

Transformada wavelet estacionaria y redes neuronales para la detección de pulso en episodios de parada cardiorrespiratoria

Erik Alonso González¹, Unai Irusta Zarandona², Elisabete Aramendi Ecenarro², Mohamud R. Daya³

¹ Departamento de Matemática Aplicada, Universidad del País Vasco (UPV/EHU), Bilbao, España, erik.alonso@ehu.eus

² Departamento de Ingeniería de Comunicaciones, Universidad del País Vasco (UPV/EHU), Bilbao, España, unai.irusta@ehu.eus, elisabete.aramendi@ehu.eus

³ Departamento de Emergencias, Oregon Health & Science University (OHSU), Portland, OR, EEUU, dayam@ohsu.edu

Resumen

La disponibilidad de un detector automático de pulso durante un episodio de parada cardiorrespiratoria extrahospitalaria (PCREH) permitiría una rápida identificación de la parada cardíaca y una temprana detección del retorno de la circulación espontánea. El objetivo de este estudio fue desarrollar un algoritmo de detección de pulso basado en el electrocardiograma (ECG) y la impedancia torácica (IT), las señales que registra la mayoría de los desfibriladores comerciales. La base de datos de estudio se compuso de 456 segmentos de 5 s que contenían las señales ECG e IT. Un total de 281 segmentos correspondieron a ritmos con pulso (RP) mientras que 175 correspondieron a actividad eléctrica sin pulso (AESP). Primero, la componente circulatoria de la impedancia (CCI) fue extraída de la señal de IT a través de la transformada wavelet estacionaria. Después, se extrajeron características para la discriminación RP/AESP del ECG preprocesado (0.5–30 Hz), de la CCI y de su primera derivada. Estas características fueron introducidas en una red neuronal que clasificó el segmento como RP/AESP. Un procedimiento basado en validación cruzada de 5-subconjuntos quasi-estratificada en términos de paciente fue usada para la selección del mejor conjunto de características y para optimizar y testear la red neuronal. Este procedimiento se repitió 50 veces para estimar la distribución estadística de las métricas de rendimiento del método. La solución óptima consistió en una red neuronal basada en 3 características y con 20 neuronas en su capa oculta que obtuvo una media (desviación estándar) en términos de sensibilidad, especificidad, precisión balanceada y precisión de 90.2% (1.9), 90.9% (1.2), 90.6% (0.9) y 90.5% (1.1), respectivamente. Se ha desarrollado un detector de pulso para uso en PCREH que hace uso de las señales disponibles en los desfibriladores.

1. Introducción

La parada cardiorrespiratoria extra-hospitalaria (PCREH) es una de las principales causas de muerte en los países industrializados ya que de media es responsable de entre 83.7-95.9 muertes al año por cada 100000 habitantes [1]. Un reconocimiento precoz de la parada cardiorrespiratoria es crucial para la supervivencia del paciente ya que posibilita, por un lado, un rápido inicio del masaje de resucitación cardiopulmonar (RCP) y por otro, una desfibrilación temprana la cual se ha comprobado que mejora la probabilidad de supervivencia [2,3]. Las actuales guías de resucitación recomiendan evaluar la ausencia de ‘respiración normal’ como indicador de falta de circulación, y por tanto, parada cardiorrespiratoria [4]. Desafortunadamente, se ha comprobado que este procedimiento no es fiable [5] e introduce interrupciones

en el masaje RCP que son perjudiciales para la supervivencia del paciente [6]. Por tanto, la implementación en los actuales desfibriladores de un detector fiable de detección de pulso contribuiría a una pronta y rápida identificación de la parada cardiorrespiratoria, y minimizaría las interrupciones en el masaje RCP para confirmar la ausencia de circulación. Además, también permitiría la rápida detección del retorno de la circulación espontánea (RCE) lo que a su vez conduciría a la inmediata iniciación de los cuidados pos-resucitación.

En esencia, la detección de pulso en la parada cardiorrespiratoria consiste en discriminar entre dos tipos de ritmos organizados: actividad eléctrica sin pulso (AESP) y ritmo generador de pulso (RP). Ambos ritmos presentan un ECG con complejos QRS y aparentemente normal. Sin embargo, mientras que los ritmos RP muestran una actividad eléctrica y mecánica normal, durante la AESP se produce una disociación electromecánica de manera que el corazón pierde su función contráctil y por lo tanto, no existe un flujo sanguíneo efectivo. La diferencia entre los ritmos RP y AESP no es siempre perceptible en el ECG. Sin embargo, la mayoría de los desfibriladores comerciales registran además del ECG, la señal de impedancia torácica (IT) a través de los parches de desfibrilación. Ésta última puede ayudar en la discriminación de estos dos ritmos ya que refleja una componente circulatoria de la impedancia (CCI) que consiste en pequeñas fluctuaciones ($<100 \text{ m}\Omega$) correlacionadas con los complejos QRS en los ritmos RP, pero no en la AESP. La CCI está oculta entre otras componentes de señal de IT.

El objetivo de este estudio fue proponer un método de detección de pulso. Para ello primero se desarrolló un método para aislar la CCI de la señal IT y después se entrenó un clasificador basado en aprendizaje automático que hiciese uso de características extraídas de la CCI y del ECG para discriminar entre RP y AESP.

2. Materiales y métodos

2.1. Base de datos de estudio

Los datos usados en este estudio fueron extraídos de 49 pacientes de PCREH tratados por la agencia Tualatin Valley Fire & Rescue (Tigard, OR, EEUU) haciendo uso del monitor/desfibrilador Philips HeartStart MRx (Philips

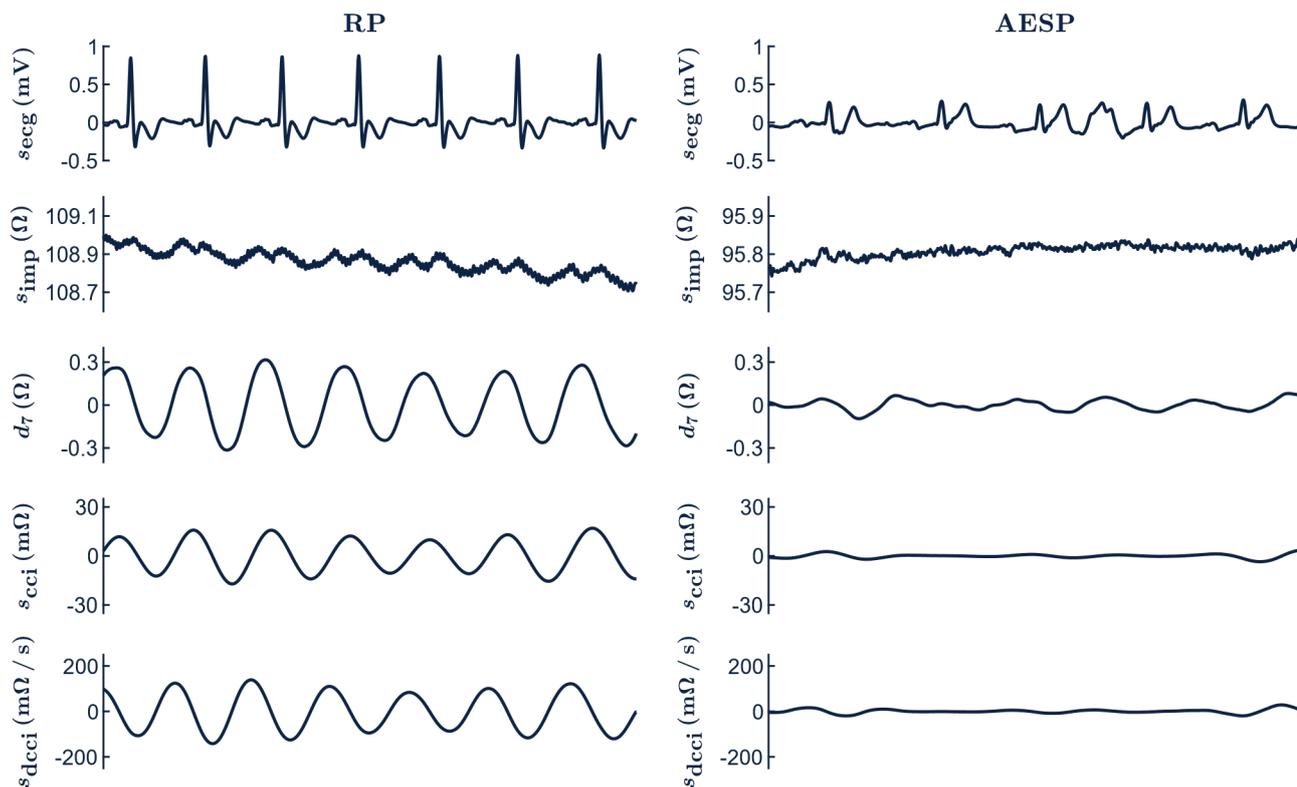


Figura 1. Ejemplos de segmentos RP (izq.) y AESP (dcha.) de la base de datos de estudio en los que se ha llevado a cabo el análisis wavelet de la señal de IT. De arriba abajo, se muestran las señales ECG (s_{ecg}), la señal IT original (s_{imp}), una sub-banda relevante de la IT (d_7) para la estimación de la CCI, la CCI estimada (s_{cci}) y su primera derivada (s_{dcci}).

HealthCare, MA, EEUU) en el año 2012. Cada episodio constó de las señales ECG, IT y capnografía muestreadas a 200 Hz. Los episodios fueron inspeccionados visualmente en busca de segmentos de 5 s que presentasen complejos QRS y ninguna interferencia debida a las compresiones torácicas o ventilaciones. Estos segmentos fueron anotados como RP o AESP por tres expertos en base a anotaciones RCE realizadas durante la actuación y a incrementos/decrementos abruptos en el capnograma que fueron indicadores de RCE y pérdida de RCE, respectivamente. La base de datos usada en este estudio se compuso de un total de 456 segmentos de los cuales 175 correspondieron a AESP y 281 a RP. Los paneles superiores de la Figura 1 muestran las señales ECG e IT para RP (izquierda) y AESP (derecha).

2.2. Extracción de la CCI

La CCI fue extraída de la señal IT, $s_{imp}(n)$, a través de la transformada wavelet estacionaria (TWE) que consiste en la aplicación de un par de filtros paso-bajo, $h_{j-1}(n)$, y paso-alto, $g_{j-1}(n)$, para producir, en el siguiente nivel de descomposición, los coeficientes de aproximación, $a_j(n)$, y detalle, $d_j(n)$:

$$a_j(n) = h_{j-1}(n) * a_{j-1}(n) \quad (1)$$

$$d_j(n) = g_{j-1}(n) * a_{j-1}(n) \quad (2)$$

donde * denota la convolución, y $a_0(n) = s_{imp}(n)$. En la etapa j los filtros son los mismos que en la etapa 0 pero incrementando su longitud a través de la inserción de $2^j - 1$ ceros entre muestras.

Se hizo uso de una wavelet madre Biorthogonal 4.4 para descomponer $s_{imp}(n)$ en $J - 7$ niveles de descomposición que produjeron los coeficientes de detalle $d_1 - d_7$ y el coeficiente de aproximación a_7 . El ruido de los coeficientes de detalle $d_6 - d_7$ fue reducido haciendo uso de una función umbral suave. Para sintetizar la CCI, $s_{cci}(n)$, se usaron los coeficientes de detalle d_6 y d_7 (banda 0.78-3.13 Hz) o solo d_7 (banda 0.78-1.56 Hz) para segmentos con frecuencia cardiaca superior e inferior a 93 latidos/min, respectivamente. El resto de coeficientes detalle y aproximación se igualaron a cero. La síntesis de $s_{cci}(n)$ se llevó a cabo mediante la evaluación recursiva de la siguiente expresión:

$$a_{j-1}(n) = \frac{1}{2}(g'_j(n) * a_j(n) + h'_j(n) * d_j(n)) \quad (3)$$

para $j = J, \dots, 1$, donde $g'_j(n)$ y $h'_j(n)$ son los denominados filtros de síntesis y el coeficiente sintetizado $a_0(n)$ se corresponde con $s_{cci}(n)$. La frecuencia cardiaca usada para la comparación con el umbral de 93 latidos/min en la síntesis de $s_{cci}(n)$ fue calculada como la inversa de la duración media de los intervalos entre complejos QRS detectados a través de una versión modificada del detector QRS propuesto por Hamilton-Tompkins [7]. Los paneles inferiores de la Figura 1 muestran las señales más relevantes obtenidas a través del análisis wavelet de $s_{imp}(n)$.

2.3. Extracción de características

Un total de 18 características fueron calculadas de $s_{ecg}(n)$, la señal ECG filtrada paso-banda (0.5-30 Hz), de $s_{cci}(n)$ y

de su primera derivada $s_{dcci}(n)$. Las primeras 7 características fueron la amplitud pico-valle media, la desviación estándar de la amplitud pico-valle y el área media de $s_{cci}(n)$ y $s_{dcci}(n)$ [8], además de la fuzzy entropy (FuzzyEn) [9] de $s_{cci}(n)$. Las siguientes 10 características fueron extraídas de $s_{ecg}(n)$ y fueron el número de complejos QRS, la media y la desviación estándar del intervalo entre ondas R, la media y la desviación estándar de la amplitud de los complejos QRS [10], la mediana de la anchura de los complejos QRS [11], amplitud spectrum area (AMSA) [12], la energía en las bandas altas de frecuencia [13], FuzzyEn y signal length [11]. Finalmente, se calculó la potencia cruzada media entre $s_{ecg}(n)$ y $s_{cci}(n)$ [14]. Los detalles de estas características pueden encontrarse en las referencias detalladas arriba y su implementación Matlab en <https://github.com/erik-alonso/PEA-PR-features>.

2.4. Clasificación

El algoritmo de clasificación usado se basó en una red neuronal feed-forward. En la capa de entrada la red contó con K nodos, uno por cada característica usada para caracterizar los segmentos. La capa oculta estuvo compuesta por un número N de neuronas y la capa de salida por una única neurona. La función sigmoide fue la seleccionada como función de activación entre capas. Así, la neurona de la capa de salida proporcionó la probabilidad de que un determinado segmento correspondiera a un ritmo RP dado el vector de K características de dicho segmento. Los segmentos con probabilidades mayores a 0.5 fueron clasificados como RP, mientras que aquellos con probabilidad igual o inferior a 0.5 fueron clasificados como AESP.

2.5. Arquitectura del modelo y evaluación

La validación cruzada de 5 subconjuntos fue la elegida para entrenar el modelo y evaluar su rendimiento. Los subconjuntos fueron creados como particiones aleatorias quasi-estratificadas respecto a pacientes. Cada subconjunto mantuvo al menos el 90% de las proporciones RP/AESP de la base de datos original.

En cada una de las cinco iteraciones de la validación cruzada, 4 subconjuntos fueron dedicados primero a la selección de las K -características más discriminativas y después, a la optimización de la red neuronal basada en esas K -características seleccionadas. El último de los subconjuntos fue usado para evaluar el rendimiento del modelo en términos de sensibilidad (SE, capacidad para detectar correctamente RP), especificidad (ESP, capacidad para detectar correctamente AESP), precisión (P, proporción de ritmos correctamente clasificados) y precisión balanceada (PB, media de SE y ESP). Estas métricas de precisión se calcularon comparando las decisiones RP/AESP tomadas por el modelo con las anotaciones realizadas por los revisores expertos.

La selección de características se llevó a cabo mediante el algoritmo de selección incremental secuencial (SIS) y un clasificador basado en regresión logística multivariable (RLM) para evaluar el rendimiento del conjunto de características a la hora de discriminar entre RP y AESP.

Tres subconjuntos fueron usados para entrenar el clasificador RLM y una para evaluar su rendimiento en términos de PB. El algoritmo SIS se ejecutó hasta que se seleccionó el mejor conjunto de K -características, usando la maximización de la PB como criterio para la inclusión de una nueva característica en el modelo.

La optimización de la red neuronal consistió por un lado en la actualización de los pesos y valores intercepto a través del algoritmo de propagación hacia atrás (*backpropagation*), y por otro, en encontrar el número óptimo de neuronas en la capa oculta que maximizase la PB de la red.

El procedimiento de validación cruzada de 5 subconjuntos se repitió 50 veces haciendo uso de diferentes particiones aleatorias para estimar la distribución estadística de las métricas de rendimiento. Todos los resultados se proporcionarán como media (desviación estándar, DE) de los valores obtenidos en las 50 repeticiones de los experimentos.

3. Resultados y discusión

La Figura 2 muestra la PB del algoritmo de detección de pulso en función del número de características incluidas en el modelo. Este análisis se llevó a cabo para una red neuronal con 10 neuronas en su capa oculta. La inclusión de nuevas características supuso una gran mejora en la PB hasta conseguir su máximo (90.5%) cuando tres características fueron incluidas en el modelo. Para modelos basados en cuatro o más características la PB se mantuvo alrededor del 90%

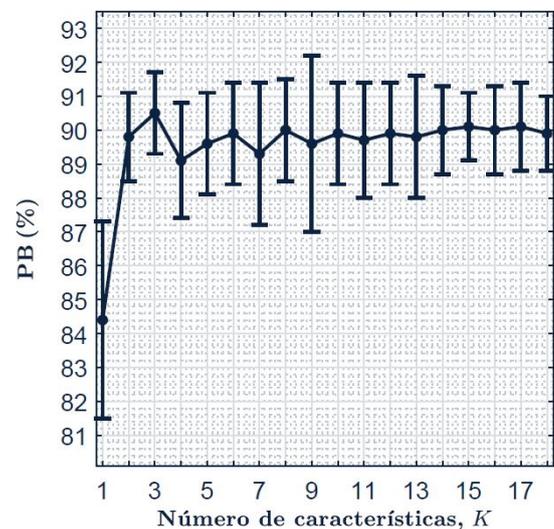


Figura 2. Media (DE) de la PB del algoritmo de detección de pulso en las 50 réplicas del procedimiento de validación cruzada en función del número de características, K , incluidas en el modelo.

La Figura 3 muestra la PB obtenida por el algoritmo de detección de pulso en función del número de neuronas, N , en capa oculta de la red neuronal. En este caso, el análisis se realizó para un algoritmo de detección de pulso basado en tres características. La máxima PB mostrada por el algoritmo de detección de pulso fue 90.6% (0.9) y fue alcanzada cuando la red neuronal contó con 20 neuronas en

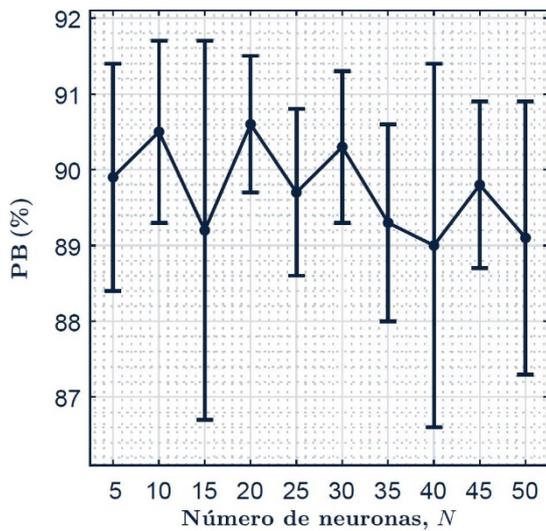


Figura 3. Media (DE) de la PB del algoritmo de detección de pulso en las 50 réplicas del procedimiento de validación cruzada en función del número de neuronas, N , en la capa oculta de la red neuronal.

su capa oculta. a partir de 30 se observa una tendencia descendente en la PB. Por lo tanto, el algoritmo de detección de pulso que mejor rendimiento en términos de PB mostró en las 50 réplicas del proceso de validación cruzada fue aquel basado en una red neuronal alimentada por tres características y con 20 neuronas en su capa oculta que presentó valores medios de SE, ESP, PB y P de 90.2% (1.9), 90.9% (1.2), 90.6% (0.9) y 90.5% (1.1), respectivamente.

4. Conclusiones

Este estudio ha propuesto un novedoso algoritmo de detección de pulso basado en las señales ECG e IT adquiridas por los desfibriladores comerciales. De esta manera, la incorporación del algoritmo en los desfibriladores únicamente requeriría de modificaciones software, sin necesidad de realizar cambios en su hardware. El algoritmo se basa en la TWE para extraer la CCI de la IT de manera que maximiza la capacidad de ésta para discriminar entre ritmos AESP y RP. Se extrajeron un total de 18 características de las señales ECG, CCI y su primera derivada, y se introdujeron en una red neuronal que se encargó de decidir si esas características correspondían a un ritmo AESP o RP. La versión optimizada de este modelo presenta resultados satisfactorios. Sin embargo, una base de datos más amplia permitiría corroborar estas conclusiones.

Agradecimientos

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia, Innovación y Universidades a través del proyecto RTI2018-101475-BI00, conjuntamente con el Fondo Europeo de Desarrollo Regional (FEDER), y en parte por el Gobierno Vasco por medio del proyecto IT-1229-19.

Referencias

[1] Berdowski J, Berg RA, Tijssen JGP, et al. Global incidences of out-of-hospital cardiac arrest and survival rates:

Systematic review of 67 prospective studies. *Resuscitation*, vol. 81(11), 2010, pp. 1479–1487.

- [2] Wissenberg M, Lippert FK, Folke F, et al. Association of National Initiatives to Improve Cardiac Arrest Management With Rates of Bystander Intervention and Patient Survival After Out-of-Hospital Cardiac Arrest. *JAMA*, vol. 310(13), 2013, pp.1377–1384.
- [3] Blom MT, Beesems SG, Homma PCM, et al. Improved survival after out-of-hospital cardiac arrest and use of automated external defibrillators. *Circulation*, vol.130(21), 2014, pp. 1868–1875.
- [4] Perkins GD, Handley AJ, Koster RW, et al, Adult basic life support and automated external defibrillation section Collaborators. European Resuscitation Council Guidelines for Resuscitation 2015: Section 2. Adult basic life support and automated external defibrillation. *Resuscitation*, vol. 95, 2015, pp. 81–99.
- [5] Ruppert M, Reith MW, Widmann JH, et al. Checking for breathing: evaluation of the diagnostic capability of emergency medical services personnel, physicians, medical students, and medical laypersons. *Annals of Emergency Medicine* vol. 34(6), 1999, pp. 720–729.
- [6] Vaillancourt C, Everson-Stewart S, Christenson J, et al, Resuscitation Outcomes Consortium Investigators. The impact of increased chest compression fraction on return of spontaneous circulation for out-of-hospital cardiac arrest patients not in ventricular fibrillation. *Resuscitation*, vol. 82(12), 2011, pp. 1501–1507.
- [7] Hamilton PS and Tompkins WJ, Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmia database. *IEEE Transactions on Biomedical Engineering*, vol. 33(12), 1986, pp. 1157–1165.
- [8] Ruiz J, Alonso E, Aramendi E, et al. Reliable extraction of the circulation component in the thoracic impedance measured by defibrillation pads. *Resuscitation*, vol. 84(10), 2013, pp. 1345–1352.
- [9] Chen W, Wang Z, Xie H, et al, Characterization of surface EMG signal based on fuzzy entropy, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 15(2), 2007, pp. 266-272.
- [10] Alonso E, Aramendi E, Daya M, et al, Circulation detection using the electrocardiogram and the thoracic impedance acquired by defibrillation pads. *Resuscitation*, vol. 99, 2016, pp. 56-62.
- [11] Risdal M, Aase SO, Kramer-Johansen J, et al. Automatic identification of return of spontaneous circulation during cardiopulmonary resuscitation, *IEEE Transactions on Biomedical Engineering*, vol. 55(1), 2008, pp. 60-68.
- [12] Ristagno G, Li Y, Fumagalli F, et al, Amplitude spectrum area to guide resuscitation-a retrospective analysis during out of-hospital cardiopulmonary resuscitation in 609 patients with ventricular fibrillation cardiac arrest, *Resuscitation*, vol. 84(12), 2013, pp. 1697-1703.
- [13] Elola A, Aramendi E, Irusta U, et al. ECG-based pulse detection during cardiac arrest using random forest classifier, *Medical & Biological Engineering & Computing*, vol. 57(2), 2019, pp. 453-462.
- [14] Ruiz JM, Ruiz de Gauna S, González-Otero DM, et al, Circulation assessment by automated external defibrillators during cardiopulmonary resuscitation, *Resuscitation*, vol. 128, 2018, pp. 158-163.