la diferencia en la media de la línea de base de un latido con el siguiente es mayor a  $400\mu V$ . Para calcular la línea de base se realiza un spline cúbico utilizando los puntos medios de cada segmentos PR [24], obtenidos a partir de un delineador basado en la Transformada Wavelet [25]. Luego, se remuestran las series obtenidas para cada parámetro y se aplica un filtro de media móvil. Por último, se normalizan las series, utilizando la media y el desvío obtenido en los primeros 100 latidos de cada serie.

Los primeros 100 latidos de los registro de la base de datos son considerados basales, en donde el paciente está acostado y no se presentan eventos isquémicos. Una vez obtenidas las dos series, se crea una única serie promediando las dos anteriores,  $z[n]$ , sobre la cual se quiso detectar la isquemia:

$$z[n] = \frac{Hil[n] + Act[n]}{2} \quad (3)$$

#### E. Detección de Isquemia

Para la detección, se utiliza un umbral adaptativo realizando un promediado exponencial de la serie durante los latidos que no son considerados isquémicos, como realizó García et al. [7]. En la Ec. 4 se puede ver la relación entre la línea de base,  $b[n]$ , y la serie,  $z[n]$ , en donde  $\beta$  es la velocidad a la que se ajusta a la serie.

$$b[n] = b[n-1] + \beta \cdot (z[n] - z[n-1]) \quad (4)$$

La línea de base se calcula únicamente en los latidos considerados no isquémicos. Se consideran latidos isquémicos aquellos que cumplen con  $z[n] - b[n-1] > \eta$ . El parámetro  $\beta$  que se utiliza es 0,001, mientras que el parámetro  $\eta$  se computa para cada paciente. Para eso se ajusta el histograma de la serie a dos gaussianas. Idealmente, una Gaussiana representa a los latidos normales de la serie y la otra a los latidos isquémicos. Se fija  $\eta$  como la intersección entre las dos gaussianas. Un ejemplo se puede observar en la Fig. 6.




Fig. 6. Ejemplo de obtención del parámetro  $\eta$  para fijar el umbral en cada paciente. En el gráfico se ven las dos Gaussianas ajustadas al histograma de la serie y  $\eta$  se define como el valor donde se intersecan ambas gaussianas.

Para el caso de la detección multi derivación, se realiza el mismo procedimiento antes descrito para las dos derivaciones por separado, si se detecta un evento isquémico en alguna de las dos derivaciones se considera que hay una isquemia.

## IV. RESULTADOS

En una primera instancia, se analizaron los parámetros por separado de los registros de la derivación MLIII, para ver si los mismos tenían diferencias significativas durante eventos isquémicos y no isquémicos. Los resultados obtenidos se muestran en los gráficos de caja de las Fig. 7a y 7b. Para realizar este análisis se tomaron todos los eventos isquémicos y la misma cantidad de eventos no isquémicos, seleccionando aleatoriamente períodos de aproximadamente 6 minutos en donde el nivel ST medido sea considerado normal. Se excluyeron los primeros 100 latidos de este análisis ya que son

los utilizados para normalizar a los parámetros. Se tomaron períodos no isquémicos de aproximadamente 6 minutos porque es el valor medio de la duración de los eventos isquémicos en la base de datos. En cada período se calculó el valor medio del parámetro durante ese evento, estos son los valores graficados en las Fig. 7a y 7b. Para analizar si la diferencia entre ambas poblaciones fue significativa, se utilizó la prueba U de Mann-Whitney, ya que es una prueba no paramétrica aplicada en dos muestras independientes. Para ambos parámetros resultó  $p < 0.0001$ .

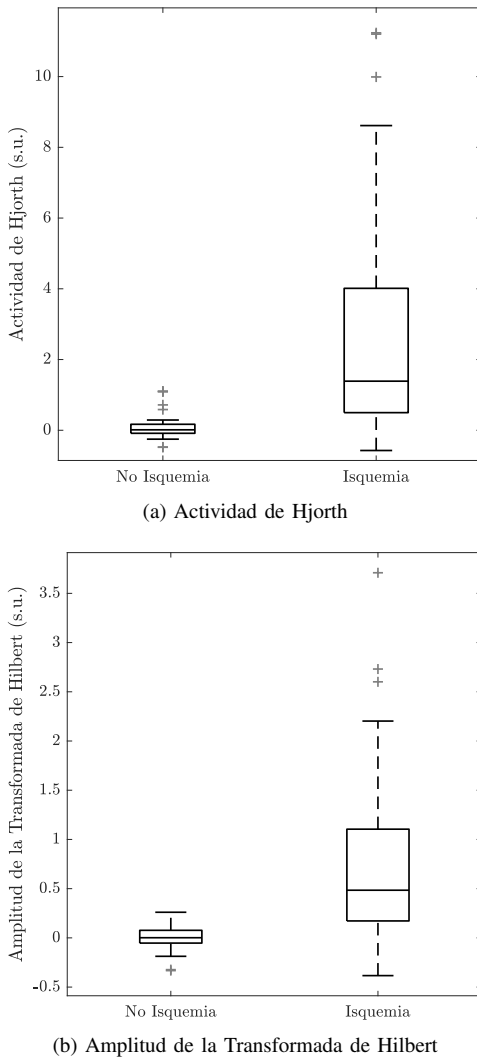


Fig. 7. Gráficos de caja donde se evidencian las diferencias de los parámetros durante eventos isquémicos y no isquémicos. Ambos parámetros se encuentran normalizados por lo que no tienen unidades.

Estos parámetros fueron utilizados luego para realizar la detección de isquemia, como se detalló previamente. En la Fig. 8 se puede ver un ejemplo de detección de isquemias de un registro en donde se detectan las siete isquemias anotadas por los especialistas en la base de datos.

Utilizando todos los pacientes con derivación MLIII se incluyeron más de 110 eventos isquémicos. La sensibilidad (Se) y el valor predictivo positivo, del inglés positive predictive value (PPV), fue de 80% y 74%, respectivamente, como se muestra en la primera columna de la Tabla I.




Fig. 8. Ejemplo de detección de isquemia. En negro está graficada la serie construida a partir de los parámetros,  $z[n]$ , en línea del puntos la línea de base,  $b[n]$ , y en líneas cortadas el umbral,  $b[n] + \eta$ . En la parte inferior del gráfico se pueden ver en gris los episodios isquémicos marcados por los especialistas en la base de datos, y en negro los episodios isquémicos detectados con nuestro método.

Se encontró que algunos de los registros analizados tenían una alta relación señal-ruido. Por lo tanto, se eliminaron todos los registros donde se habían eliminado más del 40% de los latidos en la etapa de postprocesamiento. De esta manera quedaron 90 eventos isquémicos para detectar. Los resultados obtenidos de Se y PPV fueron del 81% y 79%, respectivamente, como se muestra en la segunda columna de la Tabla I.

Al realizar esta eliminación se halló que la mayoría de los registros eliminados correspondían a los registros realizados con un mismo equipo médico. Por lo tanto, se evaluaron los resultados al eliminar únicamente los registros que habían sido tomados con ese mismo equipo, quedando así unos 80 eventos isquémicos. Los resultados obtenidos de Se y PPV fueron del 88%, como se puede observar en la tercera columna de la Tabla I. En la Tabla II se puede ver la matriz de confusión obtenida, con 64 eventos isquémicos bien detectados, 9 falsos positivos y 9 falsos negativos.

Por último, se realizó una detección multi derivación. Se encontró que la combinación de derivaciones que más se repetía en la base de datos era MLIII y V4, entonces se analizaron a todos los pacientes con esta combinación de derivaciones (más de 90 eventos isquémicos) y se realizó la detección en ambas derivaciones. Los resultados obtenidos fueron del 92% y 80% de Se y PPV, respectivamente, como se muestra en la última columna de la Tabla I. La matriz de confusión se puede ver en la Tabla III, con 62 eventos isquémicos bien detectados, 14 falsos positivos y 5 falsos negativos.

## V. DISCUSIÓN

El algoritmo de EMD es una técnica de descomposición que se creó con el objetivo de poder analizar series no lineales y no estacionarias, a diferencia de otros métodos como por ejemplo la Transformada Wavelet, que se utiliza para series lineales. Como el ECG es una señal no lineal y no estacionaria, consideramos que este es un método correcto para su descomposición. Numerosos trabajos han utilizado EMD o técnicas basadas en EMD para filtrar la señal de ECG [26]

TABLA I  
RESUMEN DE LOS RESULTADOS OBTENIDOS

	Pacientes con derivación MLIII			Multi derivación MLIII y V4
	Todos los pacientes	Sin registros con alta relación señal-ruido	Sin registros obtenidos con Del Mar Avionics 445B	Todos los pacientes
Cantidad de isquemias	113	90	82	93
Se	80%	81%	<b>88%</b>	<b>92%</b>
PPV	74%	79%	<b>88%</b>	<b>80%</b>

(Se: sensibilidad; PPV: valor predictivo positivo, del inglés positive predictive value)

\*Se eliminaron todos los registros que tenían más del 40% de los latidos eliminados en la etapa de Postprocesamiento

TABLA II  
MATRIZ DE CONFUSIÓN DEL DETECTOR DE ISQUEMIA PARA REGISTROS  
DE LA DERIVACIÓN MLIII, LUEGO DE LA ELIMINACIÓN DE REGISTROS

	Predicción positiva	Predicción negativa
Anotación positiva	64	9
Anotación negativa	9	-

TABLA III  
MATRIZ DE CONFUSIÓN DEL DETECTOR DE ISQUÉMIA PARA REGISTROS  
DE LA DERIVACIÓN MLIII Y V4.

	Predicción positiva	Predicción negativa
Anotación positiva	62	5
Anotación negativa	14	-

[27] [28]. En el último tiempo también se agregaron trabajos donde comenzaban a utilizar los IMFs obtenidos del EMD para la extracción de parámetros y con ellos luego realizar un clasificador de arritmias [29] [30]. Esto fue una motivación para utilizarlo de esta misma manera pero para la detección de isquemias, algo para lo que, hasta ahora, no se ha reportado en el estado del arte.

Por otra parte, los parámetros de Hjorth fueron primero introducidos en 1970 para la extracción de características espectrales en estudios electroencefalográficos, sin necesidad de computar la transformada de Fourier instante a instante de tiempo [22], y desde entonces se los ha utilizado con distintos objetivos: reconocimiento de emociones [31], análisis de epilepsia [32], detección de Alzheimer [33], entre otros. En los últimos años también se ha comenzado a utilizar estos parámetros en ECG [34] [35] [36].

Se eligió la derivación MLIII porque, además de ser una de las derivaciones con más registros en la base de datos, se utiliza mucho en los registros Holter y en los ECG mientras se realiza actividad física. En la derivación MLIII se modifica la ubicación del electrodo y esto produce algunos cambios en el ECG. Por ejemplo, se evidencian de manera más prominente cambios en el nivel ST, sin alterar los límites considerados normales [37].

Al realizar la eliminación de latidos encontramos que había algunos registros con muchos latidos eliminados y la mayoría correspondían a los registros tomados con un mismo equipo

médico, Del Mar Avionics 445B. Con esto no decimos que el equipo médico no sea apto para la detección de isquemia o que sus registros tengan una baja relación señal-ruido, pero probablemente todos estos registros se hayan tomado en el mismo centro médico, y puede haber muchos otros factores que hayan hecho que los mismos sean más ruidosos, tales como el estado y la ubicación de los electrodos.

Como avance de este trabajo, habría que extender el análisis para otras derivaciones para poder comparar los resultados con otros detectores de isquemias. A su vez, se piensa que estos parámetros pueden agregarse a parámetros comúnmente utilizados en la detección de isquemias, como por ejemplo el nivel ST o la pendiente inicial de la onda T, y así poder realizar un detector de isquemia brindando más información de la señal que genera el evento isquémico.

Dada la gran cantidad de métodos propuestos para la detección de isquemias cardíacas, es fundamental validar estos métodos y compararlos para encontrar cuáles son los más efectivos. Para ello, se deben utilizar técnicas de validación robustas y métricas de rendimiento uniformes con el fin de crear resultados que sean generalizables y reproducibles. Sin embargo, esta no ha sido la tendencia dominante en los trabajos de detección de isquemia [17]. En primer lugar, hay una falta de uniformidad en el análisis que se debe realizar para evaluar el desempeño de un detector. Muchas veces se utiliza la sensibilidad y especificidad, definidos como  $\frac{VP}{VP+FN}$  y  $\frac{VN}{VN+FP}$ , respectivamente, donde  $VP$  son la cantidad de verdaderos positivos,  $VN$  de verdaderos negativos,  $FN$  de falsos negativos y  $FP$  de falsos positivos. Sin embargo, en un detector de isquemia, donde las clases no están balanceadas y hay una gran cantidad de  $VN$ , estas pruebas de rendimiento no reflejan el verdadero efecto de la gran cantidad de falsos positivos [17]. Es por este motivo, que es importante utilizar el PPV, definido como  $\frac{TP}{TP+FP}$ , quedando así evidenciado el efecto de los falsos positivos en los resultados del detector. Por lo tanto, es importante que en los trabajos se reporten las matrices de confusión para que el lector pueda obtener cualquiera medición del desempeño que necesite [17].

Para poder comparar distintos métodos, también se le agrega el problema de la definición de  $VP$ ,  $VN$ ,  $FP$  y  $FN$ . Algunos trabajos se refieren a latidos isquémicos o no isquémicos, mientras que otros se refieren a eventos isquémicos y no isquémicos. A su vez, algunos autores reportan las mediciones de rendimiento promedio por paciente, mientras que otros cuentan la cantidad total de eventos o latidos para calcular las distintas métricas.

Otra razón que dificulta la comparación es que los registros sobre los que se evalúan los detectores dependen de muchos factores: la base de datos, los registros, el intervalo de cada registro y la derivaciones utilizada en cada caso.

En el trabajo realizado por Ansari *et al.* [17] en el 2017, se analizan los trabajos de detección de isquemia y se detallan aquellos que explícitamente o implícitamente señalan cómo se validó el trabajo. Los resultados obtenidos por los trabajos que utilizan la base de datos EDB se reportan en la Tabla IV.

TABLA IV  
RESUMEN DE LOS RESULTADOS OBTENIDOS POR OTROS TRABAJOS

Trabajos de detección de isquemia	Se	PPV
Taddei <i>et al.</i> [6]	81%	75%
Vila <i>et al.</i> [38]	83%	75%
Maglaveras <i>et al.</i> [39]	85%	69%
Jager <i>et al.</i> [9]	81%	81%
Bezerianos <i>et al.</i> [40]	78%	74%

(Se: sensibilidad; PPV: valor predictivo positivo, del inglés positive predictive value)

Los resultados obtenidos por Taddei *et al.* [6] son el promedio de lo obtenido para cada paciente de la base de datos en dos derivaciones. Vila *et al.* [38] obtuvieron resultados similares, pero en un conjunto de testeo de 60 registros. Estos resultados se pueden comparar con los nuestros al realizar el análisis multi derivación, con las derivaciones MLIII y V4 (Ver Tabla I). En principio nuestros resultados son alentadores ya que superan aproximadamente en un 10% la Se y 5% el PPV. Si comparamos nuestros resultados con los de Jager *et al.* [9], para prácticamente el mismo PPV, con nuestro detector se obtiene un 12% más de Se. Sin embargo, para poder comparar los trabajos correctamente habría que hacer el mismo análisis para todas las derivaciones.

Los resultados reportados por Bezeriano *et al.* corresponden a la Se y el PPV obtenidos al evaluar una derivación de 30 registros. Estos resultados son comparables con los resultados obtenidos al analizar la derivación MLIII, ya que incluso en el caso donde se eliminan los registros obtenidos con el Holter Del Mar Avionics 445B se analizan más de 30 registros. Los resultados en este trabajo superan en más de un 10% a los obtenidos por Bezeriano *et al.*

Maglaveras *et al.* [39] trabajaron con la primera derivación de todos los registros. Además de los resultados reportados para toda la base de datos, informan los resultados obtenidos para cada derivación. Para la derivación MLIII obtuvieron una Se y PPV del 80% y 56.1%, respectivamente. Estos resultados se pueden comparar directamente con los nuestros al analizar todos los registros de esa misma derivación, en donde se obtuvo cerca de un 5% más de sensibilidad y 18% más de PPV. Estos resultados mejoraron aun más cuando se eliminaron los registros obtenidos con el Holter Del Mar Avionics 445B, llegando a obtener una Se y PPV del 88% para ambos casos.

En los últimos años se ha continuado trabajando en el tema, sin embargo, la mayoría de los trabajos encontrados son más breves, como por ejemplo de congresos, y no son claros en la metodología utilizada de validación. Los mismos inconvenientes encontrados por Ansari *et al.* [17] para poder comparar los resultados obtenidos, se encuentran en los últimos trabajos

publicados. Por ejemplo, en [41] reportan una exactitud del 97% al evaluar su detector en 18 registros y en [27] una Se y PPV aproximadamente del 97%, pero en ninguno de los dos trabajos queda claro cómo se realiza la validación. Algo similar ocurre en [42] en donde validan clasificando tramos de un minuto de ECG y no aclaran si hay independencia de pacientes entre el grupo de entrenamiento y el de testeo. Por último, en [43] los resultados reportados son de la clasificación de latidos, no de la detección de episodios, y lo evalúan en cerca de 13 registros, obteniendo una sensibilidad y especificidad del 95% y 83%, respectivamente. En este caso sí se aclara que hay independencia de pacientes pero no se aclara qué registros se utilizan y cuáles serían los resultados obtenidos para la detección de eventos isquémicos.

## VI. CONCLUSIONES

En este trabajo se extrajeron dos parámetros innovadores a partir de las IMFs del ECG: actividad de Hjorth y amplitud de la Transformada de Hilbert. El EMD demostró ser una técnica muy útil para poder descomponer la señal de ECG. Seleccionando las IMFs de interés se pudo obtener una señal con la información del segmento ST, de donde se extrajo la actividad de Hjorth y la amplitud de la transformada de Hilbert. Con los resultados de los parámetros obtenidos se puede concluir que los mismos son significativamente distintos durante episodios isquémicos y no isquémicos ( $p < 0.0001$ ). A su vez, los mismos pueden ser utilizados para detectar isquemias en la derivación MLIII e incluso para realizar una detección multi derivación con MLIII y V4.

## AGRADECIMIENTOS

Este trabajo se llevó a cabo con los subsidios de UBACYT (20020190200175BA) y de Agencia MINCYT (PICT 2145 2016).

## REFERENCES

- [1] W. H. Organization, "Global Health Estimates 2020: Deaths by Cause, Age, Sex, by Country and by Region, 2000-2019," tech. rep., Geneva, 2020.
- [2] L. Sörnmo and P. Laguna, "The Electrocardiogram - A Brief Background," in *Bioelectrical Signal Processing in Cardiac and Neurological Applications*, ch. 6, p. 411, Academic Press, 2005.
- [3] J. Cinca, F. J. Noriega, E. Jorge, J. Alvarez-Garcia, G. Amoros, and D. Arzamendi, "ST-segment deviation behavior during acute myocardial ischemia in opposite ventricular regions: Observations in the intact and perfused heart," *Heart Rhythm*, vol. 11, no. 11, pp. 2084-2091, 2014.
- [4] G. D. Clifford, F. Azuaje, and P. E. McSharry, *Advanced Methods and Tools for ECG Data Analysis*. Artech House, 2006.
- [5] A. Gallina, S. Chierchia, G. Smith, M. Croom, M. Morgan, C. Marchesi, and A. Maseri, "Computer system for analysis of ST segment changes on 24 hour Holter monitor tapes: Comparison with other available systems," *Journal of the American College of Cardiology*, vol. 4, no. 2, pp. 245-252, 1984.
- [6] A. Taddei, G. Costantino, R. Silipo, M. Emdin, and C. Marchesi, "A system for the detection of ischemic episodes in ambulatory ECG," *Computers in Cardiology*, pp. 705-708, 1995.
- [7] J. García, L. Sörnmo, S. Olmos, and P. Laguna, "Automatic detection of ST-T complex changes on the ECG using filtered RMS difference series: Application to ambulatory ischemia monitoring," *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 9, pp. 1195-1201, 2000.
- [8] G. Sun, C. W. Thomas, J. Liebman, Y. Rudy, Y. Reich, O. Stilli, and E. Macchi, "Classification of normal and ischemia from BSPM by neural network approach," in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1988.



- [9] F. Jager, G. B. Moody, and R. G. Mark, "Detection of transient ST segment episodes during ambulatory ECG monitoring.," *Computers and biomedical research, an international journal*, vol. 31, no. 5, pp. 305–22, 1998.
- [10] A. Smrdel and F. Jager, "Automated detection of transient ST-segment episodes in 24 h electrocardiograms.," *Medical & biological engineering & computing*, vol. 42, no. 3, pp. 303–311, 2004.
- [11] P. Ranjith, P. C. Baby, and P. Joseph, "ECG analysis using wavelet transform: application to myocardial ischemia detection Détection des événements ischémiques myocardiques à partir de la transformée en ondelettes du signal ECG," *Engineering*, vol. 24, pp. 44–47, 2003.
- [12] D. Lemire, C. Pharand, J. C. Rajaonah, B. Dubé, and A. Robert Leblanc, "Wavelet time entropy, T wave morphology and myocardial ischemia," *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 7, pp. 967–970, 2000.
- [13] T. Stamkopoulos, K. Diamantaras, N. Maglaveras, and M. Strintzis, "ECG analysis using nonlinear PCA neural networks for ischemia detection," *IEEE Transactions on Signal Processing*, vol. 46, no. 11, pp. 3030–3044, 1998.
- [14] F. Jager, R. Mark, G. Moody, and S. Divjak, "Analysis of Transient ST Segment Changes During Ambulatory Monitoring," *Computers in Cardiology 1991, Proceedings.*, pp. 453 – 456, 1991.
- [15] S. Papadimitriou, S. Mavroudi, L. Vladutu, and A. Bezerianos, "Ischemia detection with a self-organizing map supplemented by supervised learning," *IEEE Transactions on Neural Networks*, vol. 12, no. 3, pp. 503–515, 2001.
- [16] A. K. Manocha and M. Singh, "An Overview of Ischemia Detection Techniques," *International Journal of Scientific & Engineering Research, Volume 2, Issue 11*, vol. 2, no. 11, pp. 1–5, 2011.
- [17] S. Ansari, N. Farzaneh, M. Duda, K. Horan, H. B. Andersson, Z. D. Goldberger, B. K. Nallamothu, and K. Najarian, "A review of automated methods for detection of myocardial ischemia and infarction using electrocardiogram and electronic health records," *IEEE Reviews in Biomedical Engineering*, vol. 10, pp. 264–298, 2017.
- [18] A. Taddei, G. Distante, M. Emdin, P. Pisani, G. Moody, C. Zeelenberg, and C. Marchesi, "The European ST-T database standard for evaluating systems for the analysis of ST-T changes in ambulatory electrocardiography," *European Heart Journal*, vol. 13, pp. 1164–1172, 1992.
- [19] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. Ivanov, R. Mark, J. Mietus, G. Moody, C. Penk, and H. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals.," *Circulation*, vol. 23, pp. e215–e220, 2000.
- [20] N. E. Huang and S. S. P. Shen, *Hilbert-Huang Transform and Its Applications*. Interdisciplinary Mathematical Sciences, 2005.
- [21] C. Fernández Biscay, P. D. Arini, A. I. Rincón Soler, and M. P. Bonomini, "Classification of ischemic and non-ischemic cardiac events in Holter recordings based on the continuous wavelet transform," *Medical and Biological Engineering and Computing*, vol. 58, no. 5, pp. 1069–1078, 2020.
- [22] B. Hjorth, "EEG Analysis Based on Time Domain Properties," *Electroencephalography and Clinical Neurophysiology*, vol. 29, pp. 306–310, 1970.
- [23] G. B. Moody and R. G. Mark, "Development and evaluation of a 2-lead ECG analysis program," *Computers in Cardiology*, pp. 39–44, 1982.
- [24] C. R. Meyer and H. N. Keiser, "Electrocardiogram baseline noise estimation and removal using cubic splines and state-space computation techniques," *Computers and Biomedical Research*, vol. 10, no. 5, pp. 459–470, 1977.
- [25] A. J. Demski and M. L. Soria, "ecg-kit a Matlab Toolbox for Cardiovascular Signal Processing," *Journal of Open Research Software*, vol. 4, pp. 2–5, 2016.
- [26] A. Kabir and C. Shahnaz, "Denoising of ECG signals based on noise reduction algorithms in EMD and wavelet domains," *Biomedical Signal Processing and Control*, vol. 7, no. 5, pp. 481–489, 2012.
- [27] A. Kumar and M. Singh, "Statistical analysis of ST segments in ECG signals for detection of ischaemic episodes," *Transactions of the Institute of Measurement and Control*, vol. 40, no. 3, pp. 819–830, 2018.
- [28] M. Rakshit and S. Das, "An efficient ECG denoising methodology using empirical mode decomposition and adaptive switching mean filter," *Biomedical Signal Processing and Control*, vol. 40, pp. 140–148, 2018.
- [29] P. Sharma and K. C. Ray, "Efficient methodology for electrocardiogram beat classification," *IET Signal Processing*, vol. 10, no. 7, pp. 1–8, 2016.
- [30] M. Suchetha and N. Kumaravel, "Classification of arrhythmia in electrocardiogram using EMD based features and support vector machine with margin sampling," *International Journal of Computational Intelligence and Applications*, vol. 12, no. 3, pp. 1350015–13, 2013.
- [31] R. M. Mehmood and H. J. Lee, "EEG based Emotion Recognition from Human Brain using Hjorth Parameters and SVM," *International Journal of Bio-Science and Bio-Technology*, vol. 7, no. 3, pp. 23–32, 2015.
- [32] M. Tanveer, "Classification of seizure and seizure-free EEG signals using Hjorth parameters," *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2018.
- [33] M. S. Safi and S. M. M. Safi, "Early detection of Alzheimer's disease from EEG signals using Hjorth parameters," *Biomedical Signal Processing and Control*, vol. 65, 2021.
- [34] S. Hadiyoso, S. Aulia, and A. Rizal, "One-Lead Electrocardiogram for Biometric Authentication using Time Series Analysis and Support Vector Machine," *International Journal of Advanced Computer Science and Applications*, vol. 10, no. 2, pp. 276–283, 2019.
- [35] J. P. R. Leite and R. L. Moreno, "Heartbeat classification with low computational cost using Hjorth parameters," *IET Signal Processing*, vol. 12, no. 4, pp. 431–438, 2018.
- [36] S. Hadiyoso and A. Rizal, "Electrocardiogram Signal Classification Using Higher-Order Complexity of Hjorth Descriptor," *Advanced Science Letters*, vol. 23, no. 5, pp. 3972–3974, 2017.
- [37] Sivaraman Jayaraman, V. Sangareddi, R. Periyasamy, J. Joseph, and R. M. Shanmugam, "Modified limb lead ECG system effects on electrocardiographic wave amplitudes and frontal plane axis in sinus rhythm subjects," *Anatol J Cardiol.*, vol. 17, no. 1, pp. 46–54, 2017.
- [38] J. Vila, J. Presedo, M. Delgado, S. Barro, R. Ruiz, and F. Palacios, "SUTIL: Intelligent ischemia monitoring system," *International Journal of Medical Informatics*, vol. 47, pp. 193–214, 1997.
- [39] N. Maglaveras, T. Stamkopoulos, C. Pappas, and M. G. Strintzis, "An adaptive backpropagation neural network for real-time ischemia episodes detection: Development and performance analysis using the European ST-T database," *IEEE Transactions on Biomedical Engineering*, vol. 45, no. 7, pp. 805–813, 1998.
- [40] A. Bezerianos, L. Vladutu, and S. Papadimitriou, "Hierarchical space partitioning with a network self-organising map for the recognition of ST-T segment changes," *Medical & Biological Engineering & Computing*, vol. 38, no. 4, pp. 406–415, 2000.
- [41] M. Wasimuddin, K. Elleithy, A. Abuzneid, M. Faezipour, and O. Abuzaqleh, "ECG Signal Analysis Using 2-D Image Classification with Convolutional Neural Network," *2019 International Conference on Computational Science and Computational Intelligence (CSCI)*, 2019.
- [42] A. F. Hussein, S. J. Hashim, F. Z. Rokhani, and W. A. Wan Adnan, "An Automated High-Accuracy Detection Scheme for Myocardial Ischemia Based on Multi-Lead Long-Interval ECG and Choi-Williams Time-Frequency Analysis Incorporating a Multi-Class SVM Classifier," *Sensors*, vol. 21, no. 7, 2021.
- [43] I. OGREZEANU, D. STOIAN, A. TURCEA, and L. M. ITU, "Deep learning based myocardial ischemia detection in ECG signals," *2020 24th International Conference on System Theory, Control and Computing (ICSTCC)*, 2020.



**Carolina Fernández Biscay** was born in Argentina in 1989. She received the biomedical engineering degree in 2013 from Favaloro University, Buenos Aires, Argentina. Afterwards, she worked in the clinical engineering area of Hospital Alemán (Buenos Aires, Argentina). In 2016, she was awarded with a PhD scholarship by the National Council for Scientific and Technical Research (CONICET, Argentina). Since then, she is doing the PhD in engineering in Buenos Aires University (Argentina). Her research is done in Cardio-Signals Research Group at the Argentine Institute of Mathematics, "Alberto P. Calderon" and at the Biomedical Engineering Institute of the Engineering Faculty from the Buenos Aires University. Her current research interests include cardiac diseases (in particular ischemia), signal processing (especially on electrocardiogram records) and classification analysis.





**María Paula Bonomini** was born in San Jorge, Argentina, in 1977. In 2001, she received M.S. degree in bioengineering from the National University of Entre Ríos, Argentina. In 2010, she obtained the PhD degree in Bioengineering from the University Miguel Hernandez of Elche, Spain. Since then, she worked in cardiac electrophysiology and ECG signal processing.

Since 2013, she has been a Research Scientist of the National Council for Scientific and Technical Research (CONICET) and develops her work in the Cardio-Signals Research Group at the Argentine Institute of Mathematics "Alberto P. Calderon". Since 2013, she has been auxiliary professor of Signals and Images in Biomedicine at the Biomedical Engineering Institute of the Engineering Faculty from the Buenos Aires University (UBA). She published more than 15 scientific articles in international journals and her research interests involve biomedical signal processing.



**Miguel Eduardo Zitto** was born in 1961 in Buenos Aires, Argentina. In 1997 he obtained a Bachelor's degree in physical sciences and in 2004 a master's degree in Numerical Simulation and Control. Both degrees were obtained in Universidad de Buenos Aires, Argentina. Since 2006 he has been working in Universidad de Buenos Aires, where he is currently Co-director of the research group Analysis of Non-stationary and Non-linear Time Series. He published more than 10 scientific articles in international journals, and his current topics of interest are the

analysis of non-stationary and non-linear time series applied to climatological series of acoustic emission.



**Rosa Piotrkowski** was born in Lodz, Poland, in 1946 and arrived in Argentina in 1949. In 1971 she obtained a Bachelor's degree in Physical Sciences and in 1990 a PhD in Physical Sciences. Both degrees were obtained in Buenos Aires University, Argentina. She worked between 1978 and 1995 at the National Atomic Energy Commission in experimental studies and codes and models of diffusion in solid materials. Since 1995 she has been teaching and researching in the Departments of Mathematics and Electronics of San Martín National University,

in the Faculty of Engineering of Buenos Aires University and in the National Technological University. She was a researcher in the Department of Applied Physics of the University of Granada, Spain. She is currently a member of the Institute of Emerging Technologies and Applied Sciences UNSAM-CONICET and is a consulting associate professor at the Faculty of Engineering of Buenos Aires University, where she dictates a postgraduate course on the analysis of non-stationary and non-linear time series and is the director of a research group. She directs Research Projects and master's and doctoral theses. She published more than 40 articles and book chapters in international journals indexed in the SCOPUS database and her current topics of interest involve modeling and analysis of time series of non-stationary and non-linear stochastic processes.



**Pedro David Arini** was born in Buenos Aires, Argentina in 1964. In 1995, he obtained the M.S. degree in electronic engineering from the National Technological University, Argentina. Also, he received the M.Sc. degree in biomedical engineering from the Favaloro University of Buenos Aires Argentina in 2001. He subsequently carried out doctoral studies on electrical cardiac signals processing with the aim to evaluate cardiac risk based on biological and mathematical models. He received the PhD degree in biomedical engineering from the

Zaragoza University, Spain, in 2007. He worked in several areas, such as video systems, control engineering, acquisition and register of biological signals, speech signal processing, neuroscience, cardiac electrophysiology and digital processing of biomedical signals.

Since 2008, he has been an Independent Research Scientist of the National Council for Scientific Research and Technical, CONICET, and develops his research work in the Cardio-Signals Research Group at the Argentine Institute of Mathematics "Alberto P. Calderon". Since 2010, he has been an associate professor of Signals and Images in Biomedicine at the Biomedical Engineering Institute of the Engineering Faculty from the Buenos Aires University, UBA. He published more than 45 scientific articles in international journals and his current research interests include biomedical signal processing, with main interest in signals of cardiovascular origin.

#### ACRONYMS

ECG	Electrocardiograma
EDB	European ST-T Database
EMD	Descomposición Empírica de Modos, del inglés Empirical Mode Decomposition
IMF	Función Intrínseca de Modo, del inglés Intrinsic Mode Function
Se	sensibilidad
PPV	valor predictivo positivo, del inglés positive predictive value