



Universidad
Zaragoza

Trabajo Fin de Máster

Procesado de la señal de balistocardiografía
e inteligencia artificial para la estimación
del gasto cardíaco

Balisticardiography signal processing and
artificial intelligence for cardiac output
estimation

Autora

Sara Entenza Garmendia

Director y Ponente

Erik Alonso González

Raquel Bailón Luesma

Máster en Ingeniería Biomédica

ESCUELA DE INGENIERÍA Y ARQUITECTURA

2025

Procesado de la señal de balistocardiografía e inteligencia artificial para la estimación del gasto cardíaco

RESUMEN

En casos de paro cardíaco extrahospitalario, la identificación y detección del retorno de la circulación espontánea son fundamentales, pero las técnicas actuales presentan importantes limitaciones. Procedimientos convencionales, como la palpación del pulso carotídeo, la observación del abdomen o el análisis del ECG, no ofrecen suficiente fiabilidad ni precisión. Una alternativa prometedora para monitorizar la recirculación sanguínea es el gasto cardíaco, expresado como el volumen de sangre eyectado por minuto. Sin embargo, las técnicas disponibles para medirlo son inviables en un entorno extrahospitalario debido a su alto coste, complejidad y la necesidad de personal especializado. En este trabajo, se propone el uso de la balistocardiografía (BCG), medida mediante un sensor piezoeléctrico, como señal base para entrenar modelos de *machine learning* (ML) con el objetivo de estimar el gasto cardíaco de manera no invasiva, asequible y automática.

Para ello, se registraron señales de ECG, BCG carotídeo y abdominal, así como el gasto cardíaco basado en presión arterial invasiva, en un grupo de 20 sujetos sanos. El conjunto final de datos consistió en 125 segmentos correspondientes a tres fases experimentales: normoventilación, hipoventilación, Trendelenburg e infusión. Las señales fueron procesadas mediante filtros adaptativos y la transformada wavelet, además de incorporar nuevas características. Se extrajeron un total de 103 características utilizando ventanas de 10 segundos con un solapamiento del 80% entre ventanas consecutivas. Estas características incluyen aspectos morfológicos, momentos estadísticos y otros basados en el cálculo del *ensemble average*. Para esta selección, se aplicó el método RReliefF con el fin de identificar las más relevantes y optimizar el rendimiento del modelo de ML, basado en Máquinas de Soporte Vectorial para Regresión. Posteriormente, se optimizaron los hiperparámetros del modelo y se evaluó su desempeño en la estimación del gasto cardíaco.

Esta técnica puede entenderse como el punto inicial para desarrollar un estimador de CO que sea automático, no invasivo, sencillo de aplicar, asequible y seguro.

Índice

1	Introducción	4
1.1	Parada cardíaca: Definición y contexto	4
1.2	Intervención temprana y su impacto en la supervivencia . . .	4
1.3	Desafíos en el reconocimiento del paro cardíaco	6
1.4	Planteamiento	8
1.4.1	Contexto en el que se realiza el trabajo	8
2	Estado del Arte	9
2.1	Estado actual de la detección de flujo sanguíneo en la parada cardíaca	9
2.2	Potenciales alternativas futuras	11
2.3	La balistocardiografía como predictor de GC	11
3	Objetivos	13
4	Materiales	14
4.1	Estudio y diseño	14
4.2	Protocolo del estudio	14
4.3	Base de datos	16
5	Metodología	17
5.1	Preprocesamiento de las señales	17
5.1.1	Preprocesamiento	17
5.1.2	Filtrado adaptativo	18
5.1.3	Análisis Wavelet	21
5.2	Extracción de características	23
5.3	Arquitectura del modelo y su evaluación	26
5.3.1	Selección de características	27
5.3.2	Algoritmo de regresión	27
6	Resultados	30
6.1	Configuración del filtro RLS	30
6.2	Algoritmos de selección de características	31
6.3	Modelo final	33
6.4	Gasto cardíaco real vs estimado	35
7	Conclusiones	38

8 Bibliography	40
Lista de Figuras	45

1. Introducción

1.1 Parada cardíaca: Definición y contexto

El paro cardíaco (PC), es una interrupción repentina del pulso y la consciencia causada por un fallo inesperado en la capacidad del corazón para bombear sangre de manera eficaz. Suele estar causada por arritmias potencialmente mortales y anomalías en el sistema eléctrico del corazón. El corazón deja de funcionar, el flujo sanguíneo hacia los órganos vitales como el cerebro se detiene, y es mortal si no se trata en pocos minutos [1]. La mayoría de los paros cardíacos ocurren fuera del hospital (OHCA por sus siglas en inglés) y no son presenciados por ningún testigo. Esto representa un problema crítico, ya que la falta de reconocimiento e intervención inmediata reduce significativamente las posibilidades de supervivencia. Se estima que en España anualmente se producen 52.300 paradas cardíacas de las cuales 30.000 ocurren fuera del ámbito hospitalario. Esto representa cerca del 57% del total de paradas cardíacas en el país y entre estos tan solo entre el 5 y el 10% se recuperan [2].

1.2 Intervencción temprana y su impacto en la supervivencia

La inmediata reanimación cardiopulmonar (RCP) y la pronta desfibrilación son fundamentales tras una parada cardíaca. Como se muestra en la siguiente Figura 1.1., la combinación de ambas intervenciones puede mejorar significativamente los resultados de supervivencia. Según el Consejo General de Colegios Oficiales de Médicos (CGCOM), iniciar maniobras de RCP dentro de los primeros 3-4 minutos puede incrementar las posibilidades de supervivencia en más del 50% [3]. Incluso personas no profesionales pueden realizar RCP mediante compresiones torácicas para mantener artificialmente la circulación hacia los órganos vitales. De hecho, la intervención temprana por parte de un testigo presencial puede duplicar o triplicar las probabilidades de supervivencia [4]. Además de la reanimación, el uso de un desfibrilador externo automatizado (DEA) es crucial para revertir arritmias ventriculares o taquicardias ventriculares letales, restaurando el ritmo cardíaco normal.



Figure 1.1: Importancia de la RCP precoz y la desfibrilación temprana para mejorar los resultados. Fuente: *American Heart Association (2021)*.

Según la base de datos del estudio Cardiac Arrest Registry to Enhance Survival (CARES), en el pasado 2023 la proporción de pacientes con OHCA que sobrevivieron hasta el alta hospitalaria cuando fueron desfibrilados primero por un testigo con un DEA fue del 47,1%, en comparación con el 25,8% de los pacientes que recibieron el primer shock por parte de primeros rescatadores legos y el 27,9% por personal de emergencia. Estos datos se encuentran reflejados en la Figura 1.2.

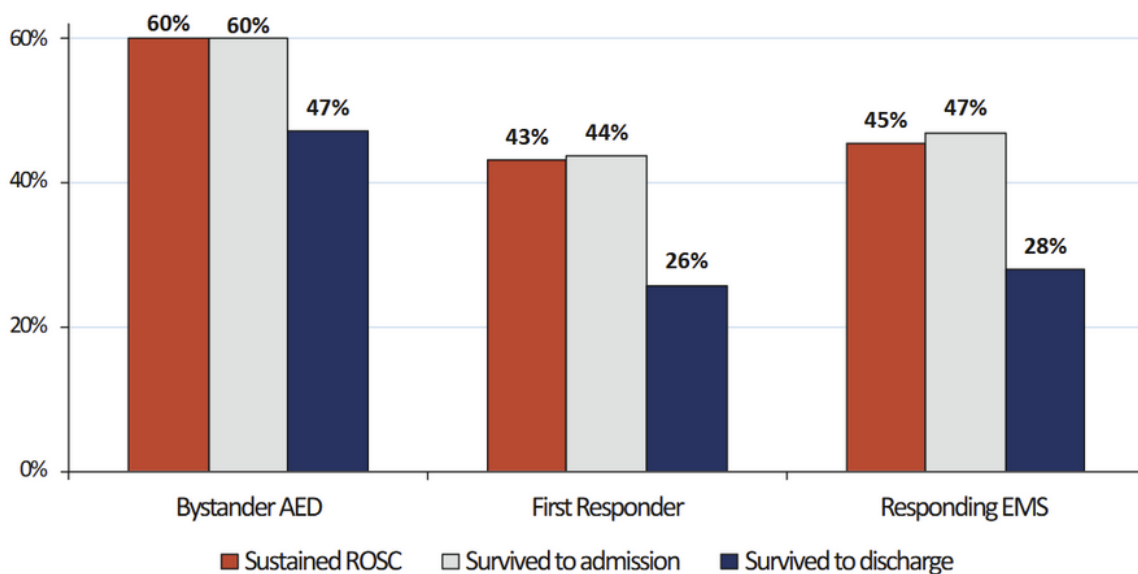


Figure 1.2: Fuente: *Cardiac Arrest Registry to Enhance Survival (CARES). 2023 Annual Report*.

El retorno de la circulación espontánea en el lugar del evento, así como la supervivencia hasta el ingreso hospitalario y el alta, están fuertemente asociados con la realización de RCP por parte de testigos. Tal y como se muestra en la Figura 1.3, en 2023, la tasa de supervivencia hasta el alta para los pacientes que recibieron RCP de inmediato (12,5%) fue significativamente mayor que la de aquellos que no contaron con esta

asistencia inicial (7,6%) [5].

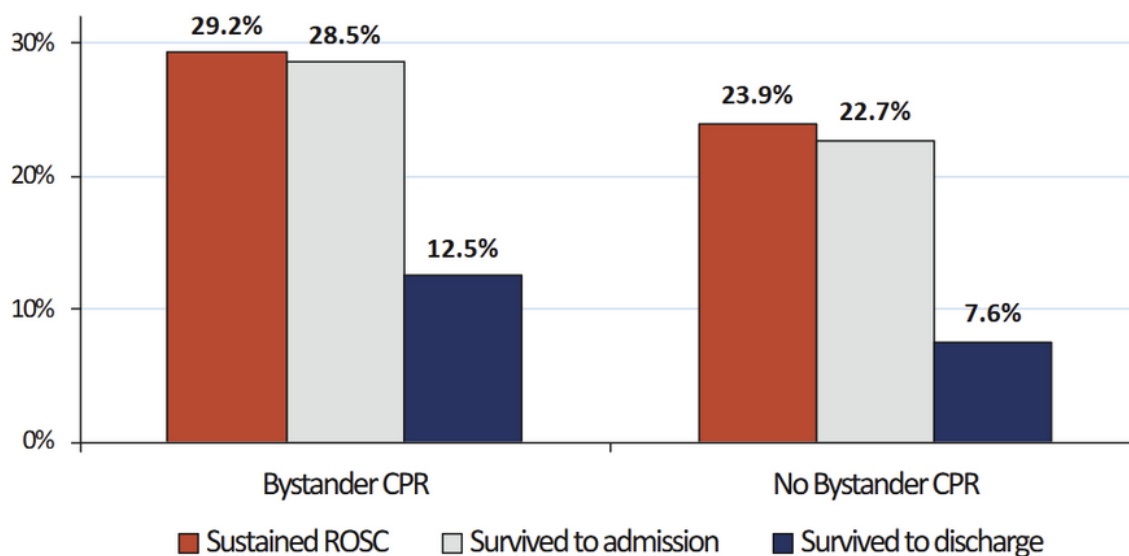


Figure 1.3: Fuente: *Cardiac Arrest Registry to Enhance Survival (CARES). 2023 Annual Report.*

1.3 Desafíos en el reconocimiento del paro cardíaco

El reconocimiento del PC presenta desafíos significativos, ya que la verificación del pulso carotídeo no ha demostrado ser precisa para los rescatadores no profesionales e incluso para aquellos con experiencia y formación especializada en atención de emergencias. En un estudio de Eberle et al. (1996) [6], se evaluó la precisión diagnóstica de los primeros rescatadores (personas legas con entrenamiento básico en soporte vital, técnicos en emergencias médicas en formación, paramédicos en formación y paramédicos certificados), al intentar palpar el pulso carotídeo en pacientes con y sin pulso. Aunque la sensibilidad para detectar la ausencia de pulso fue relativamente alta, la especificidad fue solo del 55%, lo que significa que muchos rescatadores no pudieron identificar correctamente el pulso en pacientes con circulación. Por otro lado, Liberman et al. (1999) [7] encontró que incluso los profesionales de la salud, como los técnicos de emergencias médicas y los paramédicos, cometieron errores significativos al intentar verificar el pulso carotídeo. Aunque el 94% de los participantes intentó palpar el pulso, solo el 45% de ellos fue capaz de detectarlo correctamente y detener la RCP cuando correspondía.

Ya en el 2000 las guías eliminaron la verificación del pulso como parte de la formación para rescatadores no especializados, y recomendaron que los profesionales de salud también redujeran su énfasis en esta práctica [8]. Las dificultades para determinar la

presencia de pulso, especialmente en emergencias donde el tiempo es crítico (según las guías, no debe tomarse más de 10 segundos y sólo en caso de ser profesional), llevaron a un cambio en las recomendaciones.

Además, se desaconsejó la verificación del ritmo cardíaco tras la descarga del desfibrilador, ya que esta acción interrumpía las compresiones torácicas durante periodos prolongados. Tres estudios observacionales [9, 10, 11], antes y después sobre paro cardíaco extrahospitalario evaluaron el impacto de omitir la verificación del ritmo inmediatamente después de un intento de desfibrilación. Los estudios observacionales documentaron una mejora en la supervivencia con un resultado neurológico favorable al alta hospitalaria asociada con este enfoque, que incluye la reanudación de las compresiones torácicas inmediatamente después de la desfibrilación [12].

Las guías de la AHA de 2010 reforzaron esta posición al reducir aún más la importancia de la revisión del pulso. En su lugar, se instruyó a los rescatadores no profesionales a asumir la presencia de paro cardíaco y a iniciar la RCP si un adulto colapsa de manera súbita o si una víctima inconsciente no respira o tiene una respiración anormal (jadeos). También se destacó que los testigos pueden interpretar erróneamente los jadeos agónicos como respiración normal, lo que puede retrasar la instrucción para iniciar la RCP [13].

Además de la mencionada palpación del pulso en la carótida, el paro cardíaco también puede detectarse mediante el electrocardiograma (ECG), distinguiendo entre la actividad eléctrica sin pulso (PEA) y el ritmo generador de pulso (PR). En el caso de la PEA, aunque el corazón pierde su capacidad contráctil (función mecánica) y deja de generar flujo y perfusión sanguínea, la actividad eléctrica persiste. Esto puede dificultar la percepción de diferencias claras en el ECG entre ambos ritmos. Teóricamente, el PR muestra complejos QRS regulares y estrechos, mientras que la PEA tiende a presentar complejos QRS más irregulares y anchos [14].




Figure 1.4: Ejemplo de segmentos PEA Y PR. Fuente: *Imagen modificada de [?]*

Así, existe una necesidad crucial de desarrollar un detector de pulso confiable, ya que actualmente no se dispone de ningún instrumento o dispositivo implementado que facilite esta tarea. Disponer de una herramienta de este tipo permitiría resolver varios de los problemas actuales, como el reconocimiento rápido del paro cardíaco, la reducción de pausas durante la RCP al detectar la circulación de manera precisa, y una identificación más eficiente de la ROSC.

Detectar el ROSC de forma temprana evitaría la necesidad de continuar con compresiones torácicas innecesarias cuando el corazón ya está bombeando ya que esto podría resultar contraproducente. Además, se evitaría la administración de medicamentos innecesarios, como la adrenalina, que en ese momento no serían beneficiosos. En conclusión, una detección temprana del ROSC permitiría iniciar el cuidado post-resucitación de manera más eficiente y efectiva, optimizando los resultados para el paciente.

1.4 Planteamiento

Como resultado, el estudio presenta un nuevo método para la detección del pulso durante el OHCA utilizando las señales de BCG obtenidas tanto en la carótida como en el abdomen. El enfoque utiliza el proceso avanzado de la señal a través de un esquema de filtrado adaptativo y el análisis de wavelet, diferentes metodologías para la selección de características y finalmente un clasificador basado en las Máquinas de Vectores de Soporte.

1.4.1 Contexto en el que se realiza el trabajo

El trabajo ha sido desarrollado en la Universidad del País Vasco (UPV/EHU), durante la contratación como investigadora en el grupo de investigación BioRes, que se especializa en la aplicación de técnicas avanzadas de procesamiento de señales y aprendizaje automático a señales biomédicas, con un énfasis particular en mejorar el tratamiento del paro cardíaco extrahospitalario.

La sección siguiente aborda el estado del arte con una revisión del contexto, de los conceptos y técnicas relacionadas con la estimación del gasto cardíaco, seguida de la descripción de la metodología desarrollada, que incluye el procesamiento de señales y la implementación del modelo machine learning. Posteriormente, se discuten los resultados obtenidos y su interpretación, concluyendo con las principales aportaciones del trabajo y posibles líneas futuras.

2. Estado del Arte

2.1 Estado actual de la detección de flujo sanguíneo en la parada cardíaca

Se han desarrollado diversas soluciones basadas en el procesamiento de señales biomédicas para cuantificar medidas de flujo sanguíneo en el ámbito de la parada cardíaca. Un ejemplo de ello es el uso de saturación regional de oxígeno cerebral, medida mediante espectroscopia de infrarrojo cercano, el cual se ha usado para predecir el ROSC en paros cardíacos tanto intrahospitalarios como extrahospitalarios [15],[16]. Por otro lado, se han investigado señales biomédicas para la detección del pulso en modelos porcinos de paro cardíaco, como el ultrasonido Doppler en la arteria carótida y la fotopleletismografía nasal, ambas empleadas para estimar el gasto cardíaco (GC). También se han empleado señales de aceleración medidas en la arteria carótida común de pacientes con paro cardíaco intra-hospitalario [17] o adquiridas a partir de dispositivos de retroalimentación de RCP basados en acelerómetros en un modelo porcino para el diseño de detectores de pulso. Asimismo, recientemente se ha observado que un aumento abrupto en los niveles de dióxido de carbono al final de la espiración (EtCO₂) puede ser un indicador específico, aunque con baja sensibilidad, de ROSC en casos de OHCA.

Finalmente, varios estudios han utilizado el ECG [18, 19, 20] o la impedancia torácica (*TI* por sus siglas en inglés) [21, 22] para detectar el pulso. Sin embargo, otros han combinado el ECG y la TI [23, 24], el ECG y el EtCO₂ [25], o el ECG, la TI y el EtCO₂ [26].

La impedancia, medida a través de los parches de desfibrilación y usada para comprobar la correcta colocación de los mismos, puede ser una señal de interés, ya que puede mostrar fluctuaciones correladas con los complejos QRS, en ritmos PR. Estas fluctuaciones, conocidas como la componente circulatoria (*ICC*, por sus siglas en inglés), representan pequeños cambios en la impedancia causados por la actividad mecánica del corazón durante la contracción ventricular. Sin embargo, estas variaciones suelen ser menores a 100 mΩ y pueden ser difíciles de detectar debido al ruido o artefactos, como el movimiento o la ventilación.

En este contexto, varios estudios recientes han explorado la *ICC* como una herramienta clave para desarrollar detectores de pulso más precisos [27, 28]. Estos trabajos se centran en cómo esas pequeñas fluctuaciones de impedancia, estrechamente vinculadas a los complejos QRS, podrían ser utilizadas para desarrollar un detector de pulso fiable. A continuación, se describen algunos artículos que abordan este enfoque.

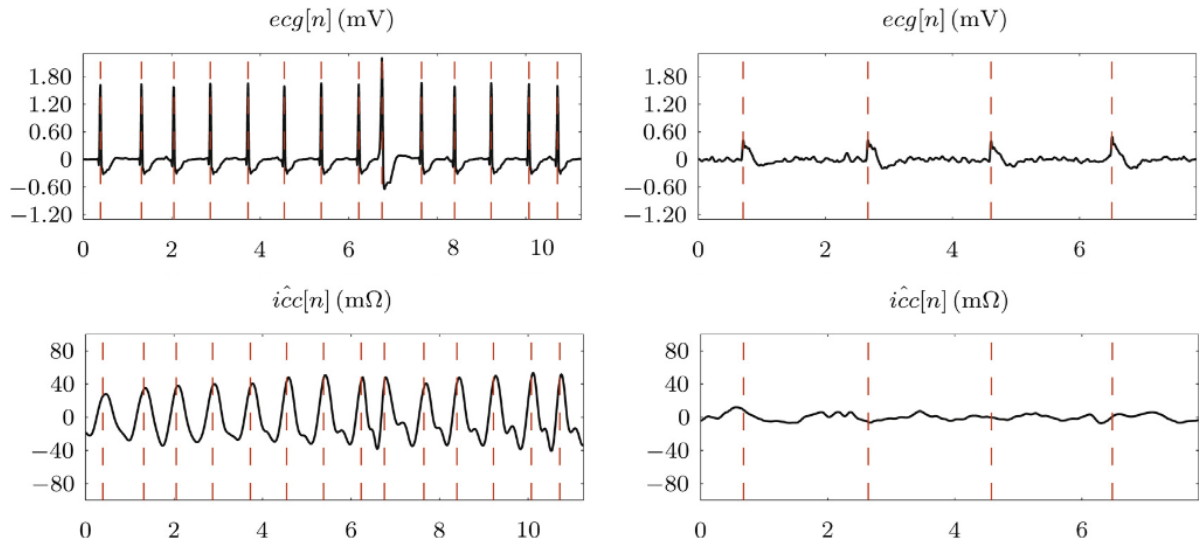


Figure 2.1: Ejemplos de señal ECG y señal ICC estimada de un segmento PR y un segmento PEA procesados con el esquema adaptativo propuesto en J. Ruiz et al. Fuente: *Imágen modificada de* [27]

En 2016, Alonso et al. [29] desarrollaron un método para clasificar ritmos organizados durante la reanimación, utilizando señales de ECG y TI libres de artefactos. El enfoque se centró en extraer características morfológicas del ECG y del ICC para distinguir entre PEA y PR. El rendimiento del método se evaluó en términos de sensibilidad y especificidad, y se exploró su utilidad en la confirmación del paro cardíaco y el ROSC.

En 2021, Elola et al. [30] presentaron una solución multimodal para clasificar el estado de circulación en pacientes con OHCA, utilizando datos de ECG, TI y capnograma. La solución clasificó los estados en dos o tres clases PR/PEA o TPEA (True PEA)/PPEA (Pseudo PEA)/PR y entrenaron un modelo de bosque aleatorio con un conjunto de datos compuesto por 2506 segmentos de 5 segundos, etiquetados con presión arterial invasiva.

Asimismo, Alonso et al. [31] propusieron en 2020 otro algoritmo basado en ECG y TI para detectar el pulso en pacientes con OHCA. Utilizaron 1140 segmentos de señales etiquetadas como PR o PEA, aplicando un filtrado adaptativo para extraer el componente circulatorio por impedancia y una descomposición wavelet del ECG.

Las características extraídas se utilizaron en un clasificador SVR para identificar la presencia o ausencia de pulso.

Aunque los estudios mencionados se centran en el desarrollo de detectores de pulso, ninguno ha logrado ser implementado con éxito por una razón principal: la impedancia debe tener una alta resolución para permitir la extracción del ICC y detectar sus fluctuaciones. Sin embargo, esto no es común, ya que solo algunos monitores desfibriladores cuentan con esta capacidad. La mayoría de los dispositivos disponibles ofrecen una impedancia de baja calidad, ya que, como se ha mencionado anteriormente, su uso se ha limitado tradicionalmente a verificar la correcta adhesión de los parches al tórax.

2.2 Potenciales alternativas futuras

Como alternativa para detectar diferentes niveles de circulación, se podría considerar la monitorización del GC. Este enfoque permitiría distinguir entre estados como PEA, con un GC inexistente, y otros estados con GC reducido o normal, proporcionando una evaluación más precisa de la perfusión y facilitando la toma de decisiones clínicas en tiempo real.

Hasta el momento, el catéter de arteria pulmonar (PAC) con la técnica de termodilución ha sido considerado el método estándar para medir GC. Sin embargo, su invasividad, la dificultad de implementación en entornos prehospitalarios y los riesgos asociados con un aumento de morbilidad y mortalidad en pacientes graves han generado dudas sobre su idoneidad. Como resultado, se ha producido un cambio hacia técnicas que son mínimamente invasivas o completamente no invasivas en las últimas dos décadas.

Algunas de estas alternativas incluyen el análisis del contorno de pulso de la onda de presión arterial [32], la termodilución transpulmonar [33], la ecocardiografía transesofágica [34] y la recirculación parcial de CO_2 [35], que ya se utilizan en monitores comerciales de GC. Sin embargo, estas técnicas presentan limitaciones en situaciones de emergencia prehospitalarias, ya sea por su complejidad técnica, la falta de fiabilidad en esos entornos o la necesidad de un tiempo considerable y habilidades especializadas para obtener resultados precisos.

2.3 La balistocardiografía como predictor de GC

En este contexto, la balistocardiografía (BCG) surge como una opción prometedora, no invasiva y de bajo costo. La BCG mide las fuerzas generadas por la sangre

bombreada hacia la cama vascular, lo que está directamente relacionado con el GC. Aunque su uso para estimar el GC es aún poco explorado, Starr et al. [36, 37] (quien es considerado el fundador de la balistocardiografía moderna por la Cardiovascular System Dynamics Society, EE. UU), ya propusieron en 1940 una fórmula para calcular el volumen sistólico en reposo utilizando características de la BCG, como la duración y las áreas [38]. A pesar de su potencial, la complejidad de los dispositivos y la aparición de la ecocardiografía hicieron que la BCG fuera relegada en la práctica clínica.

Recientemente, el interés por la BCG ha aumentado gracias a los avances tecnológicos que han permitido reducir el tamaño de los sensores. Se ha comprobado que las características de la onda de BCG, obtenidas a partir de sensores ubicados en una báscula, un asiento o directamente sobre la piel, siguen de cerca los cambios en el GC [39]. La amplitud de la onda registrada en una placa de fuerza o en la muñeca ha mostrado correlaciones positivas con el GC. Incluso, se ha sugerido que la BCG medida en una báscula de baño, una cama sensible a la carga estática o en la muñeca podría ser útil como indicador de la contractilidad cardíaca.

Sin embargo, ninguno de los estudios previos se ha realizado en un entorno de emergencia prehospitalaria, lo que limita su aplicabilidad en situaciones reales de atención urgente fuera del hospital. Recientemente, Svensøy et al. [40] realizaron un estudio de factibilidad en sujetos sanos, en el cual analizaron la estimación del GC utilizando características morfológicas extraídas de señales de BCG. Su trabajo representa un primer paso prometedor hacia un método automatizado y no invasivo para la estimación del GC.

3. Objetivos

El objetivo de este Trabajo de Fin de Máster es analizar la viabilidad de estimar el GC utilizando señales extraídas de biosensores piezoeléctricos colocados en la superficie corporal de sujetos sanos, en condiciones de prueba que simulen una situación de medicina de emergencia. La BCG tiene el potencial de medir de manera no invasiva la contractilidad cardíaca y de seguir los cambios en el GC, lo que la convierte en una alternativa prometedora en este contexto. Para ello, se emplearán algoritmos de inteligencia artificial que procesen las características morfológicas extraídas de las señales de BCG, con el fin de estimar el GC de manera precisa en situaciones de emergencia.

Para alcanzar este objetivo, se han establecido los siguientes **objetivos específicos**:

1. **Preprocesado de las señales:** Eliminación de línea base y artefactos de alta y baja frecuencia.
2. **Filtrado adaptativo:** Extracción de la componente circulatoria.
3. **Aplicación de la transformada wavelet estacionaria:** Análisis multiresolución de las señales de BCG.
4. **Extracción de características:** Caracterización estadística de las señales BCG y cálculo de características morfológicas de su forma de onda.
5. **Selección de características:** Aplicación de un algoritmo de selección de características.
6. **Modelo SVR:** Aplicación de un algoritmo SVR para la estimación de GC.

4. Materiales

4.1 Estudio y diseño

El estudio se llevó a cabo en el departamento de cardiología del Hospital Universitario de Oslo (Ullevål Hospital), en 20 sujetos sanos en el que a cada uno se le colocaron biosensores BCG piezoeléctricos, parches de desfibrilación para el registro del ECG y un sensor FloTrac conectado a una línea arterial radial mientras permanecían acostados en una camilla de ambulancia. El sensor piezoeléctrico se colocó sobre la piel en dos zonas, la arteria carótida y la aorta abdominal para capturar las señales de BCG que se utilizaron posteriormente para la extracción de características. Los parches de desfibrilación, dispuestas en posición anterolateral registran ECG (VII) a través del monitor LIFEPAK[®] 15. Para terminar, se mide la presión de manera invasiva a través de una línea arterial radial conectada sensor FloTrac y vinculado al monitor HemoSphere (Edwards Lifesciences Corporation, Nyon, Suiza) que utilizó para calcular el gasto cardíaco mediante análisis del contorno de la onda de pulso. Este último es el que se utiliza como “gold standard” o referencia para la estimación del GC.

4.2 Protocolo del estudio

El protocolo se llevó a cabo de manera continua y consecutiva, sin pausas intermedias:

- **Normoventilación (9 minutos):** Los sujetos respiraron normalmente mientras se registraban todas las señales.
- **Hiperventilación (1 minuto):** Se les pidió que respiraran de forma rápida y profunda. Esta fase generó movimientos abruptos que introdujeron artefactos en las señales, especialmente en las de BCG, lo que dificultó su interpretación posterior e impidió su uso en el análisis final.
- **Hipoventilación (0.5 minutos):** Los participantes mantuvieron la respiración durante medio minuto.
- **Posición Trendelenburg (aproximadamente 2 minutos):** Los sujetos fueron colocados en una inclinación de 30° para inducir los posibles cambios hemodinámicos asociados con el desplazamiento de fluidos corporales y la presión hacia la parte superior del cuerpo.

- **Transporte en ambulancia (5 minutos):** Los sujetos fueron transportados en una camilla por carreteras bacheadas. Esta fase se incluyó para simular condiciones de movimiento típicas en emergencias hospitalarias. Sin embargo, al igual que el caso de la hiperventilación, las señales de esta fase no se utilizaron en el análisis debido a artefactos significativos.
- **Infusión (aproximadamente 4 minutos):** Se administraron 500 ml de solución de Ringer Acetat mientras los participantes respiraban normalmente.

Estos procedimientos tienen como objetivo evaluar el impacto de los cambios respiratorios y por consiguiente el ritmo cardíaco y gasto cardíaco. En la Figura 4.1, se puede observar una descripción general de la colocación de los biosensores mencionados.

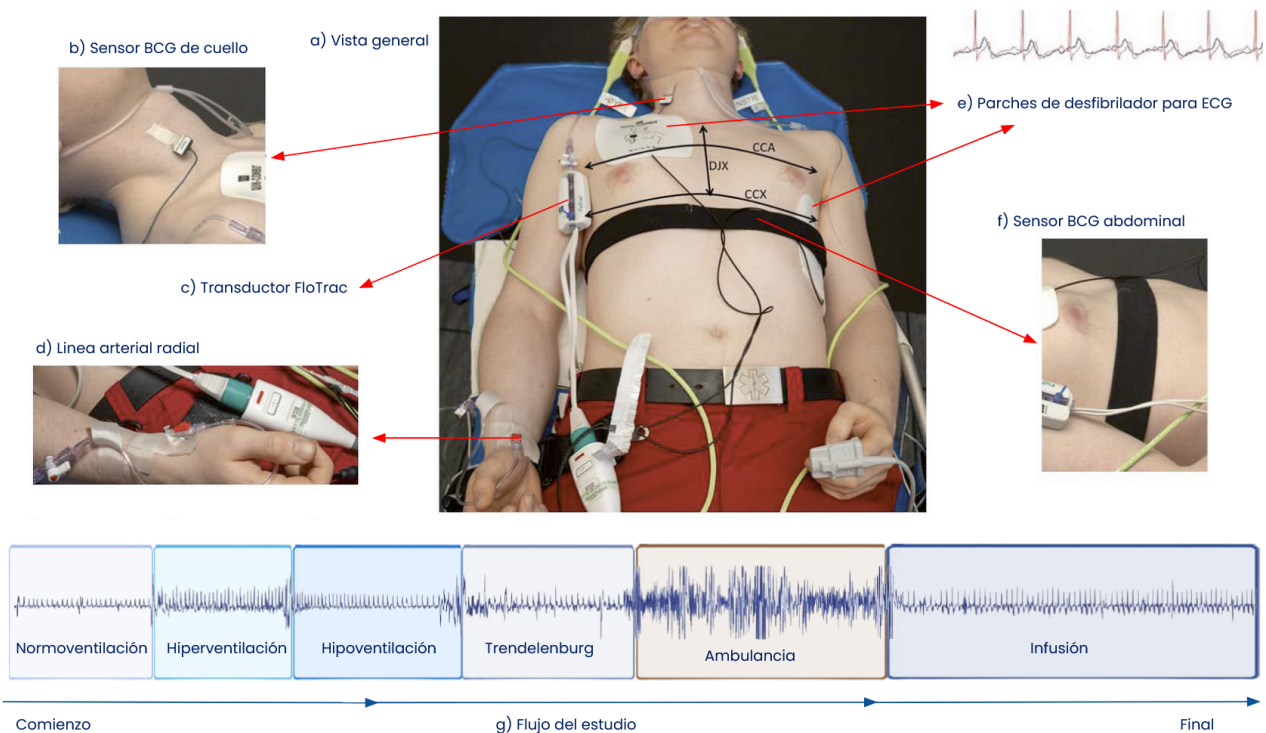


Figure 4.1: (a) Sujeto recostado en una camilla. (b) El biosensor BCG, posicionado sobre la piel en la arteria carótida. (c) El transductor FloTrac (d) La línea arterial radial, conectada al sensor y al transductor FloTrac. (e) Las palas de desfibrilación acopladas al monitor LIFEPAK[®] 15, que muestra el ECG (con ondas ECG rojas superpuestas a las ondas BCG azules como ejemplo). (f) El biosensor BCG ubicado sobre la piel en la aorta abdominal. (g) Se puede observar cómo evoluciona la señal a lo largo de cada fase. Fuente: *Imagen modificada de [40]*

4.3 Base de datos

Como se ha mencionado anteriormente, el estudio incluyó datos de 20 sujetos adultos sanos a los cuales se les registraron las señales de ECG con una frecuencia de muestreo de 250 Hz y las señales de balistocardiografía recolectadas en las ubicaciones carotídea y abdominal, también grabadas a 250 Hz. Además el gasto cardíaco fue medido invasivamente a una frecuencia de 0.5 Hz (una muestra cada 2 segundos), y fue considerado como “ground truth”. Dado que cada señal se registró con dispositivos diferentes, se realizó una conversión de los datos a un formato estándar compatible con MATLAB y se alinearon temporalmente las señales para facilitar su análisis.

Los segmentos se inspeccionaron individualmente para seleccionar únicamente las señales libres de artefactos. Sin embargo, como se ha mencionado, en algunas fases, como el transporte en ambulancia y la hiperventilación, no fue posible extraer señales debido a los movimientos provocados por la rápida respiración y los desplazamientos vehiculares alterando así significativamente las grabaciones de BCG. El conjunto final de datos constó de 125 segmentos de ECG además del balistocardiograma medido tanto la carótida BCG^c como en el abdomen BCG^a . Estos se distribuyeron en las siguientes 4 fases:

- **Normoventilación:** 27 segmentos con una duración de 41.1 segundos.
- **Hipoventilación:** 19 segmentos con una duración de 30.1 segundos.
- **Trendelenburg:** 29 segmentos con una duración de 45.7 segundos.
- **Infusión:** 50 segmentos con una duración de 61.3 segundos.

Siendo la duración media (desviación estándar, DE) de todos los segmentos de 48.6 (42.3) s.

5. Metodología

En el presente capítulo se describe en detalle la metodología desarrollada en este trabajo. El proceso inicia con la adquisición de señales de ECG, BCG^c y BCG^a , las cuales se someten a un preprocesamiento para eliminar ruido e interferencias. A continuación, se lleva a cabo la detección de los complejos QRS, lo que permite identificar los latidos cardíacos. Con esta información, se aplica un filtrado adaptativo a la señal, seguido de una transformación Wavelet que facilita la extracción de características relevantes. Como se muestra en la Figura 5.2., estas señales procesadas se utilizan en la etapa de extracción de características, donde se seleccionan las más relevantes mediante el algoritmo ReliefF. Finalmente, se emplea un modelo SVR para estimar el gasto cardíaco a partir de las características seleccionadas. La evaluación de este modelo se realiza utilizando la métrica de error absoluto medio (MAE por sus siglas en inglés), la cual mide la magnitud promedio de los errores entre las predicciones del modelo y los valores reales.

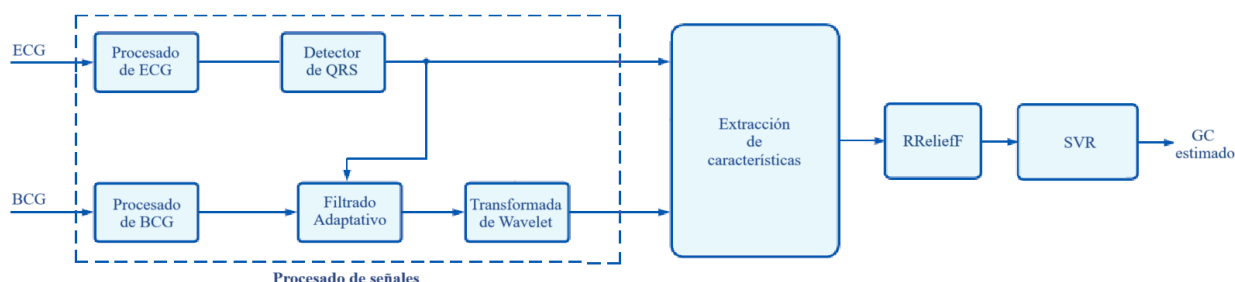


Figure 5.1: Descripción general de la metodología

5.1 Preprocesamiento de las señales

5.1.1 Preprocesamiento

El procesamiento de señales es una etapa esencial para extraer información relevante y minimizar la influencia de ruido. Para ello, como se ha mencionado, primero se pasan las tres señales (ECG, BCG^a y BCG^c) por filtros paso bandas para eliminar los artefactos relacionados con las bajas y altas frecuencias y fluctuaciones de línea base.

La frecuencia de corte debe seleccionarse de manera que preserve la información de la señal ECG sin causar distorsión, a la vez que se elimine la mayor cantidad posible del desplazamiento de la línea base. Para ello, se identifica la componente de frecuencia

más baja del ECG. Por ejemplo, si la frecuencia cardíaca puede descender a 40 latidos por minuto, la frecuencia mínima sería de 0,67 Hz. Sin embargo, debido a que este valor no es demasiado preciso, se recomienda utilizar una frecuencia de corte suficientemente baja, alrededor de 0,5 Hz. Así, el filtrado de la señal ECG se realiza mediante un filtro pasa bandas entre 0.5 Hz y 30 Hz, con el objetivo de suprimir la deriva de la línea base y el ruido de alta y baja frecuencia. Una vez filtradas, se detectaron automáticamente los complejos QRS en el ECG utilizando el algoritmo de Hamilton-Tompkins. Esta información fue crucial para las etapas posteriores de filtrado adaptativo y extracción de características.

Por otro lado, en el filtrado de las señales BCG se ha utilizado un filtro paso bandas entre 0.5 Hz y 3 Hz, ajustado a las características específicas de las señales BCG, para preservar exclusivamente las componentes frecuenciales relacionadas con la circulación mientras se elimina el ruido de alta y baja frecuencia.




Figure 5.2: Ejemplo de un segmento de 60 segundos analizado correspondiente a la fase Trendelenburg. De arriba a abajo, se representan el CO, el ECG preprocesado, el CC^c y el CC^a . Los puntos rellenos en azul oscuro en el CC^c y el CC^a representan los máximos de las fluctuaciones causadas por cada latido cardíaco.

5.1.2 Filtrado adaptativo

El filtrado adaptativo se implementó utilizando un algoritmo recursivo de mínimos cuadrados (RLS por sus siglas en inglés) para extraer las componentes circulatorias específicas (CC^c y CC^a) de las señales BCG carotídea y abdominal, respectivamente.

La señal se modeló como la siguiente suma de componentes:

$$s_{\text{bcg}}(n) = s_{\text{rest}}(n) + CC(n) \quad (5.1)$$

siendo:

- $CC(n)$: Componente de circulación que refleja fluctuaciones provocadas por la contracción cardíaca.
- $s_{\text{rest}}(n)$: Señal BCG incluyendo línea base, componente respiratoria, y artefactos debidos a movimientos del sensor.

donde n , el índice de muestra, está relacionado con el tiempo de manera que $t = \frac{n}{f_s}$ siendo f_s la frecuencia de muestreo (250 Hz).

Los instantes de los complejos QRS detectados fueron usados como referencia para llevar a cabo el filtrado adaptativo. La clave de este enfoque radica en que cada contracción efectiva del corazón eyecta sangre hacia la aorta, lo que genera fluctuaciones en el BCG. Estas fluctuaciones corresponden a la componente relacionada con la circulación, denotada como $CC(n)$ y es la señal a estimar con el filtro RLS.

Esta componente $CC(n)$, al ser de naturaleza cuasiperiódica, se modeló como una serie de Fourier con N armónicos, donde las amplitudes y frecuencias varían lentamente:

$$CC(n) = \sum_{k=1}^N [a_k(n) \cos(k\omega_0(n)n) + b_k(n) \sin(k\omega_0(n)n)] \quad (5.2)$$

donde:

- N : Número de armónicos.
- $a_k(n)$ y $b_k(n)$: Coeficientes de Fourier (amplitudes de fase y cuadratura).
- $\omega_0(n) = \frac{2\pi f_0(n)}{f_s}$: Frecuencia angular fundamental.

Amplitud de la componente en fase, $a_k(n)$: Representa la magnitud de la componente del coseno en la señal para el k -ésimo armónico. Un cambio en $a_k(n)$ indica una variación en el peso de la parte alineada con el coseno.

Amplitud de la componente en cuadratura $b_k(n)$: Representa la magnitud de la componente del seno en la señal para el k -ésimo armónico. Un cambio en $b_k(n)$ indica una variación en el peso de la parte desfasada 90° respecto al coseno.

Como se ha mencionado, los índices de los picos R (r_i) de los complejos QRS se detectaron utilizando el algoritmo de Hamilton-Topkins y se usaron para calcular $f_0(n)$

de la siguiente manera:

$$f_0(n) = \frac{f_s}{r_{i+1} - r_i}, \quad \forall n \in [r_i, r_{i+1}] \quad (5.3)$$

donde $f_0(n)$, la frecuencia cardíaca, es constante dentro de cada intervalo QRS, pero varía lentamente entre intervalos consecutivos.

Utilizando la notación matricial, $CC(n) = x^T(n)w(n)$:

$$x(n) = \begin{pmatrix} \cos(\omega_0(n)n) \\ \sin(\omega_0(n)n) \\ \vdots \\ \cos(N\omega_0(n)n) \\ \sin(N\omega_0(n)n) \end{pmatrix} = \begin{pmatrix} x_1(n) \\ x_2(n) \\ \vdots \\ x_{2N-1}(n) \\ x_{2N}(n) \end{pmatrix}$$

$$w(n) = \begin{pmatrix} a_1(n) \\ b_1(n) \\ \vdots \\ a_N(n) \\ b_N(n) \end{pmatrix} = \begin{pmatrix} w_1(n) \\ w_2(n) \\ \vdots \\ w_{2N-1}(n) \\ w_{2N}(n) \end{pmatrix}$$

Así, de manera iterativa, el algoritmo RLS estima los coeficientes $a_k(n)$ y $b_k(n)$, minimizando el error cuadrático ponderado:

$$C(n) = \sum_{i=1}^n \lambda^{n-i} |e(i)|^2 \quad (5.4)$$

donde:

- λ : Factor de olvido ($0 < \lambda \leq 1$).
- $e(n)$: Error entre la señal deseada y la estimada, definido como:

$$e(n) = s_{\text{bcg}}(n) - CC(n) = s_{\text{bcg}}(n) - x^T(n)w(n) \quad (5.5)$$

El factor de olvido o *forgetting factor* (λ) hace referencia a la adaptabilidad de un filtro que gobierna la velocidad de convergencia y la estabilidad del algoritmo RLS. Un λ pequeño acelera la velocidad de convergencia, pero a riesgo de volver inestable el proceso. Cuando el factor de olvido es igual a 1 en un filtro RLS, el comportamiento del filtro se asemeja a un mínimo cuadrado clásico (*least squares*) sin ningún tipo de olvido. Esto significa que el filtro se ajusta a todas las observaciones históricas de manera igualitaria, sin dar preferencia a las muestras más recientes. En otras palabras,

el filtro no adapta su estimación de acuerdo a los cambios dinámicos en los datos, sino que mantiene una “memoria” completa de todas las mediciones anteriores.

La optimización de la configuración del algoritmo RLS se centra en ajustar dos parámetros clave: el factor de olvido (λ) mencionado recientemente y el número de armónicos (N). El proceso y resultado del mismo se detallan en la sección 6.0.1.

5.1.3 Análisis Wavelet

Para finalizar con el procesado de la señal, se llevó a cabo un análisis multiresolución utilizando la transformada wavelet estacionaria (SWT) con el objetivo de aislar y analizar las diferentes componentes sub-banda ciculatorias de la señal BCG y obtener así la señal BCG reconstruida $s_r(n)$, únicamente usando las sub-bandas de interés.

En este proceso, la señal obtenida a partir del filtrado adaptativo detallado en el apartado anterior (denotada como $CC(n)$) se somete a dos filtros: un filtro paso-bajo (h_j) y un filtro paso-alto (g_j). Estos filtros permiten separar las componentes de frecuencia baja y alta, respectivamente. Como resultado, se generan dos conjuntos de coeficientes en cada nivel de descomposición, $J = 1, \dots, J$: los coeficientes de aproximación $a_j(n)$ y los coeficientes de detalle $d_j(n)$, lo que permite descomponer la señal en diferentes niveles de detalle y frecuencia.

Los filtros en cada nivel se aumentan por un factor de 2 con respecto a los filtros del nivel anterior. Así, $h_j(n)$ se obtiene insertando un cero entre cada par de muestras adyacentes de $h_{j-1}(n)$.

La extracción de coeficientes en cada nivel se realiza de la siguiente forma, donde $(*)$ denota convolución:

- $a_0(n) = CC(n)$: Coeficiente de aproximación inicial, que representa la salida del filtro adaptativo.
- $a_j(n) = g_{j-1}(n) * a_{j-1}(n)$: Coeficiente de aproximación en el nivel j , obtenido mediante la convolución del coeficiente de aproximación del nivel anterior $j - 1$ con el filtro paso-alto.
- $d_j(n) = h_{j-1}(n) * a_{j-1}(n)$: Coeficiente de detalle en el nivel j , obtenido convolucionando el coeficiente de aproximación del nivel anterior $j - 1$ con el filtro paso-bajo.

En este análisis, se realizó una descomposición en $J = 8$ niveles utilizando una wavelet madre Coiflet 3, generando así los coeficientes de detalle (d_1, \dots, d_8) .

Finalmente, se reconstruye el coeficiente ($a_0(n)$) a través de la evaluación recursiva de la siguiente ecuación :

$$a_{j-1}(n) = \frac{1}{2}(g'_j(n) * a_j(n) + h'_j(n) * d_j(n)) \quad (5.6)$$

desde $j = 1, \dots, J$, donde $g_j(n) = g_j(M - 1 - n)$ y $h_j(n) = h_j(M - 1 - n)$ son las versiones invertidas en el tiempo de los filtros de descomposición, conocidos como filtros de síntesis. El coeficiente sintetizado $a_0(n)$ correspondió a $s_r(n)$ el cual fue reconstruido usando los coeficientes de detalle $d_6 - d_8$ y por lo tanto, sólo retuvo componentes frecuenciales entre 0,5 – 3,8 Hz. En la Figura 5.3. se puede ver la señal BCG reconstruida y los coeficientes de detalle d_6 a d_8 mencionados.

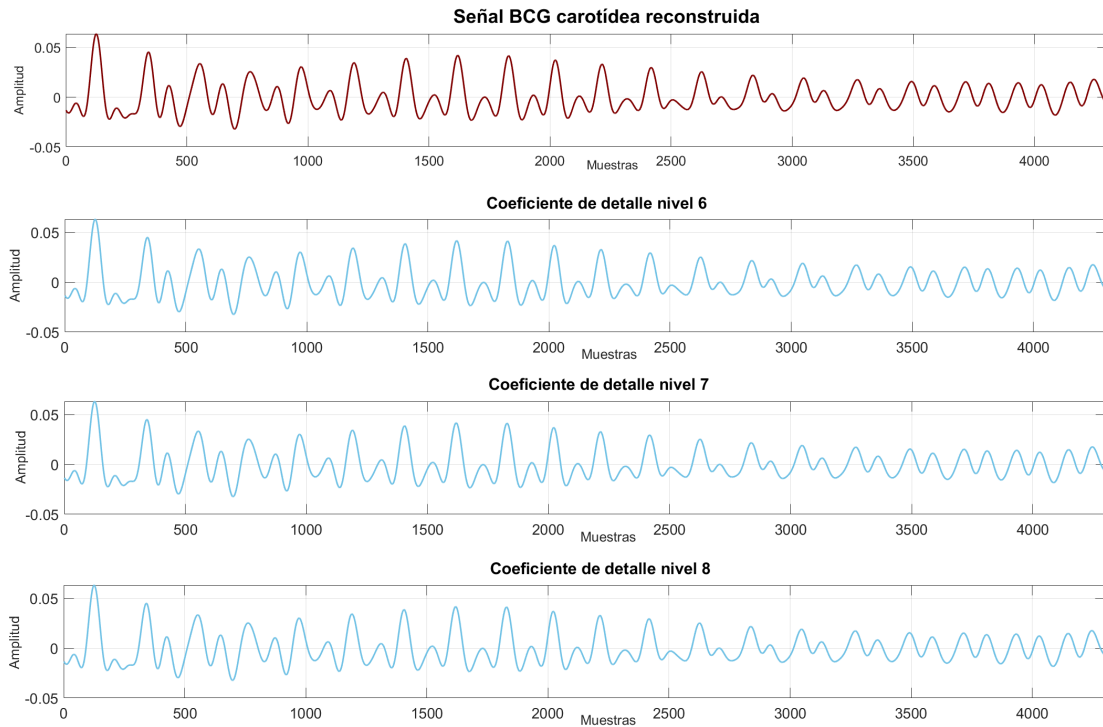


Figure 5.3: Análisis de la señal BCG carotídea reconstruida y sus coeficientes de detalle, en la parte superior muestra la señal reconstruida, mientras que los gráficos inferiores representan los coeficientes de detalle en los niveles 6, 7 y 8 obtenidos mediante descomposición wavelet.

5.2 Extracción de características

Se extrajeron un total de 103 características utilizando ventanas de 10 segundos con un solapamiento del 80% entre ventanas consecutivas. Estas características se agrupan en dos conjuntos principales. El primero incluye 66 características extraídas de las señales reconstruidas $s_r^a(n)$ (correspondiente al abdomen) y $s_r^c(n)$ (de la carótida) descritas en el apartado anterior, y el segundo está compuesto por un total de 36 características extraídas de los coeficientes de detalle, $d_6^a-d_8^a$ (abdomen) y $d_6^c-d_8^c$ (carótida).

Dentro del primer conjunto, las primeras 60 características corresponden a la mediana y desviación estándar de 15 características morfológicas calculadas en base a cada latido, con el objetivo de caracterizar lo siguiente:

- **Duración:** El tiempo desde el inicio de la fluctuación hasta el pico positivo máximo (D_1), la duración total de la fluctuación (D_t), el tiempo desde el pico positivo máximo hasta el final y el ancho del pulso de la fluctuación (D_2), definido como la duración de la mitad superior de la fluctuación. La Figura 5.4 muestra de manera individual el detalle de cálculo de las cuatro características mencionadas.




Figure 5.4: De izquierda a derecha, D_1 , D_2 , D_t , y P_w , respectivamente. Para las tres primeras características t_{on} , t_M , y t_{off} representan los instantes inicial, pico positivo máximo, y final de la fluctuación. Mientras que para P_w , los instantes en los que se alcanzan el 50% de la amplitud en la primera y segunda mitad de la fluctuación vienen dados por t_i y t_f , respectivamente.

- **Amplitud:** La amplitud máxima de la fluctuación (a_M), la amplitud desde el inicio de la fluctuación hasta el pico positivo máximo (A_1), la amplitud desde el pico positivo máximo hasta el final de la fluctuación (A_2), además de los valores máximo A_{max} y medio A_{mean} entre las amplitudes A_1 y A_2 . La Figura 5.5 muestra de manera individual el detalle de cálculo tres de las cinco características mencionadas.




Figure 5.5: De izquierda a derecha, A_2 , a_M y A_1 , respectivamente. Para el caso de A_1 y A_2 mencionados, a_{on} , a_M , y a_{off} representan la amplitud inicio, máximo y final respectivamente.

- **Área:** El área desde el inicio hasta el pico positivo máximo de la fluctuación (Ar_1), el área total de la fluctuación (Ar_t) y el área desde el pico positivo máximo hasta el final de la fluctuación (Ar_2). La Figura 5.6 muestra de manera individual el detalle de cálculo de las cuatro características mencionadas.




Figure 5.6: Características con el área. Los instantes t_{on} , t_M , y t_{off} son los mencionados anteriormente.

- **Longitud:** La longitud total de la fluctuación (L_t), la longitud desde el pico positivo máximo hasta el final de la fluctuación (L_2) y la longitud desde el inicio de la fluctuación hasta pico positivo máximo (L_1). La Figura 5.7 muestra de manera individual el detalle de cálculo de las cuatro características mencionadas.




Figure 5.7: Características con la longitud. Los instantes t_{on} , t_M , y t_{off} son los mencionados anteriormente.

Las restantes tres características que completan las 66, se enfocaron en resumir la distribución estadística de la señal, incluyendo la desviación estándar, la asimetría y la curtosis.

Como se ha mencionado anteriormente, el segundo grupo está compuesto por un total de 36 características. Se calcularon 6 características para los tres coeficientes de detalle, y a su vez, cada coeficiente se calcula para cada señal $d_6^a - d_8^a$ (abdómen) y $d_6^c - d_8^c$ (carótida). Estas se basan en el cálculo del *ensemble average* (EA), el cual consiste en obtener un patrón promedio a partir de ciclos repetitivos de una señal segmentada en función de puntos de referencia, como los instantes QRS. El promedio del conjunto elimina las variaciones latido a latido, pero proporciona una buena estimación de la forma de onda relacionada con la circulación. En este caso, se analizan las señales reconstruidas s_r^a y s_r^c alineando segmentos individuales de la señal basados en los instantes QRS detectados en el ECG [23].

Matemáticamente, el proceso se puede describir con la siguiente fórmula:

$$z_{EA}(m) = \frac{1}{K} \sum_{k=1}^K z(p(k) + m - 1), \quad m = 1, \dots, M,$$

donde:

- $z(p(k) + m - 1)$: Amplitud del coeficiente de detalle en el instante $p(k)$, que corresponde al inicio del k -ésimo intervalo R-R del ECG, desplazado $m - 1$ muestras hacia adelante.
- K : Número total de intervalos R-R utilizados.
- M : Longitud promedio de los intervalos R-R en muestras.
- m : Índice temporal dentro de cada intervalo R-R considerado.

Estas son las 6 características obtenidas para cada EA de los coeficientes detalle $d_6^a - d_8^a$ y $d_6^c - d_8^c$ representados de forma genérica en las siguientes ecuaciones a través de $z_{EA}(m)$:

1. **Amplitud relativa de la señal:** Representa la diferencia entre los valores máximo y mínimo de la señal promedio $z_{EA}(m)$, normalizada por la duración total L :

$$a_{rel} = \frac{\max(z_{EA}(m)) - \min(z_{EA}(m))}{L}$$

2. **Rango de la primera diferencia de la señal:** Calcula la diferencia entre el

valor máximo y mínimo de $dz_{EA}(m)$, la primera diferencia:

$$R_d = \max(dz_{EA}) - \min(dz_{EA})$$

3. **Área bajo la forma de onda:** Corresponde al área de la señal $z_{EA}(m)$, donde f_s y L representan la frecuencia de muestreo y duración total de la señal:

$$A_b = \frac{\sum_{m=1}^L |z_{EA}(m)|}{L}$$

4. **Duración del flanco negativo de mayor longitud:** Calcula la diferencia entre los instantes del pico negativo (n_{p1}) y el siguiente pico negativo (n_{p2}):

$$D_{\text{flk}} = n_{p2} - n_{p1}$$

5. **Amplitud del flanco negativo (v_{11}):** Representa la diferencia de amplitud entre $z_{EA}(n_{p1})$ y $z_{EA}(n_{p2})$:

$$a_{\text{flk}} = z_{EA}(n_{p2}) - z_{EA}(n_{p1})$$

6. **Longitud de la curva de la señal (CL):** Calcula la complejidad total de la señal considerando los cambios locales y la frecuencia de muestreo f_s :

$$CL = \sum_{m=1}^L \sqrt{\left(\frac{1}{f_s}\right)^2 + (dz_{EA}(m))^2}$$

5.3 Arquitectura del modelo y su evaluación

El presente trabajo desarrolla un sistema de aprendizaje supervisado que combina validación cruzada anidada, selección de características y optimización de hiperparámetros para un modelo de Regresión de Vectores de Soporte. Inicialmente, los datos se dividen por pacientes de manera que en la validación cruzada se asegura que el modelo no se vea influido por datos del mismo paciente en ambos conjuntos lo que podría llevar a una sobreestimación del rendimiento.

La validación cruzada utilizada consta de dos niveles: un bucle externo, donde se evalúa el rendimiento general del modelo, y un bucle interno, que selecciona las características relevantes y optimiza los hiperparámetros. El bucle interno consistió en un esquema de validación cruzada (CV) de 4 folds, mientras que en el bucle externo se empleó una validación cruzada de 5 particiones para optimizar los hiperparámetros del clasificador

y evaluar el rendimiento del modelo. En ambos bucles, interno y externo, se utilizaron particiones aleatorias cuasi-estratificadas a nivel de pacientes.

Como se ha mencionado al principio de este capítulo, la evaluación del desempeño del modelo se realiza mediante el MAE. Estas métricas se calcularon exclusivamente en los folds de test (bucle exterior), comparando la estimación del GC generada por el modelo con el *gold standard* proporcionado por el sistema Hemosphere. Finalmente, para garantizar la robustez de los resultados, todo el proceso de validación cruzada anidada se repitió 50 veces. Esto permite evaluar la variabilidad y consistencia de las métricas de desempeño, asegurando que los resultados no estén influenciados por la aleatoriedad de las particiones.

5.3.1 Selección de características

RReliefF mide la relevancia de cada característica observando cómo los valores de esa característica cambian entre instancias vecinas en el espacio de características. Las instancias se clasifican en dos tipos de vecindad:

- **Vecinos de la misma clase:** Se buscan instancias cercanas con la misma clase para minimizar las diferencias entre ellas, ya que las características relevantes deben ser consistentes entre estos vecinos.
- **Vecinos de clases diferentes:** Se buscan instancias cercanas pero de diferentes clases para maximizar las diferencias, dado que las características relevantes deben ser capaces de discriminar entre las clases.

Para calcular el peso de cada característica, el algoritmo toma cada muestra i de los datos de entrada X y encuentra los k vecinos más cercanos. En nuestro caso, al abordar un problema de regresión, los vecinos se encuentran en términos de distancia euclídea.

RReliefF evalúa las diferencias en la variable continua y entre los vecinos y utilizando la distancia euclídea entre las instancias, el algoritmo actualiza los pesos de las características en función de cómo reflejan las diferencias en y [41].

Así, las características que ayudan a predecir la variable continua se valoran más, mientras que aquellas que no aportan información útil se penalizan, permitiendo una selección de características más precisa.

5.3.2 Algoritmo de regresión

SVR es una técnica dentro del aprendizaje automático (*Machine Learning, ML*) que se utiliza para resolver problemas de regresión. Mientras que el aprendizaje supervisado

busca encontrar patrones en datos etiquetados, el objetivo específico de la regresión es predecir un valor continuo en lugar de clasificar datos en categorías (como en el caso del *Support Vector Machine, SVM*). SVR utiliza los mismos principios que SVM, pero adapta su formulación para ajustar una función continua en lugar de crear un umbral de decisión.

En SVR, el objetivo principal es encontrar una función $f(x)$ que prediga los valores de salida y con la mayor precisión posible, mientras que se minimiza la complejidad del modelo. La idea clave es introducir un margen de tolerancia ϵ alrededor de la función $f(x)$. En lugar de ajustar perfectamente los puntos de datos, SVR permite cierta desviación siempre que los errores sean menores que ϵ . Esto garantiza que el modelo sea robusto frente a ruido en los datos.

La formulación matemática de SVR puede explicarse a partir de la minimización de una función objetivo que equilibra dos elementos principales:

$$\min_{\mathbf{w}, b, \xi, \xi^*} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

Aquí:

- $\|\mathbf{w}\|^2$ controla la complejidad del modelo, manteniendo los pesos del modelo lo más pequeños posibles para evitar sobreajuste.
- C es un hiperparámetro que define el compromiso entre minimizar el error y mantener la complejidad del modelo.
- ξ_i y ξ_i^* son variables de holgura que representan los errores de predicción por fuera del margen ϵ .

El modelo debe cumplir con las siguientes restricciones para los datos de entrada (x_i, y_i) :

$$y_i - (\mathbf{w} \cdot \mathbf{x}_i + b) \leq \epsilon + \xi_i$$

$$(\mathbf{w} \cdot \mathbf{x}_i + b) - y_i \leq \epsilon + \xi_i^*$$

$$\xi_i, \xi_i^* \geq 0$$

En estas expresiones:

- $\mathbf{w} \cdot \mathbf{x}_i + b$ representa la predicción del modelo.
- ϵ es el margen dentro del cual los errores no son penalizados.
- ξ_i y ξ_i^* se activan cuando un dato está fuera del margen permitido, lo que significa que es un error significativo.

En términos más intuitivos, SVR busca un hiperplano que pase cerca de los datos, pero sin intentar ajustarlos perfectamente. Esto ayuda a evitar el sobreajuste, especialmente en casos donde los datos contienen ruido.

Además, al igual que en SVM, SVR puede usar funciones kernel (en el caso del presente trabajo se usa *RBF*, el kernel de base radial) para transformar los datos de entrada a un espacio de mayor dimensión, permitiendo que las relaciones no lineales sean capturadas de manera efectiva. El (*RBF*) se define como:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$$

donde γ controla el alcance de la influencia de un solo punto de dato. Esto permite que SVR modele relaciones complejas en los datos de entrada.

La optimización de los hiperparámetros consiste en ajustar C y γ . El parámetro de costo C regula el equilibrio entre sesgo y varianza del SVR y γ define la adaptabilidad de la frontera de decisión [42]. Los hiperparámetros C y γ se ajustaron en el bucle externo a través de una búsqueda en cuadrícula de 6×6 en los rangos $0.6 \leq C \leq 1.02$ y $10 \leq \gamma \leq 10.4$ para maximizar el MAE del SVR.

6. Resultados

Los principales resultados de los experimentos y su contextualización se presentan en esta sección. Primero, se realiza la búsqueda de los puntos de trabajo óptimos del filtro RLS para la extracción de la $CC(n)$, evaluando la interacción entre el factor de olvido, λ , y los N armónicos de la serie de Fourier N . Segundo, se analiza el impacto de la selección de características, incluyendo un ranking de las características seleccionadas según su relevancia y la evaluación del rendimiento del modelo en función de diferentes algoritmos de selección y el número de características K incluidas. Por último, se examina el rendimiento del modelo a lo largo de las cuatro fases analizadas (Normoventilación, Hipoventilación, Trendelenburg e Infusión).

6.1 Configuración del filtro RLS

Como se ha mencionado en la metodología, una de las etapas principales ha sido la optimización de los dos parámetros de ajuste del filtro. λ es un parámetro clave en el filtro RLS, que controla cómo el filtro “olvida” los errores pasados a medida que procesa nuevos datos. Este factor se utiliza para darle más o menos peso a las mediciones más recientes. Así, junto al factor de olvido, se ha calculado cuánta relevancia tiene el número de armónicos usado en la serie de Fourier.

Para ello, se evalúan todas las combinaciones posibles de los parámetros N y λ mediante un “grid search” en las 50 repeticiones del procedimiento de validación cruzada anidada. Los valores considerados para N son 1, 2, 3, 4 y 5, mientras que los valores de λ son 0.9950, 0.9970, 0.9990, 0.9993, 0.9996 y 0.9999.

El desempeño de cada configuración se mide a través del error absoluto medio en un modelo de regresión lineal. En la siguiente imagen se observa en un mapa de calor, el resumen del error absoluto medio para cada combinación de N y λ .

Como se puede observar en la Figura 6.1 la combinación más óptima de número de armónico y factor de olvido se da con $N= 3$ y $\lambda = 0,9999$.

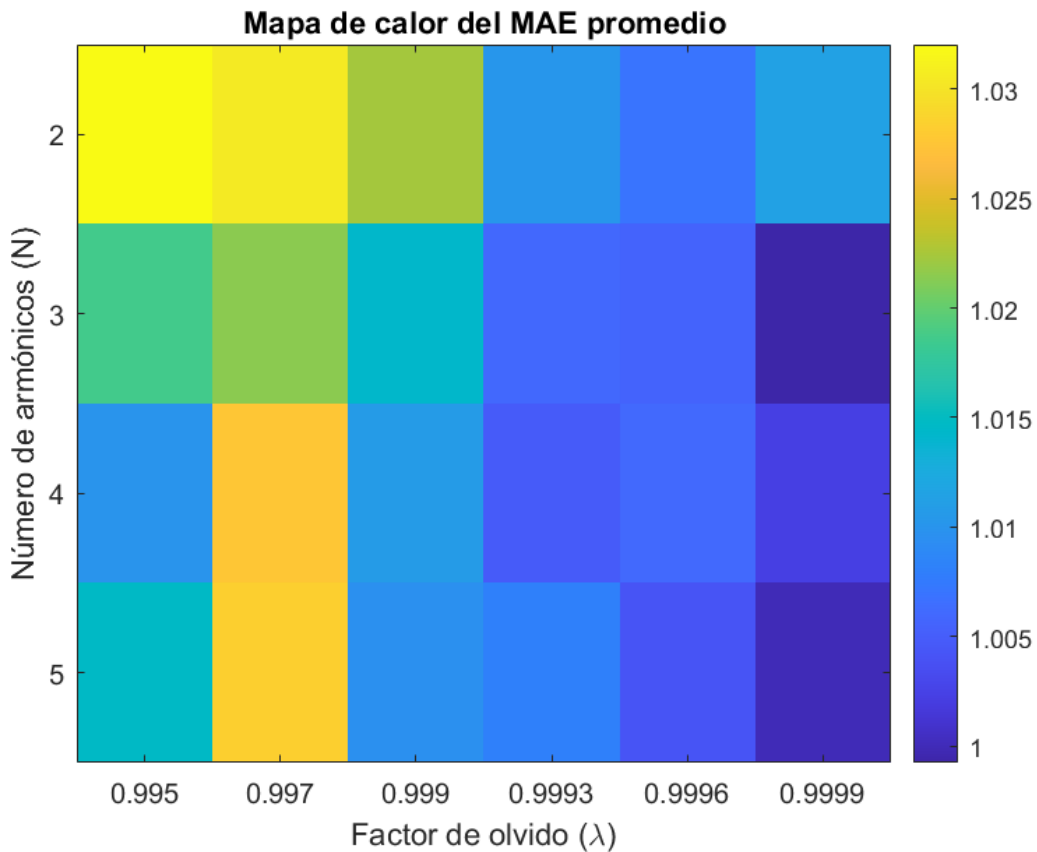


Figure 6.1: Mapa de calor del MAE promedio en función del número de armónicos y el factor de olvido.

6.2 Algoritmos de selección de características

En la Figura 6.2. presentada, se compara el desempeño de tres métodos de selección de características: RReliefF, MRMR y PTA(3,2), evaluados en términos de MAE en función del número de características seleccionadas. Se observa que, en general, el rendimiento de los algoritmos varía dependiendo de la cantidad de características utilizadas, mostrando una tendencia decreciente del MAE conforme se incrementa el número de características hasta cierto punto, para luego estabilizarse.

Como se ha mencionado anteriormente, el algoritmo RReliefF es una extensión del método ReliefF, diseñado para evaluar la relevancia de las características mediante la estimación de diferencias ponderadas entre instancias cercanas. En la gráfica, se observa que RReliefF presenta el menor MAE en comparación con los otros métodos cuando se selecciona un número reducido de características, alcanzando su valor mínimo cuando se incluyen 14 características en el modelo. Sin embargo, a partir de ese punto, a medida que se incluyen más características, el MAE experimenta un ligero aumento antes de estabilizarse en un valor cercano a 1.05. Este comportamiento sugiere que

RReliefF es efectivo para identificar un conjunto óptimo de características relevantes, pero su rendimiento podría degradarse si se incorporan atributos irrelevantes y/o redundantes.

Por otro lado, el método MRMR (Minimum Redundancy Maximum Relevance) selecciona características buscando un equilibrio entre la relevancia con la variable objetivo y la redundancia con las características ya seleccionadas. Su objetivo es maximizar la información útil mientras se minimiza la redundancia dentro del conjunto seleccionado. En la Figura 6.2., el MRMR muestra un comportamiento similar al de RReliefF al incluir las primera características, aunque su MAE inicial es ligeramente superior. A medida que se incrementa el número de características, el error se reduce y alcanza su valor mínimo en 9 características, antes de comenzar a aumentar gradualmente. Este resultado indica que MRMR logra el equilibrio perfecto entre relevancia y redundancia de las características seleccionadas con un número ligeramente menor de atributos en comparación con RReliefF pero con un MAE más alto.

En cuanto a PTA(3,2) este método combina enfoques de búsqueda secuencial hacia adelante (Sequential Forward Selection, SFS) y hacia atrás (Sequential Backward Selection, SBS) para seleccionar características de manera progresiva, agregando y eliminando atributos en cada iteración basándose en un criterio de desempeño. Los parámetros(3,2) indican que en cada iteración se seleccionan gradualmente hacia delante las 3 mejores características para después usando la selección gradual hacia atrás, eliminar las 2 menos relevantes. De esta manera el algoritmo en cada iteración incluye la característica más relevante en el modelo, evitando el efecto “anidamiento” presentado por los métodos puramente secuenciales SFS y SBS. Esta selección difiere de las otros métodos mencionados ya que se llevó a cabo utilizando un esquema de validación cruzada interna de 4 particiones, mediante un enfoque *wrapping* en el cual se evalúa el MAE en un modelo de regresión lineal siempre con el objetivo de minimizar el mismo.

En la gráfica, se evidencia un comportamiento más estable, con un MAE mínimo inicial, que a diferencia de los otros métodos, no muestra prácticamente mejora significativa al aumentar el número de características.

En términos generales, los resultados sugieren que RReliefF es el algoritmo más adecuado cuando se busca minimizar el MAE con un número reducido de características, mientras que MRMR con un comportamiento similar, no consigue reducir tanto el MAE. El algoritmo PTA(3,2), por su parte, muestra un comportamiento más consistente a lo largo de toda la gama de características

evaluadas sin realmente conseguir el objetivo de encontrar el equilibrio entre número de características y MAE mínimo.

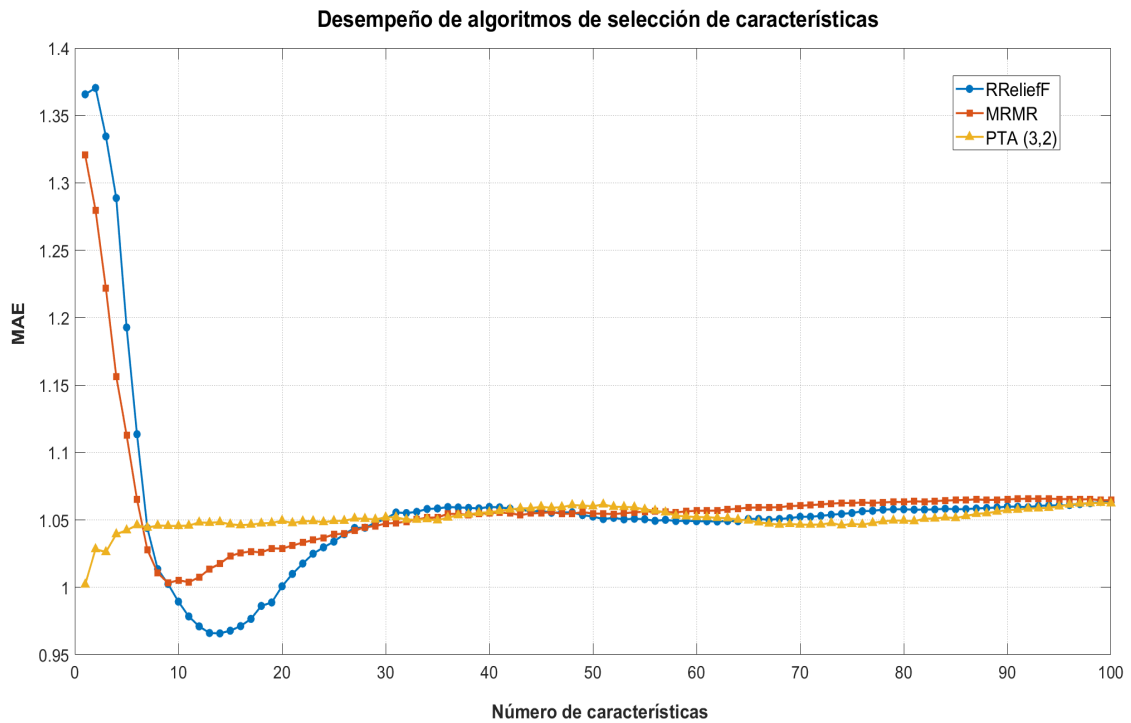


Figure 6.2: MAE en función de las características incluídas en el modelo para los distintos algoritmos de selección de características

6.3 Modelo final

El modelo desarrollado en este trabajo para la estimación del GC se basó en una SVR que incuyó $k = 14$ características seleccionadas en cada réplica mediante *ReliefF*. Se utilizó validación cruzada estratificada con 5 pliegues externos y 4 internos para asegurar la generalización del modelo.

Por otro lado en la Figura 6.3 podemos ver el análisis hecho para evaluar la relevancia de características basado en su aparición en las 14 posiciones de rankings generados durante ($50 \text{ repeticiones} \times 5 \text{ pliegues de CV} = 250 \text{ bucles de selección de características}$). En cada iteración, las características se ordenan según su importancia relativa utilizando ReliefF, y se registran cuántas veces cada característica aparece entre las primeras N posiciones (donde N varía de 1 a 14). Este proceso se repite para todos los pliegues y repeticiones, acumulando estas frecuencias. Finalmente, estas frecuencias se convierten en probabilidades al normalizarlas por el número total de rankings generados.

El análisis del ranking de las características más importantes revela una marcada

predominancia de métricas provenientes de momentos estadísticos, como la skewness (asimetría), y de medidas temporales, como el ancho de pulso y las duraciones clave en las fluctuaciones. Entre estas métricas destacan el tiempo desde el inicio de la fluctuación hasta el pico positivo máximo (D_1), así como el tiempo desde el pico positivo máximo hasta el final de la fluctuación y el ancho de pulso (D_2), tanto en la señal medida en el abdomen como en la carótida. Estas características resaltan por su capacidad para capturar los patrones temporales y la forma general de las señales analizadas, lo cual resulta crucial para la discriminación de los datos.

Adicionalmente, el modelo subraya la relevancia de características derivadas de los flancos negativos de los coeficientes de detalle (d_6, d_7). En particular, la amplitud de estos flancos aporta información complementaria a las métricas temporales, indicando que los coeficientes de detalle juegan un papel relevante en la caracterización de patrones específicos presentes en las señales.

Otro aspecto interesante es la distribución equitativa de la información aportada por las señales medidas en la carótida y el abdomen. Por ejemplo, dentro de las 10 características más probables del ranking, cinco provienen de la señal carotídea y cinco de la señal abdominal. Este balance sugiere que ambas señales contribuyen de manera significativa al modelo, sin que ninguna de ellas domine claramente como la principal fuente de información discriminativa.

En general, el ranking refleja un equilibrio entre características que capturan aspectos globales, como la forma y las duraciones de las fluctuaciones, y métricas más específicas obtenidas a partir de los coeficientes de detalle. Este balance destaca la importancia de combinar ambas perspectivas para mejorar el rendimiento del modelo y asegurar una caracterización integral de las señales.

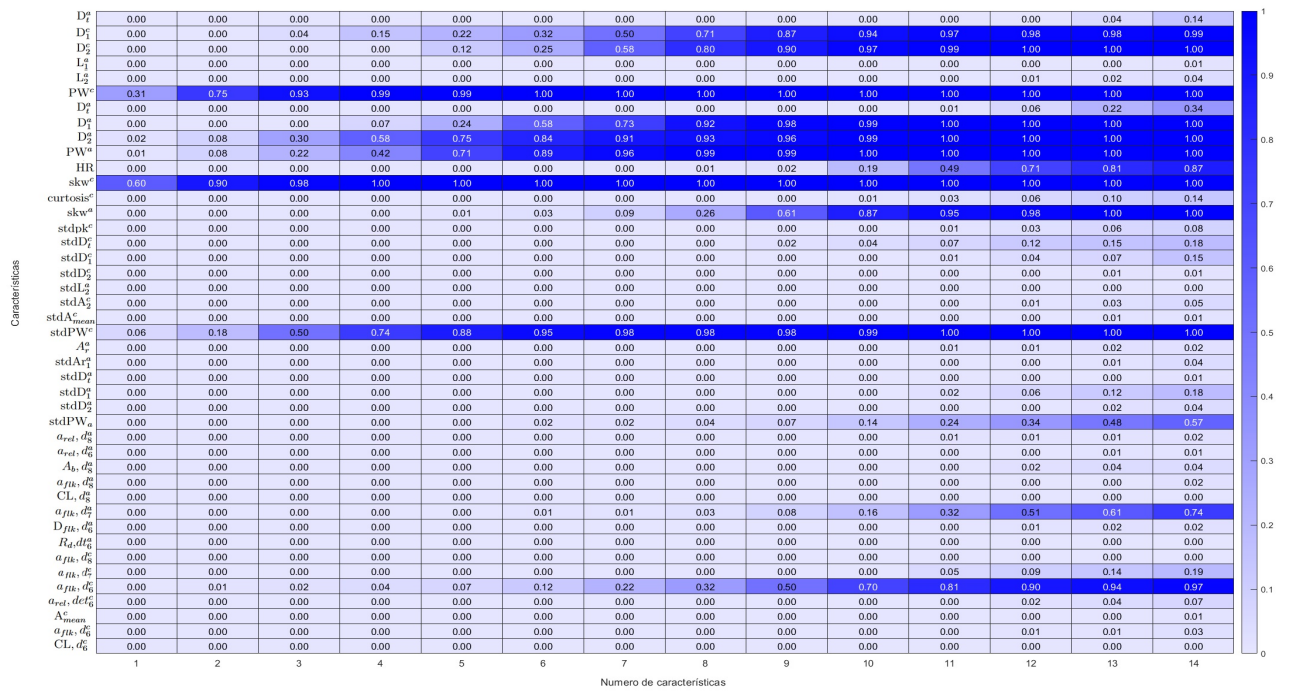


Figure 6.3: MAE en función de las características incluidas en el modelo para los distintos algoritmos de selección de características

6.4 Gasto cardíaco real vs estimado

La gráfica Bland-Altman presentada Figura 6.4, permite analizar las diferencias entre los valores reales del GC, medidos por el Hemsphere, y las predicciones generadas por nuestro modelo. En el eje x se representan las mediciones reales del Hemsphere, mientras que en el eje y se muestran las diferencias (GC real - GC estimado) entre las predicciones y los valores reales. Este enfoque proporciona una visión clara sobre el comportamiento del modelo y su nivel de concordancia con las mediciones reales.

El sesgo, calculado como la mediana de las diferencias debido a la ausencia de normalidad ($p < 0.001$), tiene un valor de -0.086, lo que indica que, en general, el modelo predice sin un sesgo concreto, lo que sugiere la ausencia de una tendencia global hacia una sobreestimación o subestimación sistemática por parte del modelo.

Los límites que delimitan el intervalo donde se encuentra aproximadamente el 90% de las diferencias, se sitúan en [-1.87, 2.35]. Al analizar la dispersión de los puntos, se observa que la mayoría de las diferencias se encuentran en un rango entre -1 y 1 cuando los valores de GC están entre 5 y 8 L/min. Esto sugiere un buen nivel de concordancia entre el modelo y el Hemsphere en esta región. Sin embargo, se observa que, a partir de un GC de 9 L/min, el modelo tiende a subestimar las mediciones reales

y por debajo de valores de 4 L/min tiende a la sobreestimación. Esto podría explicarse por la naturaleza del conjunto de datos, compuesto principalmente por sujetos sanos, lo que lleva al modelo a especializarse en predecir valores dentro de un rango "normal" de GC, que podría considerarse entre 4 y 8 L/min.

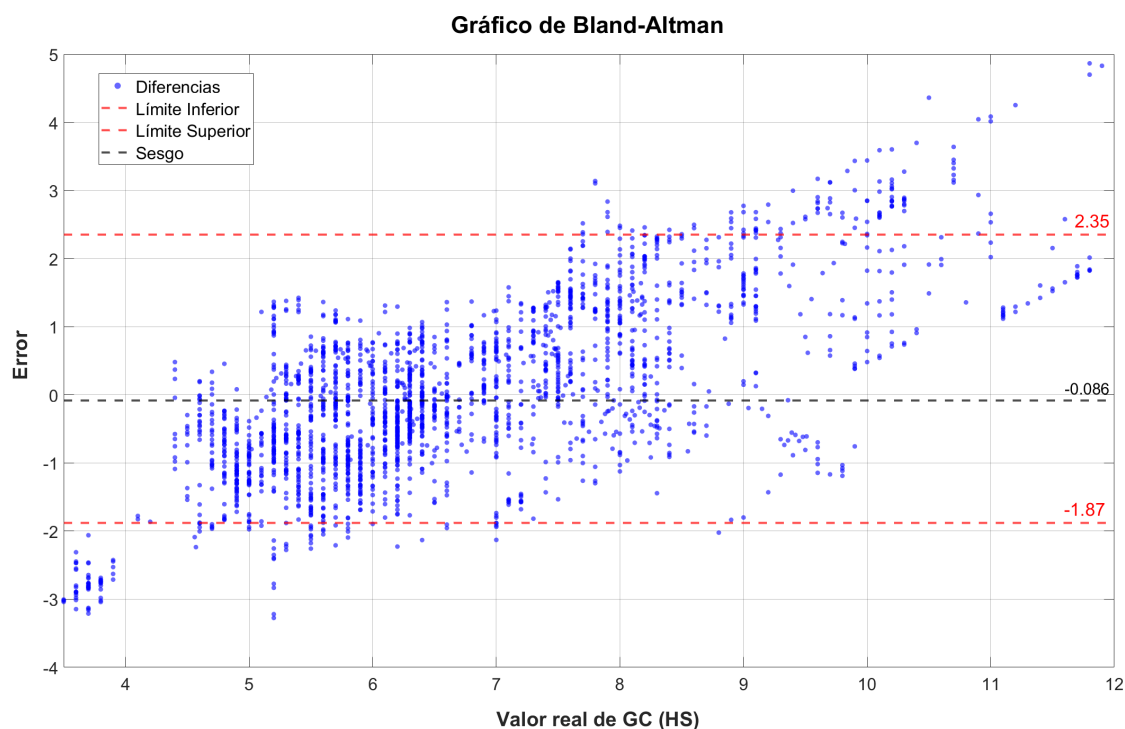


Figure 6.4: Gráfico de Bland-Altman que muestra los valores reales del GC dados por el dispositivo Hemosphere en litros por minuto frente al error calculado como GC real - GC estimado. La línea negra discontinua representa el sesgo mientras que las líneas discontinuas rojas indican el intervalo de acuerdo al 90%.

Para finalizar, se realizó un análisis detallado de la distribución del error absoluto medio en las distintas fases del protocolo de estudio, tal como se muestra en la Figura 6.5: Normoventilación, Hipoventilación, Trendelenburg e Infusión.

En la fase de Normoventilación, el MAE se mantuvo relativamente bajo, con una mediana cercana a 1.0 L/min, aunque se identificaron algunos valores atípicos que podrían estar relacionados con la variabilidad interindividual. En la transición hacia la fase de Hipoventilación, se evidenció un aumento notable del MAE, alcanzando una mediana de aproximadamente 1.5 L/min. Este incremento podría explicarse por la influencia de los artefactos de movimiento asociados con patrones respiratorios irregulares, especialmente tras la fase de hiperventilación, que pudo haber dejado un efecto residual en las mediciones. Adicionalmente, el dispositivo utilizado calcula el gasto cardíaco basándose en los últimos 20 segundos de presión arterial invasiva, lo que podría haber maximizado las discrepancias durante esta breve fase.

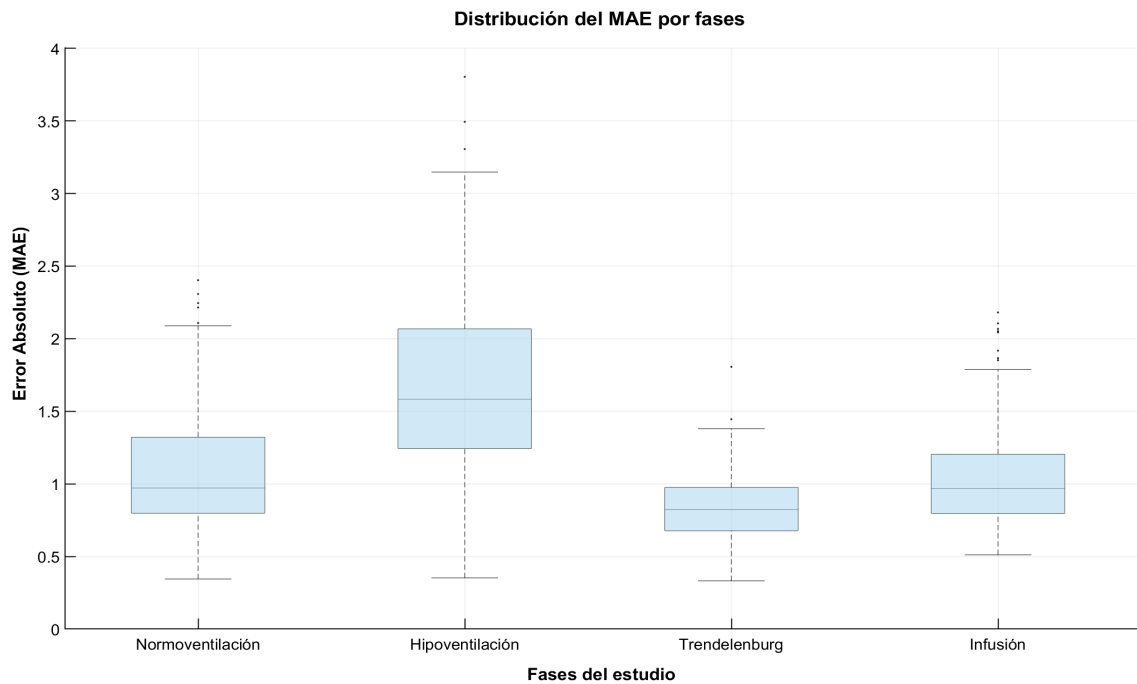


Figure 6.5: Gráfico de cajas del error absoluto medio (MAE) en las diferentes fases del protocolo de estudio

Durante la fase de Trendelenburg, el MAE mostró una disminución significativa, estabilizándose en torno a una mediana de 0.8 L/min. Este descenso podría atribuirse a la postura inclinada, que favorece una redistribución más homogénea del volumen sanguíneo, reduciendo artefactos fisiológicos y facilitando la obtención de mediciones más consistentes.

Por último, en la fase de Infusión, el MAE experimentó un leve incremento en comparación con Trendelenburg, situándose en torno a una mediana de 0.9 L/min. Esta diferencia es mínima respecto a la fase anterior y los valores de error en esta etapa siguen siendo bastante bajos en comparación con el resto, ya que es la fase de la cual más información se ha extraído.

7. Conclusiones

Este estudio presentó un marco técnico que combina procesado avanzado de señales y técnicas de aprendizaje automático para estimar el gasto cardíaco. Se registraron señales de ECG, BCG carotídeo y abdominal, junto con mediciones de gasto cardíaco obtenidas mediante presión arterial invasiva. Las señales adquiridas fueron procesadas utilizando filtros adaptativos y la transformada wavelet, seguidos de una selección de características. Para esta última, se aplicó el método RReliefF con el objetivo de identificar las características más relevantes y optimizar el rendimiento del modelo de aprendizaje automático basado en SVR. Finalmente, el desempeño del modelo se evaluó mediante el MAE en la estimación del gasto cardíaco en situaciones de medicina de emergencia, analizando su efectividad en un contexto clínico real.

El presente estudio documenta, hasta donde sabemos, un paso prometedor hacia una estimación precisa y confiable del gasto cardíaco utilizando señales que pueden registrarse fácilmente en entornos prehospitalarios. Los biosensores de BCG ofrecen varias ventajas: (1) son muy fáciles y rápidos de desplegar; (2) el registro y procesamiento de las señales de BCG podría realizarse tanto en un dispositivo autónomo como integrado en monitores/desfibriladores comerciales con las modificaciones adecuadas de hardware y software; y (3) la estimación del CO sería completamente automatizada, evitando el uso de equipos técnicamente complejos y la necesidad de personal altamente capacitado para obtener lecturas confiables del CO.

En cuanto a la precisión, nuestro modelo mostró un MAE de 0,96 L/min, lo que representa un error relativo de aproximadamente el 14% (considerando un CO promedio de 6,7 L/min). La comunidad médica, y en particular la clínica prehospitalaria, debe alcanzar un consenso sobre la validez y aplicabilidad de un método con este margen de error relativo. Hipotetizamos que, bajo condiciones hemodinámicamente estables, la capacidad de proporcionar mediciones precisas puntuales puede ser determinante. Sin embargo, en pacientes inestables, la capacidad de rastrear cambios en el CO podría ser igualmente, o incluso más, valiosa y crucial.

Además, planteamos la hipótesis de que la precisión del método podría mejorarse en estudios futuros mediante, primero, la incorporación de información no correlacionada extraída de señales de impedancia transtorácica, capnografía y fotopletimografía registradas por monitores/desfibriladores en entornos prehospitalarios, y segundo, utilizando modelos de machine learning más complejos y menos interpretables, como

ensambles de árboles de decisión o redes neuronales artificiales.

En conclusión, presentamos un método basado en machine learning para estimar el CO utilizando únicamente características morfológicas extraídas de biosensores de BCG carotídeo y abdominal en sujetos sanos. Este método puede considerarse como el primer paso hacia un estimador de CO automatizado, no invasivo, fácil de implementar, económico y confiable, especialmente útil en la medicina de emergencias prehospitalarias para guiar la terapia, optimizar el tratamiento y, en última instancia, contribuir a aumentar la tasa de supervivencia.

8. Bibliography

- [1] Fundación Española del Corazón. Parada cardíaca: Ficha informativa, 2025.
- [2] R. F. Roca, R. G. López, E. L. de Sá, and A. A. Solé. Acreditación en la gestión del paro cardíaco en los hospitales españoles: Proyecto capac, 2023.
- [3] Consejo Español de Resucitación Cardiopulmonar. El egcom y cercp echan ‘dos manos’ para ayudar a concienciar sobre la parada cardíaca y salvar vidas, 2021.
- [4] American Heart Association. Reducing disparities for out-of-hospital cardiac arrest: Toolkit. Technical report, American Heart Association, 2021.
- [5] Cardiac Arrest Registry to Enhance Survival (CARES). 2023 annual report, 2023.
- [6] B. Eberle, W.F. Dick, T. Schneider, G. Wisser, S. Doetsch, and I. Tzanova. Checking the carotid pulse check: diagnostic accuracy of first responders in patients with and without a pulse. *Resuscitation*, 33(2):107–116, 1996.
- [7] Moishe Liberman, André Lavoie, David Mulder, and John Sampalis. Cardiopulmonary resuscitation: errors made by pre-hospital emergency medical personnel. *Resuscitation*, 42(1):47–55, 1999.
- [8] M. F. Hazinski, V. M. Nadkarni, R. W. Hickey, R. O’Connor, L. B. Becker, and A. Zaritsky. Major changes in the 2005 aha guidelines for cpr and ecc: reaching the tipping point for change. *Circulation*, 112(24_supplement):IV–206, 2005.
- [9] B. J. Bobrow, L. L. Clark, G. A. Ewy, V. Chikani, A. B. Sanders, R. A. Berg, P. B. Richman, and K. B. Kern. Minimally interrupted cardiac resuscitation by emergency medical services for out-of-hospital cardiac arrest. *JAMA*, 299:1158–1165, 2008.
- [10] M. J. Kellum, K. W. Kennedy, and G. A. Ewy. Cardiocerebral resuscitation improves survival of patients with out-of-hospital cardiac arrest. *American Journal of Medicine*, 119:335–340, 2006.
- [11] T. D. Rea, M. Helbock, S. Perry, M. Garcia, D. Cloyd, L. Becker, and M. Eisenberg. Increasing use of cardiopulmonary resuscitation during out-of-hospital ventricular fibrillation arrest: survival implications of guideline changes. *Circulation*, 114:2760–2765, 2006.

- [12] Monica E. Kleinman, Erin E. Brennan, Zachary D. Goldberger, Robert A. Swor, Mark Terry, Bentley J. Bobrow, Raúl J. Gazmuri, Andrew H. Travers, and Thomas Rea. Part 5: Adult basic life support and cardiopulmonary resuscitation quality: 2015 american heart association guidelines update for cardiopulmonary resuscitation and emergency cardiovascular care. *Circulation*, 132:S414–S435, 2015.
- [13] R. A. Berg, R. Hemphill, B. S. Abella, T. P. Aufderheide, D. M. Cave, M. F. Hazinski, E. B. Lerner, T. D. Rea, M. R. Sayre, and R. A. Swor. Part 5: adult basic life support: 2010 american heart association guidelines for cardiopulmonary resuscitation and emergency cardiovascular care. *Circulation*, 122(18_supplement 3):S685–S705, 2010.
- [14] H. Kwok, J. Coult, J. Blackwood, S. Bhandari, P. Kudenchuk, and T. Rea. Electrocardiogram-based pulse prediction during cardiopulmonary resuscitation. *Resuscitation*, 147:104–111, 2020.
- [15] T. Yagi, K. Nagao, T. Kawamorita, T. Soga, M. Ishii, N. Chiba, K. Watanabe, S. Tani, A. Yoshino, A. Hirayama, and K. Sakatani. Detection of rosc in patients with cardiac arrest during chest compression using nirs: A pilot study. In C. E. Elwell, T. S. Leung, and D. K. Harrison, editors, *Oxygen Transport to Tissue XXXVII (Advances in Experimental Medicine and Biology)*, volume 876. Springer, 2016.
- [16] S. Parnia et al. Cerebral oximetry during cardiac arrest: A multicenter study of neurologic outcomes and survival. *Critical Care Medicine*, 44(9):1663–1674, Sep 2016.
- [17] K. Dellimore, R. Wijshoff, C. Haarburger, V. Aarts, R. Derkx, J. van de Laar, K. Nammi, J. K. Russell, P. Hubner, F. Sterz, and J. Muehlsteff. Towards an algorithm for automatic accelerometer-based pulse presence detection during cardiopulmonary resuscitation. In *Proc. 38th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC)*, pages 3531–3534, Aug. 2016.
- [18] A. Elola, E. Aramendi, U. Irusta, J. Del Ser, E. Alonso, and M. Daya. Ecg-based pulse detection during cardiac arrest using random forest classifier. *Medical Biological Engineering Computing*, 57(2):453–462, Feb 2019.
- [19] A. Elola, E. Aramendi, U. Irusta, A. Picón, E. Alonso, P. Owens, and A. Idris. Deep neural networks for ecg-based pulse detection during out-of-hospital cardiac arrest. *Entropy*, 21(3):305, Mar 2019.

- [20] A. B. Rad, T. Eftestøl, K. Engan, U. Irusta, J. T. Kvaloy, J. Kramer-Johansen, L. Wik, and A. K. Katsaggelos. Ecg-based classification of resuscitation cardiac rhythms for retrospective data analysis. *IEEE Transactions on Biomedical Engineering*, 64(10):2411–2418, Oct 2017.
- [21] H. Losert, M. Risdal, F. Sterz, J. Nysæther, K. Köhler, T. Eftestøl, C. Wandaller, H. Myklebust, T. Uray, S. O. Aase, and A. N. Laggner. Thoracic-impedance changes measured via defibrillator pads can monitor signs of circulation. *Resuscitation*, 73(2):221–228, May 2007.
- [22] N. A. Cromie, J. D. Allen, C. Navarro, C. Turner, J. M. Anderson, and A. A. J. Adgey. Assessment of the impedance cardiogram recorded by an automated external defibrillator during clinical cardiac arrest. *Critical Care Medicine*, 38(2):510–517, Feb 2010.
- [23] M. Risdal, S. O. Aase, J. Kramer-Johansen, and T. Eftestøl. Automatic identification of return of spontaneous circulation during cardiopulmonary resuscitation. *IEEE Trans. Biomed. Eng.*, 55(1):60–68, Jan. 2008.
- [24] J. M. Ruiz, S. Ruiz de Gauna, D. M. González-Otero, P. Saiz, J. J. Gutiérrez, J. F. Veintemillas, J. M. Bastida, and D. Alonso. Circulation assessment by automated external defibrillators during cardiopulmonary resuscitation. *Resuscitation*, 128:158–163, Jul. 2018.
- [25] D. P. Davis, R. E. Sell, N. Wilkes, R. Sarno, R. D. Husa, E. M. Castillo, B. Lawrence, R. Fisher, C. Brainard, and J. V. Dunford. Electrical and mechanical recovery of cardiac function following out-of-hospital cardiac arrest. *Resuscitation*, 84(1):25–30, Jan. 2013.
- [26] A. Elola, E. Aramendi, U. Irusta, E. Alonso, Y. Lu, M. P. Chang, P. Owens, and A. H. Idris. Capnography: A support tool for the detection of return of spontaneous circulation in out-of-hospital cardiac arrest. *Resuscitation*, 142:153–161, Sep. 2019.
- [27] J. Ruiz, E. Alonso, E. Aramendi, J. Kramer-Johansen, T. Eftestøl, U. Ayala, and D. González-Otero. Reliable extraction of the circulation component in the thoracic impedance measured by defibrillation pads. *Resuscitation*, 84(10):1345–1352, 2013.
- [28] E. Alonso, J. Ruiz, E. Aramendi, D. González-Otero, S. R. de Gauna, U. Ayala, and M. Daya. Reliability and accuracy of the thoracic impedance signal for

- measuring cardiopulmonary resuscitation quality metrics. *Resuscitation*, 88:28–34, 2015.
- [29] E. Alonso, E. Aramendi, M. Daya, U. Irusta, B. Chicote, J. K. Russell, and L. G. Tereshchenko. Circulation detection using the electrocardiogram and the thoracic impedance acquired by defibrillation pads. *Resuscitation*, 99:56–62, Feb. 2016.
- [30] A. Elola, E. Aramendi, U. Irusta, P. O. Berve, and L. Wik. Multimodal algorithms for the classification of circulation states during out-of-hospital cardiac arrest. *IEEE Transactions on Biomedical Engineering*, 68(6):1913–1922, 2021.
- [31] E. Alonso, U. Irusta, E. Aramendi, and M. R. Daya. A machine learning framework for pulse detection during out-of-hospital cardiac arrest. *IEEE Access*, 8:161031–161041, 2020.
- [32] L. Mathews and R. K. Singh. Cardiac output monitoring. *Annals of Cardiac Anaesthesia*, 11(1):56–68, 2008.
- [33] S. G. Sakka, D. A. Reuter, and A. Perel. The transpulmonary thermodilution technique. *Journal of Clinical Monitoring and Computing*, 26(5):347–353, 2012.
- [34] J. Poelaert, C. Schmidt, and F. Colardyn. Transoesophageal echocardiography in the critically ill. *Anaesthesia*, 53(1):55–68, 1998.
- [35] M. B. Jaffe. Partial co2 rebreathing cardiac output—operating principles of the nico system. *Journal of Clinical Monitoring and Computing*, 15(6):387–401, 1999.
- [36] I. Starr, A. J. Rawson, and H. A. Schroeder. Apparatus for recording the heart’s recoil and the blood’s impacts in man (ballistocardiograph), experiments on the principles involved, records in normal and abnormal conditions. *The American Journal of Physiology*, 123:195, 1938.
- [37] I. Starr, A. J. Rawson, H. A. Schroeder, and N. R. Joseph. Studies on the estimation of cardiac output in man, and of abnormalities in cardiac function from the heart’s recoil and the blood’s impact; the ballistocardiogram. *The American Journal of Physiology*, 127:1, 1939.
- [38] I. Starr and H. A. Schroeder. Ballistocardiogram. ii. normal standards, abnormalities commonly found in diseases of the heart and circulation, and their significance. *The Journal of Clinical Investigation*, 19(3):437–450, 1940.
- [39] T. Tamura and W. Chen. *Seamless healthcare monitoring*. 2018.

- [40] J. N. Svensøy, E. Alonso, A. Elola, R. Bjørnerheim, J. Ræder, E. Aramendi, and L. Wik. Cardiac output estimation using ballistocardiography: a feasibility study in healthy subjects. *Scientific Reports*, 14(1):1671, 2024.
- [41] M. Robnik-Šikonja and I. Kononenko. An adaptation of relief for attribute estimation in regression. In *Machine Learning: Proceedings of the Fourteenth International Conference (ICML'97)*, volume 5, pages 296–304, July 1997.
- [42] Jerome Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2009.

Lista de Figuras

1.1	Importancia de la RCP precoz y la desfibrilación temprana para mejorar los resultados. Fuente: <i>American Heart Association (2021)</i>	5
1.2	Fuente: <i>Cardiac Arrest Registry to Enhance Survival (CARES). 2023 Annual Report</i>	5
1.3	Fuente: <i>Cardiac Arrest Registry to Enhance Survival (CARES). 2023 Annual Report</i>	6
1.4	Ejemplo de segmentos PEA Y PR. Fuente: <i>Imagen modificada de [?]</i> .	7
2.1	Ejemplos de señal ECG y señal ICC estimada de un segmento PR y un segmento PEA procesados con el esquema adaptativo propuesto en J. Ruiz et al. Fuente: <i>Imagen modeificada de [27]</i>	10
4.1	(a) Sujeto recostado en una camilla. (b) El biosensor BCG, posicionado sobre la piel en la arteria carótida. (c) El transductor FloTrac (d) La línea arterial radial, conectada al sensor y al transductor FloTrac. (e) Las palas de desfibrilación acopladas al monitor LIFEPAK [®] 15, que muestra el ECG (con ondas ECG rojas superpuestas a las ondas BCG azules como ejemplo). (f) El biosensor BCG ubicado sobre la piel en la aorta abdominal. (g) Se puede observar cómo evoluciona la señal a lo largo de cada fasa. Fuente: <i>Imagen modificada de [40]</i>	15
5.1	Descripción general del la metodología	17
5.2	Ejemplo de un segmento de 60 segundos analizado correspondiente a la fase Trendelenburg. De arriba a abajo, se representan el CO, el ECG preprocesado, el CC^c y el CC^a . Los puntos rellenos en azul oscuro en el CC^c y el CC^a representan los máximos de las fluctuaciones causadas por cada latido cardíaco.	18
5.3	Análisis de la señal BCG carotídea reconstruida y sus coeficientes de detalle, en la parte superior muestra la señal reconstruida, mientras que los gráficos inferiores representan los coeficientes de detalle en los niveles 6, 7 y 8 obtenidos mediante descomposición wavelet.	22

5.4	De izquierda a derecha, D_1 , D_2 , D_t , y P_w , respectivamente. Para las tres primeras características t_{on} , t_M , y t_{off} representan los instantes inicial, pico positivo máximo, y final de la fluctuación. Mientras que para P_w , los instantes en los que se alcanzan el 50% de la amplitud en la primera y segunda mitad de la fluctuación vienen dados por t_i y t_f , respectivamente.	23
5.5	De izquierda a derecha, A_2 , a_M y A_1 , respectivamente. Para el caso de A_1 y A_2 mencionados, a_{on} , a_M , y a_{off} representan la amplitud inicio, máximo y final respectivamente.	24
5.6	Características con el área. Los instantes t_{on} , t_M , y t_{off} son los mencionados anteriormente.	24
5.7	Características con la longitud. Los instantes t_{on} , t_M , y t_{off} son los mencionados anteriormente.	24
6.1	Mapa de calor del MAE promedio en función del número de armónicos y el factor de olvido.	31
6.2	MAE en función de las características incluidas en el modelo para los distintos algoritmos de selección de características	33
6.3	MAE en función de las características incluidas en el modelo para los distintos algoritmos de selección de características	35
6.4	Gráfico de Bland-Altman que muestra los valores reales del GC dados por el dispositivo Hemosphere en litros por minuto frente al error calculado como GC real - GC estimado. La línea negra discontinua representa el sesgo mientras que las líneas discontinuas rojas indican el intervalo de acuerdo al 90%.	36
6.5	Gráfico de cajas del error absoluto medio (MAE) en las diferentes fases del protocolo de estudio	37