

Algoritmo multietapa para la detección de ventilaciones en la impedancia torácica durante la resucitación cardiopulmonar

X. Jaureguibeitia Lara¹, U. Irusta Zarandona¹, E. Aramendi Ecenarro¹, H.E. Wang², A.H. Idris³

¹ BioRes, Dpto. de Ingeniería de Comunicaciones, Universidad del País Vasco (UPV/EHU), Bilbao, España, {xabier.jaureguibeitia, unai.irusta, elisabete.aramendi}@ehu.eus

² University of Texas Health Science Center, Houston (TX, EEUU), Henry.E.Wang@uth.tmc.edu

³ University of Texas Southwestern Medical Center, Dallas (TX, EEUU), ahamed.idris@utsouthwestern.edu

Resumen

La resucitación cardiopulmonar (RCP) es clave en el tratamiento de la parada cardiorrespiratoria extra-hospitalaria (PCREH). La impedancia torácica (IT) adquirida a través de los parches de un desfibrilador permite detectar las ventilaciones para proveer al rescatador de realimentación sobre el manejo de la vía aérea, pero presenta artefactos debidos a las compresiones torácicas. El objetivo de este trabajo fue el desarrollo de un algoritmo para la detección de ventilaciones en la IT durante compresiones concurrentes. Se analizaron un total de 152 episodios de PCREH, y se anotaron 9665 ventilaciones de referencia en el capnograma. El método constó de tres etapas: procesado de señal para la extracción de la componente de ventilación de la IT, incluyendo un bloque de filtrado adaptativo para eliminar el artefacto de compresiones, detección y caracterización de formas de onda de ventilación, y clasificación mediante una máquina de vectores de soporte para discriminar falsos positivos. Los pacientes, uno por episodio, fueron divididos en grupos de entrenamiento (70%) y evaluación (30%). Se utilizaron 100 particiones diferentes a fin de reducir el sesgo. Las métricas de desempeño finales mostraron valores medianos por paciente de 87.6% de sensibilidad y 85.0% de valor predictivo positivo. El algoritmo podría utilizarse para proporcionar realimentación al rescatador en términos de tasa de ventilación y volúmenes de aire insuflado.

1. Motivación

La parada cardiorrespiratoria extra-hospitalaria (PCREH), con una tasa de incidencia en torno a 55 casos por 100.000 habitantes y año, y una ratio de supervivencia cercana al 10%, representa un problema de salud pública de primer orden [1]. Un evento de parada se origina, generalmente, debido a un mal funcionamiento del sistema eléctrico del corazón, y resulta en la pérdida repentina de la función circulatoria. Una resucitación cardiopulmonar (RCP) de calidad, consistente en compresiones torácicas (CTs) y ventilaciones a fin de inducir un flujo mínimo de sangre oxigenada al paciente, constituye un elemento clave en el tratamiento de la PCREH, retrasando la aparición de daño celular, y ganando así tiempo para la aplicación de otras terapias [2]. Las guías de resucitación aconsejan una tasa de CTs de 100-120 min⁻¹ [2]. Si las CTs se administran de forma ininterrumpida, es decir, sin pausas para ventilaciones, éstas últimas deben suministrarse con una tasa en torno a 10 min⁻¹, procurando no hiperventilar al paciente [3]. El cumplimiento de estas recomendaciones mejora cuando el rescatador recibe realimentación en tiempo real sobre la

RCP practicada [4]. En este sentido, se han implementado diversas soluciones para mejorar la calidad de la terapia, incluyendo acelerómetros integrados para monitorizar la tasa y la profundidad de compresión, e incluso dispositivos mecánicos capaces de administrar CTs de forma autónoma y muy regular. Las soluciones para la monitorización de las ventilaciones son más limitadas, recomendándose el uso de la capnografía [3], que mide la presión parcial de CO₂ en los gases espirados. La capnografía, sin embargo, requiere de un manejo avanzado de la vía aérea, así como de equipo de monitorización especializado, y no aporta información sobre el volumen de aire insuflado.

La impedancia torácica (IT), medida como la resistencia del cuerpo al paso de corriente, representa una alternativa para la monitorización de ventilaciones, pues es sensible a cambios de volumen de aire en los pulmones. La mayoría de equipos de resucitación básicos registran la señal de IT a través de los parches de desfibrilación, por lo que ésta tiende a estar disponible una media de 13 min antes que la capnografía durante un evento de PCREH [5]. La amplitud de las fluctuaciones de IT debidas a las ventilaciones puede emplearse además como medida subrogada del volumen de aire insuflado, que a su vez puede ser relacionado con la efectividad de la terapia y las opciones de supervivencia del paciente [6]. En el lado negativo, la señal es sensible a diversas fuentes de ruido, tales como el movimiento de los electrodos o del paciente. Las CTs aplicadas como parte de la RCP producen, además, un artefacto que enmascara las ventilaciones y debe eliminarse. Las soluciones presentes en el estado del arte para este escenario hacen uso frecuente de filtros adaptativos originalmente concebidos para la eliminación del artefacto de CTs en el ECG [7].

Este trabajo parte de una solución anterior, diseñada para la detección de ventilaciones durante CTs aplicadas por un dispositivo mecánico [8], y trata de adaptarla al caso más general de compresiones manuales administradas por un rescatador. En este escenario, el artefacto debido a las CTs es más variable, y la prevalencia de ruido de movimiento es también mayor.

2. Materiales

Se analizaron los ficheros electrónicos de 152 episodios de PCREH, tratados por los servicios médicos de emergencia de Dallas - Fort Worth (TX, EEUU) entre febrero de 2016 y marzo de 2017, y adscritos al estudio clínico aleatorizado

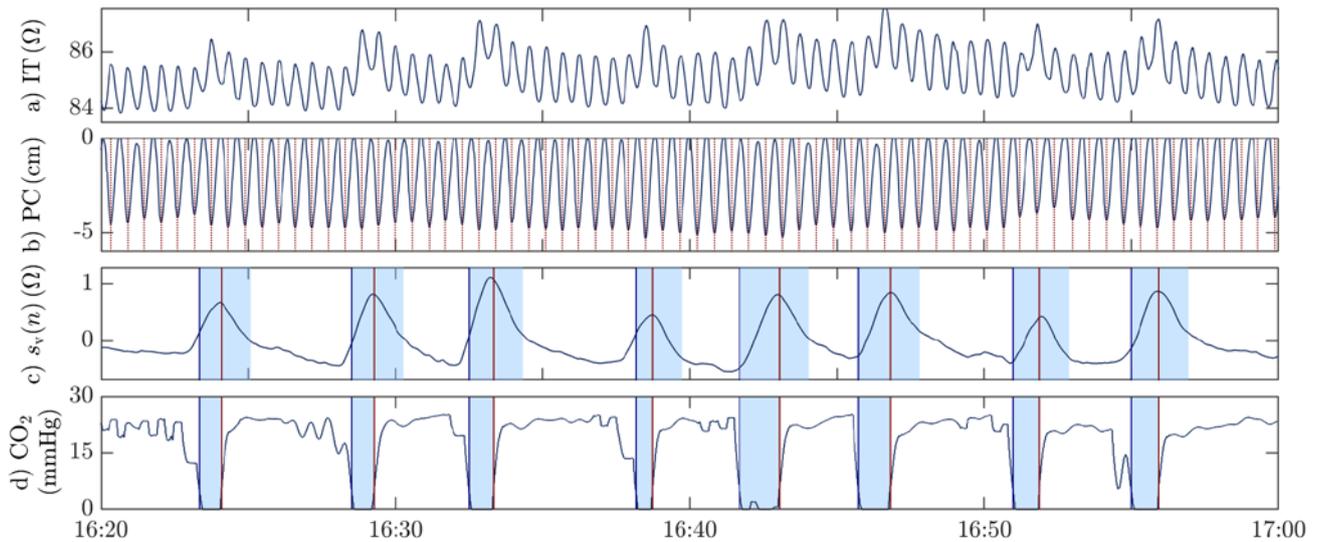


Figura 1. Ejemplo de las señales implicadas en el proceso de anotación: (a) señal de IT original. (b) señal de PC, incluyendo los instantes de CT anotados. (c) componente de ventilaciones de la IT, obtenida tras filtrado adaptativo en la primera etapa del algoritmo. (d) señal de capnografía sincronizada con la IT, incluyendo las anotaciones de ventilaciones de referencia.

Pragmatic Airway Resuscitation Trial [9]. Todos los casos fueron tratados con un monitor-desfibrilador Philips MRx (Philips Medical Systems, Andover, MA), que registra la señal de IT con una frecuencia de muestreo de 200Hz y una resolución de 0.74mΩ. Los ficheros fueron exportados y convertidos a un formato adecuado para su análisis usando MATLAB (MathWorks Inc., Natick, MA), y se exploraron en busca de segmentos de IT apropiados para el desarrollo del algoritmo. Se seleccionaron segmentos de al menos 60s durante CTs, con información concurrente de capnografía y profundidad de compresión (PC). Se excluyeron pausas de CTs mayores a 20s, así como intervalos de IT mostrando excursiones abruptas u otros artefactos significativos. Los instantes de CT se anotaron de forma automática en la PC para compresiones superiores a 1.5cm. Las ventilaciones se anotaron de forma manual en el capnograma a modo de referencia. Se corrigió el retardo entre las señales de IT y capnografía debido al transporte de gas en la vía aérea. La Figura 1 muestra un ejemplo de las señales implicadas en el proceso de anotación. La base de datos final constó de 423 segmentos, para un total de 1210 min de grabaciones de IT y 9665 ventilaciones de referencia, el 97.7% de ellas durante CTs concurrentes.

3. Métodos

El algoritmo de detección propuesto constó de tres etapas. En primer lugar, la señal de IT fue filtrada a fin de eliminar el artefacto de compresiones y de extraer la componente de ventilación. A continuación, se detectaron y delimitaron las fluctuaciones individuales asociadas a ventilaciones. Esta etapa fue diseñada tratando de maximizar la detección de ventilaciones reales, por lo que produjo también un elevado número de falsos positivos. Cada una de las detecciones se representó en términos de un vector \mathbf{x}_i de 16 características representativas. La etapa final consistió en un clasificador basado en aprendizaje máquina para la discriminación de los falsos positivos.

3.1. Extracción de la componente de ventilación

Como primer paso, la señal de IT se remuestreó a 50Hz, lo que redujo la carga computacional del algoritmo y facilitó el diseño de los filtros: un primer filtro paso-alto con una frecuencia de corte de 0.06Hz para eliminar la componente continua, seguido de un filtro de media móvil ($L=50$) para suprimir el ruido de alta frecuencia y atenuar el artefacto de compresiones. La supresión final del artefacto se llevó a cabo mediante un esquema de filtrado adaptativo LMS (*Least Mean Squares*), con los instantes de CT previamente anotados empleados a modo de referencia [10].

Sea $s[n]$ la entrada a la etapa de filtrado adaptativo, ésta se consideró formada por dos términos incorrelados, $s_v[n]$ y $s_c[n]$, debidos respectivamente a ventilaciones y CTs, de modo que $s[n] \approx s_v[n] + s_c[n]$. La componente de CTs se modeló a su vez como una serie de Fourier truncada de la forma

$$\hat{s}_c[n] = A[n] \sum_{k=1}^N [a_k[n] \cos(k\phi[n]) + b_k[n] \sin(k\phi[n])]$$

donde N representa el número de armónicos considerado. La fase instantánea $\phi[n]$ se derivó de los instantes de CT, considerando una variación lineal de fase de 2π entre cada par de compresiones contiguas. $A[n]$, a su vez, se definió tal que diferenciase intervalos con ($A=1$) y sin ($A=0$) CTs, de acuerdo a una duración mínima de pausa de 1.5s. Los coeficientes de amplitud de los términos en fase y cuadratura, $a_k[n]$ y $b_k[n]$, se estimaron haciendo uso de la configuración LMS para la supresión de interferencia armónica [11]. La señal de error $e[n] = s[n] - \hat{s}_c[n]$ a la salida del filtro se aproxima en este caso a la componente de ventilación $s_v[n]$. Tras unos experimentos preliminares, se estableció un tamaño de paso $\mu=0.05$ para el algoritmo LMS, así como un número de armónicos $N=3$.

3.2. Detección y caracterización de formas de onda

Las formas de onda potencialmente debidas a ventilaciones se identificaron empleando un algoritmo de detección de picos con una separación mínima de 1.5s. Para cada pico $t_{p,i}$ detectado, se aplicaron a continuación un conjunto de reglas heurísticas a fin de localizar los instantes de inicio $t_{s,i} \in [t_{p,i} - 5.5, t_{p,i} - 0.45]$ y final $t_{e,i} \in [t_{p,i} + 0.45, t_{p,i} + 5.5]$ de la forma de onda. Se descartó cualquier detección para la que $t_{s,i}$ o $t_{e,i}$ no pudieran ser determinados.

Cada fluctuación detectada se representó en términos de un total de 16 características extraídas de su morfología y de las inmediaciones de señal. Las 4 primeras consistieron en las amplitudes, Z_u y Z_d , y duraciones, T_u y T_d , de las fases de insuflación y exhalación, que se corresponden a su vez con las secciones ascendente y descendente de la forma de onda. Para cada fase se realizó también una aproximación de mínimos cuadrados en base a polinomios de Legendre de hasta orden 4, resultando en 10 nuevas características. Finalmente, las dos últimas características vinieron dadas por las excursiones de señal $\Delta_{90} = P_{95} - P_5$ y $\Delta_{95} = P_{97.5} - P_{2.5}$, donde P_x representa el percentil x de la señal $s_p[n]$ en una ventana de hasta un minuto centrada en la posición de pico.

3.3. Clasificación

Cada una de las ventilaciones potenciales identificadas en la etapa anterior se etiquetó como ventilación real ($y_i = 1$) o ausencia de ventilación ($y_i = 0$) en base a las anotaciones de referencia tomadas en el capnograma. Las detecciones cuyo instante de pico $t_{p,i}$ se ubicó dentro de un intervalo de referencia (áreas sombreadas en Figura 1.c) se etiquetaron como $y_i = 1$. En caso de que varias detecciones cumplieran la condición para un mismo intervalo, sólo aquella con $t_{p,i}$ más próximo al comienzo de espiración (líneas verticales en Figura 1.c) fue etiquetada como ventilación real. De este modo, la entrada a la etapa constituyó un conjunto de pares $\{x_i, y_i\} \in \mathbb{R}^{16 \times (0,1)}$.

Se consideró que algunas de las formas de onda detectadas podrían estar afectadas por transitorios debidos a las pausas de compresiones, artefactos de ruido o similares, y de este modo deteriorar el funcionamiento del clasificador. En este sentido, se optó por eliminar de los datos de entrenamiento un 5 % de las muestras para ambas clases. La detección de valores extremos se llevó a cabo empleando la distancia de Mahalanobis.

Se escogió como algoritmo de clasificación una máquina de vectores de soporte (*support vector machine*, SVM) [12] con *kernel* gaussiano, para la que se optimizaron los hiperparámetros C y γ , que controlan la frontera de decisión del algoritmo.

3.4. Evaluación del modelo

El conjunto final de ventilaciones potenciales se dividió en grupos de entrenamiento, para el aprendizaje de la etapa de clasificación, y evaluación. Esta división se realizó en base a paciente, de modo que todas las muestras asociadas a un mismo caso, con probables similitudes morfológicas entre sí, se asignasen a un mismo grupo. El 70% de los pacientes fue asignado al grupo de entrenamiento y el 30% restante a evaluación. Se exigió una proporcionalidad similar en el

número de ventilaciones de referencia asignadas a cada uno de los grupos. Se generaron 100 particiones diferentes de entrenamiento/evaluación para minimizar cualquier sesgo debido a un reparto concreto de los datos.

Se determinaron sobre el grupo de evaluación el número de verdaderos (VP) y falsos positivos (FP), así como de falsos negativos (FN). Se contabilizó también como FN cualquier ventilación perdida en la etapa de detección de formas de onda. Se computaron, para cada paciente, los valores de sensibilidad (Se), valor predictivo positivo (VPP) y F_1 :

$$Se = \frac{VP}{VP + FN} \quad VPP = \frac{VP}{VP + FP} \quad F_1 = 2 \frac{Se \cdot VPP}{Se + VPP}$$

Estas métricas de rendimiento se promediaron entre todas las particiones en las que el paciente objetivo formaba parte del grupo de evaluación. El análisis final se realizó entre pacientes, en términos de mediana (cuartil 1 – cuartil 3).

4. Resultados

La detección preliminar de formas de onda sobreestimó las ventilaciones, con Se de 94.1 (89.0 - 98.4) % y VPP de 56.0 (44.9 - 66.7) %. La etapa de clasificación logró corregir la mayoría de falsos positivos, resultando en unas métricas de desempeño finales de 87.6 (75.2 - 93.0) % para Se, 85.0 (71.5 - 92.5) % para VPP, y 83.7 (73.6 - 92.2) % para F_1 . La Figura 2 muestra una distribución más detallada de las métricas de desempeño para los distintos pacientes.

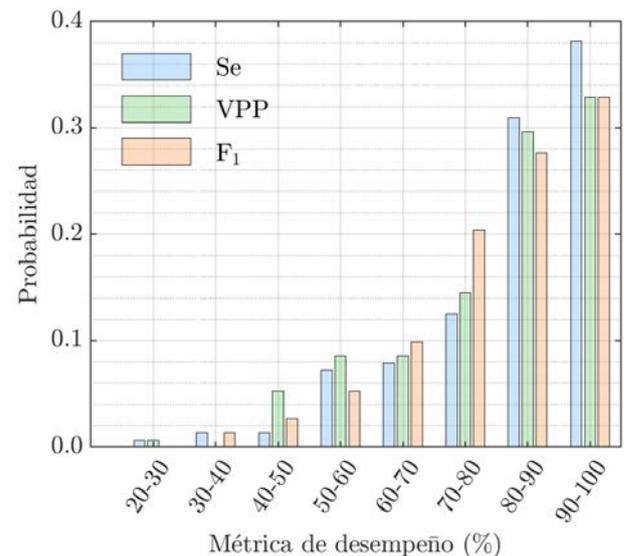


Figura 2. Distribuciones de métricas de desempeño por paciente, normalizadas como probabilidad.

5. Discusión

Este trabajo describe y evalúa un método automático para la detección de ventilaciones en IT durante compresiones concurrentes de carácter manual.

El algoritmo propuesto, adaptado de una solución previa para uso durante RCP mecánica [8], mostró un desempeño manifiestamente inferior al del trabajo original, en parte debido a una mayor irregularidad en frecuencia y amplitud de las CTs, pero, fundamentalmente, a la aparición de una

componente de ruido de baja frecuencia, que distorsiona y enmascara las ventilaciones, y que se estima originada por el movimiento del paciente y/o los electrodos durante la RCP. La Figura 3 muestra un ejemplo de dicho fenómeno. Aún así, el método se mostró efectivo en una mayoría de casos, con métricas de desempeño superiores al 85%. Estas prestaciones podrían mejorarse en un futuro mediante el diseño de nuevos predictores o el uso de técnicas más avanzadas de filtrado y/o clasificación.

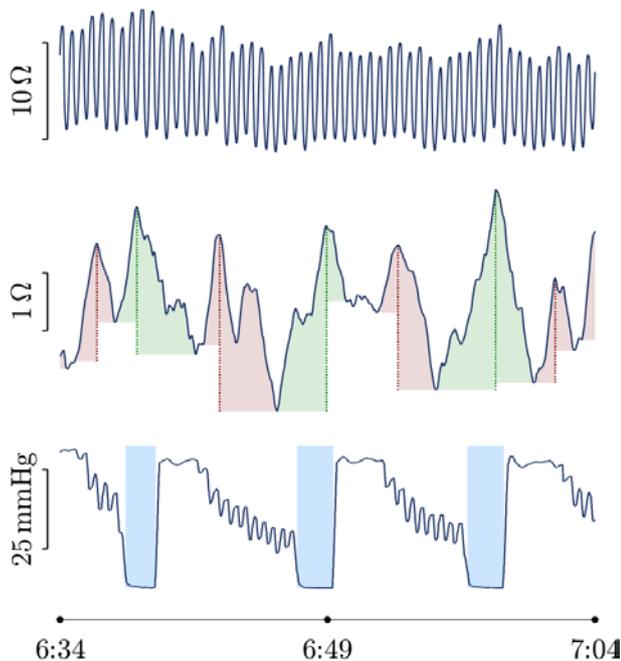


Figura 3. Ejemplo de segmento de IT afectado por ruido de baja frecuencia.

El algoritmo expuesto mejoró el rendimiento de soluciones más simples, como la propuesta por Alonso et al [13], para la que se obtuvo una Se mediana de 88.8%, pero un VPP muy inferior, de 63.4%. Esta reducción de rendimiento con respecto de los resultados publicados se atribuye a la fuerte presencia de ruido de movimiento, una característica muy dependiente de la base de datos de estudio. Cabe resaltar también que no se llevó a cabo ningún tipo de optimización de parámetros. Otras soluciones más complejas, como la propuesta por Risdal et al [7], no pudieron ser evaluadas por requerir para su entrenamiento de anotaciones tomadas directamente sobre la IT. La existencia en nuestra base de estudio de episodios fuertemente artefactados, para los que dicha anotación no resulta viable, sugiere, no obstante, un rendimiento inferior al reportado (con métricas superiores al 90%), más en línea con el mostrado por nuestra solución.

6. Conclusiones

Con unas métricas de rendimiento medianas alrededor del 85%, el algoritmo de detección expuesto podría emplearse para proveer de realimentación útil acerca de la terapia de ventilación en una mayoría de casos. Se estima necesario de cara al futuro el desarrollo de predictores que permitan identificar escenarios fuertemente afectados por ruido de movimiento, evitando así una realimentación inadecuada con posibles efectos adversos en la terapia RCP.

Agradecimientos

Este trabajo ha recibido ayuda financiera del Ministerio de Ciencia, Innovación y Universidades, proyecto RTI2018-101475-BI00, junto con el Fondo Europeo de Desarrollo Regional (FEDER), así como del Gobierno Vasco a través de la subvención a grupos de investigación IT-1229-19 y la beca pre-doctoral PRE-2019-1-0209.

Referencias

- [1] Berdowski J, Berg RA, Tijssen JGP, Koster RW. Global incidences of out-of-hospital cardiac arrest and survival rates: Systematic review of 67 prospective studies. *Resuscitation*, vol 81, 2010, pp 1479-1487.
- [2] Perkins GD, Handley AJ, Koster RW, et al. European Resuscitation Council Guidelines for Resuscitation 2015 Section 2. Adult basic life support and automated external defibrillation. *Resuscitation*, vol 95, 2015, pp 81-99.
- [3] Soar J, Nolan JP, Böttiger BW, et al. European Resuscitation Council Guidelines for Resuscitation 2015 Section 3. Adult advanced life support. *Resuscitation*, vol 95, 2015, pp 100-147.
- [4] Hostler D, Everton-Stewart S, Rea TD, et al. Effect of real-time feedback during cardiopulmonary resuscitation outside hospital: prospective cluster-randomized trial. *BMJ (Clinical research ed.)*, vol 342, 2011.
- [5] Aramendi E, Lu Y, Chang MP, et al. A novel technique to assess the quality of ventilation during pre-hospital cardiopulmonary resuscitation. *Resuscitation*, vol 132, 2018, pp 41-46.
- [6] Chang MP, Lu Y, Leroux B, et al. Association of ventilation with outcomes from out-of-hospital cardiac arrest. *Resuscitation*, vol 141, 2019, pp 174-181.
- [7] Risdal M, Aase SO, Stavland M, et al. Impedance-based ventilation detection during cardiopulmonary resuscitation. *IEEE Transactions on Biomedical Engineering*, vol 54, 2007, pp 2237-2245.
- [8] Jaureguibeitia X, Irusta U, Aramendi E, et al. Automatic detection of ventilations during mechanical cardiopulmonary resuscitation. *IEEE JBHI*, vol 24, 2020, pp 2580-2588.
- [9] Wang HE, Schmicker RH, Daya MR, et al. Effect of a strategy of initial laryngeal tube insertion vs endotracheal intubation on 72-hour survival in adults with out-of-hospital cardiac arrest: a randomized clinical trial. *JAMA*, vol 320, 2018, pp 769-778.
- [10] Irusta U, Ruiz J, de Gauna SR, et al. A least mean-square filter for the estimation of the cardiopulmonary resuscitation artifact based on the frequency of compressions. *IEEE Transactions on Biomedical Engineering*, vol 56, 2009, pp 1052-1062.
- [11] Xiao Y, Tadokoro Y. Lms-based notch filter for the estimation of sinusoidal signals in noise. *Signal Processing*, vol 46, 1995, pp 223-231.
- [12] Cortes C, Vapnik V. Support-vector networks. *Machine Learning*, vol 20, 1995, pp 273-297.
- [13] Alonso E, Ruiz J, Aramendi E, et al. Reliability and accuracy of the thoracic impedance for measuring cardiopulmonary resuscitation quality metrics. *Resuscitation*, vol 88, 2015, pp 28-34.