

Universidad de Alcalá

Escuela Politécnica Superior

Máster Universitario en Ingeniería de Telecomunicación



Trabajo Fin de Máster

Detección automática de apneas del sueño a partir del
electrocardiograma



ESCUELA POLITECNICA
SUPERIOR

Autor: Carlos Alonso Lucea

Tutora: Ana Jiménez Martín

2022

UNIVERSIDAD DE ALCALÁ
ESCUELA POLITÉCNICA SUPERIOR

Máster Universitario en Ingeniería de Telecomunicación

Trabajo Fin de Máster

**Detección automática de apneas del sueño a partir del
electrocardiograma**

Autor: Carlos Alonso Lucea

Tutora: Ana Jiménez Martín

Tribunal:

Presidente: Juan Carlos García

Vocal 1º: Manuel Blanco Velasco

Vocal 2º: Ana Jiménez Martín

Fecha de depósito: 23 de Septiembre de 2022

Índice

I. Resumen	9
II. Abstract	11
III. Palabras clave / Keywords	13
IV. Memoria	15
1. Introducción	17
1.1. Objetivos	18
1.2. Estructura del TFM	19
2. Estado del arte	21
2.1. Apnea del sueño	21
2.2. Monitorización de la respiración	22
2.3. Electrocardiograma	24
2.3.1. Ruidos e interferencias en el ECG	25
2.3.2. Respiración derivada del ECG	28
2.3.3. Algoritmo de detección del complejo QRS	32
2.3.4. Evaluación de la calidad de la señal ECG	35
2.4. Métodos de detección de apneas	39
2.5. Técnicas de fusión de datos	41
3. Algoritmo de detección de apneas	45
3.1. Adecuación del ECG y localización de picos R	46
3.2. Evaluación de la calidad	48
3.3. Estimación del EDR	51
3.4. Identificación de apneas centrales	54

3.4.1.	Análisis frecuencial	54
3.4.2.	Análisis temporal	56
3.5.	Cálculo de certeza	57
3.6.	Fusión de resultados	63
4.	Red neuronal	67
4.1.	Extracción de características	68
4.2.	Estructura de la red neuronal	69
5.	Resultados y discusión	73
5.1.	Base de datos	73
5.2.	Métricas de evaluación	75
5.3.	Procedimiento del análisis del algoritmo de detección	77
5.4.	Resultados del algoritmo de detección	78
5.5.	Procedimiento del análisis de la red neuronal	85
5.6.	Resultados de la red neuronal	88
5.7.	Comparativa entre los dos clasificadores	90
6.	Conclusiones y trabajo futuro	93
6.1.	Conclusiones	93
6.2.	Trabajo futuro	94
V.	Pliego de condiciones	97
A.	Pliego de condiciones generales	97
B.	Pliego de condiciones particulares	97
B.1.	Requisitos de hardware recomendados	97
B.2.	Requisitos de software	98
VI.	Presupuesto	99
A.	Presupuesto de ejecución material	99
A.1.	Mano de obra	99
A.2.	Recursos hardware	99
A.3.	Recursos software	100
B.	Presupuesto de ejecución por contrata	100
C.	Honorarios facultativos	101

D. Presupuesto Total	101
VII Bibliografía	103

Índice de figuras

1	Estructura de la señal ECG. Extraída de [13]	25
2	Comparación entre una señal ECG con y sin interferencia de línea de 50 Hz. (a) Señal ECG con interferencia de línea. (b) Resultado de la señal ECG tras filtrar la interferencia. Extraída de [17]	26
3	Señal ECG afectada por ruido electromiográfico. Extraída de [16]	26
4	Señal ECG afectada por ruido de línea base. Extraída de [16]	27
5	Señal ECG afectada por artefactos de movimiento. Extraída de [19]	27
6	Representación de los valores de los cuatro métodos usados en [20] para la obtención de la señal EDR	29
7	Señal respiratoria original y las obtenidas con los métodos EMD y DWT. Extraída de [24]	30
8	(a) Señales ECG y respiratoria adquiridas simultáneamente. (b) Señales EDR estimadas con diferentes métodos. Extraída de [25]	31
9	Diagrama de bloques del procedimiento de pre-procesado de la señal ECG. Extraída de [32]	33
10	Ejemplo del funcionamiento de la FSM. La línea negra se corresponde con la señal ECG mientras que la roja se corresponde con el valor del umbral. Extraída de [32]	34
11	Comparación de los resultados de la FFT obtenidos de dos tramos diferentes de una señal EDR. Las líneas rojas indican los límites de los rangos de frecuencias elegidos por los autores en los que debe encontrarse la componente de mayor amplitud para clasificar un tramo como respiración normal o apnea. (a) Tramo de respiración normal. (b) Tramo de apnea. Extraída de [42]	39
12	Comparación del análisis frecuencial del EDR de los dos métodos. (a) Resultado de la FFT. (b) Resultado de Lomb-Scargle. Extraída de [43]	40

13	Diagrama de bloques del algoritmo de detección desarrollado en este TFM	46
14	Señal ECG saturada a una amplitud de 1 mV	47
15	Señal ECG saturada (azul) y señal estimada (rojo)	48
16	Comparación de las dos maneras de seleccionar los puntos de corte de una zona de mala calidad. (a) Ejemplo de un tramo de mala calidad de una señal ECG y la ventana (rectángulo rojo) que lo abarca. (b) Resultado de la señal ECG tras realizar el corte en los puntos de inicio y fin de la ventana. El círculo rojo indica el punto donde se ha realizado el corte. (c) Resultado de la señal ECG tras realizar el corte en los puntos medios entre picos R. El círculo rojo indica el punto donde se ha realizado el corte	50
17	Representación de la estimación del área alrededor de un pico R	52
18	Representación de la estimación de la amplitud de un pico R	52
19	Comparación de una señal abdominal (a), una señal EDR estimada mediante el método EDR_área (b) y una señal EDR estimada mediante el método EDR_amp (c)	53
20	Comparación del resultado del periodograma de Lomb-Scargle para una ventana con un episodio de respiración normal (a) y dos con un episodio de apnea (b) (c) según los dos criterios comentados	55
21	Tramo de una señal EDR procesada según D-EDR en el que se ha producido una apnea	57
22	Diagrama de bloques del cálculo de la certeza para cada uno de los resultados obtenidos a través de las distintas técnicas	58
23	Representación de la función del cálculo de certeza para la técnica de identificación de apneas F-EDR	60
24	Arriba la representación de las funciones del cálculo de certeza para la técnica de identificación de apneas D-EDR en los casos en los que se haya identificado una apnea (a) y en los que no (b). Abajo la representación de las mismas funciones para la técnica D2-EDR (c) (d)	62
25	Diagrama de bloques del proceso de fusión de datos según la teoría de DS. Extraído de [49]	63
26	Esquema de la red neuronal Fully Connected	70

27	Proceso de obtención de los parámetros estadísticos para el algoritmo de detección	78
----	--	----

Índice de tablas

1	Resultado de la combinación de dos matrices de masas de probabilidad. Extraída de [49]	64
2	Resultado de la combinación de dos matrices de masas de probabilidad tras aplicar la redistribución de probabilidad de los elementos vacíos. Extraída de [49]	65
3	Información de la base de datos utilizada	75
4	Datos empleados en el análisis del algoritmo de detección con el GT de apneas centrales	78
5	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 50 % y el GT de apneas centrales	79
6	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 75 % y el GT de apneas centrales	80
7	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 90 % y el GT de apneas centrales	81
8	Datos empleados en el análisis del algoritmo de detección con los GT de apneas centrales, obstructivas y mixtas	81
9	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 50 % y el GT de apneas centrales, obstructivas y mixtas	82
10	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 75 % y el GT de apneas centrales, obstructivas y mixtas	83
11	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 90 % y el GT de apneas centrales, obstructivas y mixtas	83
12	Datos empleados en el análisis del algoritmo de detección con los GT de apneas centrales, obstructivas, mixtas e hipopneas	84

13	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 50 % y el GT de apneas centrales, obstructivas, mixtas e hipopneas	84
14	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 75 % y el GT de apneas centrales, obstructivas, mixtas e hipopneas	85
15	Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 90 % y el GT de apneas centrales, obstructivas, mixtas e hipopneas	85
16	Datos empleados en el análisis de las características que se utilizarán para evaluar la red neuronal	86
17	Resultados de las métricas sobre el análisis de todas las características en la red neuronal	87
18	Resultados de las métricas sobre el análisis del desempeño de cada característica en la red neuronal	87
19	Resultados de las métricas sobre el análisis de la red neuronal y el GT de apneas centrales	88
20	Datos empleados en el análisis de la red neuronal con los GT de apneas centrales, obstructivas y mixtas	89
21	Resultados de las métricas sobre el análisis de la red neuronal y el GT de apneas centrales, obstructivas y mixtas	89
22	Datos empleados en el análisis de la red neuronal con los GT de apneas centrales, obstructivas, mixtas e hipopneas	89
23	Resultados de las métricas sobre el análisis de la red neuronal y el GT de apneas centrales, obstructivas, mixtas e hipopneas	90
24	Mano de obra	99
25	Recursos hardware utilizados	99
26	Recursos software utilizados	100
27	Presupuesto de ejecución material	100
28	Importe de ejecución por contrata	100
29	Importe de los honorarios facultativos	101
30	Importe del presupuesto total del proyecto	101

I. Resumen

En este proyecto se desarrollan dos clasificadores para la detección de apneas centrales utilizando la señal ECG de pacientes reales. El primero de ellos utiliza un decisor estadístico basado en la teoría de la evidencia de Dempster-Shafer para fusionar los resultados obtenidos de seis técnicas de identificación de apneas diferentes, a partir de la señal EDR. Los resultados muestran una detección del 82 % con un 63 % de ellas con un nivel de certeza por encima del 90 %. En el segundo, mediante técnicas de *Machine Learning*, con una red neuronal de siete capas, se consiguen resultados del 89 % de detección.

II. Abstract

This project presents two central sleep apnea classifiers models using real ECG signals. The first one uses a statistical decision maker based on the Dempster-Shafer evidence theory to merge the results obtained from 6 different apnea identification techniques, using the EDR signal. The results show a 82% detection with 63% of them above a 90% certainty level. In the second one, using *Machine Learning* techniques, with a 7-layer neural network, 89% detection results are achieved.

III. Palabras clave / Keywords

Apnea del sueño, Electrocardiograma, Señal EDR, Dempster-Shafer, Red neuronal,
Fusión de datos

Sleep apnea, Electrocardiogram, EDR signal, Dempster-Shafer, Neural network, Data
fusion

IV. Memoria

1. Introducción

La tecnología se ha convertido en una parte imprescindible en la sociedad actual y está en constante evolución. Los avances tecnológicos han revolucionado nuestra forma de vida desde los aspectos más triviales de nuestro día a día hasta necesidades vitales. El desarrollo de la tecnología responde muchas veces a las necesidades que surgen en otros campos de aplicación como el de la medicina donde históricamente se ha buscado siempre mejorar nuestra calidad de vida y aumentar la esperanza de vida.

En los últimos años, la explosión de las Tecnologías de la Información y la Comunicación (TIC) debida principalmente al aumento en la accesibilidad y capacidad de procesamiento de los ordenadores personales y la rápida expansión de Internet ha permitido a los profesionales en medicina el acceso a una cantidad cada vez mayor de datos relacionados con las ciencias de la salud y una mejor comunicación con los pacientes. Gracias a esto se han desarrollado servicios como los de teleasistencia, telemedicina y telerehabilitación que permiten al paciente en muchos casos evitar desplazamientos, ahorrar tiempo, costes y a su vez proporcionar al profesional un seguimiento diario del paciente. Por otro lado, disponer de una amplia base de datos médicos sobre multitud de pacientes puede ser muy útil para el diagnóstico de multitud de enfermedades y problemas de salud pero para ello es vital que los datos sean adquiridos e interpretados correctamente.

Una de las patologías más frecuentes a día de hoy son los trastornos del sueño. Uno de los más graves es la apnea del sueño que puede causar un deterioro en la calidad de vida, enfermedades cardiovasculares, cerebrovasculares e incluso se le ha relacionado con un aumento de mortalidad. A pesar de ello, la gran mayoría de la gente que los sufre lo desconocen dado que se producen mientras duermen y no son capaces de identificar el problema.

La prueba de referencia a día de hoy es la polisomnografía (PSG), que consiste en el registro simultáneo del electroencefalograma (EEG), el electrooculograma (EOG), el

electromiograma (EMG) de los músculos submentonianos, el electrocardiograma (ECG) y la respiración. Según el tipo de trastorno que presente el enfermo, se pueden monitorizar además otros parámetros: temperatura rectal, tensión arterial, movimientos de las extremidades, gases sanguíneos, presión endoesofágica, erección peneana y reacción electrodérmica. Aunque se trata de una prueba indolora y de riesgos mínimos, es compleja, cara y requiere que el paciente se desplace durante toda una noche hasta una Unidad del Sueño. Por ello desde hace algunos años se están buscando métodos alternativos para el diagnóstico de la apnea del sueño menos agresivos y más accesibles para el paciente. Una de las alternativas más común en la literatura es a través del estudio el ritmo cardíaco, debido a que se trata de una medida rutinaria y relativamente fácil de obtener. El principal objetivo de este Trabajo Fin de Máster es el análisis de la señal ECG para extraer la máxima información posible como ayuda al diagnóstico de trastornos del sueño.

1.1. Objetivos

El presente trabajo persigue desarrollar algoritmos que permitan identificar episodios de apneas a partir de la señal de ECG como herramienta de ayuda al diagnóstico en los trastornos del sueño. Para ello es necesario disponer de señales ECG anotadas por expertos por lo que para este trabajo se van a utilizar señales reales cedidas por el Hospital Universitario de Guadalajara.

Para conseguir dicho objetivo, se proponen dos modelos de clasificación de apneas basados en el estudio de la señal ECG. El primero de ellos, denominado algoritmo de detección, se ha implementado a partir de un trabajo previo ya desarrollado sobre la detección de apneas dentro del grupo GEINTRA. En este algoritmo se utilizan varias técnicas de detección de apnea aplicadas sobre dos señales EDR estimadas a partir de los picos R de la señal ECG. Los resultados obtenidos se fusionan mediante un decisor estadístico basado en la teoría de la evidencia de Dempster-Shafer para determinar el nivel de certeza final de apnea.

El segundo modelo, desarrollado íntegramente en este trabajo, está basado en una de las técnicas de *Machine Learning* más empleados hoy en día como es una red neuronal. Este tipo de algoritmos destacan debido a su utilidad para manejar y analizar grandes cantidades de datos y su capacidad de ir aprendiendo con el tiempo y tomar decisiones

inteligentes basadas en los resultados obtenidos. La red utilizada está formada por 7 capas y utiliza como datos de entrada diferentes características extraídas a partir de un análisis de la señal ECG.

1.2. Estructura del TFM

La estructura seguida a lo largo de este documento es la siguiente:

- **Capítulo 1.- Introducción:** en este primer capítulo se hace una breve introducción sobre el contexto donde se desarrolla este trabajo y los objetivos del mismo
- **Capítulo 2.- Estado del arte:** este capítulo trata de manera teórica los aspectos más relevantes del proyecto. Se recoge información sobre la apnea del sueño, métodos de identificación de la misma, la señal ECG y señales derivadas de ella, algoritmos de detección de complejos QRS y técnicas de fusión de datos
- **Capítulo 3.- Algoritmo de detección de apneas:** en este capítulo se describen todas las etapas que forman el primero de los clasificadores utilizados para la detección de apneas centrales
- **Capítulo 4.- Red neuronal:** en este capítulo se define el segundo clasificador basado en una red neuronal. Se describe la estructura de la red y las técnicas empleadas para la extracción de características de la señal ECG
- **Capítulo 5.- Resultados y discusión:** este apartado recoge los resultados obtenidos de los dos clasificadores desarrollados. Tras analizar los resultados de cada uno se realiza una comparación final entre ellos
- **Capítulo 6.- Conclusiones y trabajo futuro:** en el último capítulo se comentan las conclusiones recogidas durante el desarrollo del trabajo y las posibles mejoras que se podrían implementar en él

2. Estado del arte

En este capítulo se van a comentar los aspectos teóricos relativos a este TFM. Se van a introducir y definir los elementos más importantes del trabajo como son la apnea del sueño y la señal de Electrocardiograma (ECG) de la que se hablará de sus características, posibles interferencias y señales derivadas a partir de ella. También se van a definir diferentes procedimientos empleados a lo largo del proyecto como la localización de los complejos QRS de la señal de ECG, la identificación de apneas a partir de ella o la fusión de datos. Además, se llevará a cabo un estudio sobre las técnicas más utilizadas para llevar a cabo estos procedimientos a día de hoy en la literatura.

2.1. Apnea del sueño

El Grupo Español del Sueño, en el que participan una veintena de sociedades científicas y colectivos sociales, elaboró en 2005 por primera vez en España un consenso nacional sobre el síndrome de apneas-hipopneas del sueño (SAHS). En él, definen este síndrome como un trastorno potencialmente grave que consiste en la aparición de episodios recurrentes de limitación del flujo de aire durante el sueño como consecuencia de una alteración anatómico-funcional en la vía aérea superior (VAS) y que provoca descensos de la saturación de oxihemoglobina (SaO_2) y microdespertares [1]. El SAHS causa hipertensión arterial y produce un aumento del riesgo de enfermedades cardiovasculares además de un deterioro de la calidad de vida, accidentes y exceso de mortalidad [2]. En 2002 un estudio llevado a cabo por Young et al. [3] reveló que el SAHS puede llegar a afectar a un 25% de hombres y un 11% de mujeres en edad adulta. Además, hay un incremento significativo de la prevalencia con la edad, lo que hace que se espere que el número de personas afectadas en el futuro sea mucho mayor [4].

Históricamente, no ha habido un consenso a la hora de definir los criterios para

clasificar un evento respiratorio como apnea o hipopnea, especialmente en el caso de las hipopneas. Las definiciones más utilizadas a día de hoy son las que recomienda la Academia Estadounidense de Medicina del Sueño (AASM) en su *Manual for the Scoring of Sleep and Associated Events* [5] publicado en el año 2007 y son las que se seguirán en este trabajo. Para el caso de la apnea, los criterios que definen que se deben cumplir es que se produzca una ausencia total o casi completa del flujo de aire (más de un 90 %) y que su duración sea de al menos 10 segundos. Por otro lado, la definición de hipopnea que recomiendan es la de una reducción de al menos un 30 % del flujo respiratorio durante al menos 10 segundos acompañada de una desaturación igual o superior al 3 % y/o de un microdespertar en el electroencefalograma (EEG). Sin embargo, también consideran aceptable como definición de hipopnea una reducción de al menos un 30 % del flujo respiratorio durante al menos 10 segundos acompañada de una desaturación igual o superior al 4 % [1]. Existen además tres tipos de apnea o hipopnea en función de la causa de la reducción del flujo de aire:

- **Obstruktiva:** es el tipo más común de apnea/hipopnea y se produce debido a un bloqueo u obstrucción en la VAS. Dicho bloqueo puede deberse a una excesiva relajación de los músculos de la boca o garganta, el peso del cuello, amigdalitis o motivos estructurales como la forma de la nariz, el cuello o la mandíbula. Se produce un esfuerzo respiratorio detectado por las bandas torácica abdominal [6]
- **Central:** en este caso la VAS está abierta pero no se realiza el esfuerzo de respirar debido a que el cerebro no comunica la orden. Las causas pueden ser una insuficiencia cardíaca o una enfermedad o lesión en el cerebro como por ejemplo un accidente cerebrovascular, un tumor cerebral, una infección cerebral viral, una enfermedad respiratoria crónica o enfermedades neurológicas. No se produce esfuerzo respiratorio [6]
- **Mixta:** es una combinación de las dos anteriores. Suele empezar con un componente central y terminar con uno obstructivo [6]

2.2. Monitorización de la respiración

Las apneas están relacionadas con la ausencia de flujo de aire que recibe el cuerpo. Por tanto, para tratar de identificarlas lo más intuitivo es estudiar la tasa respiratoria del

paciente. Esta tasa se define como el número de respiraciones en un intervalo de tiempo, generalmente un minuto, y ayuda en el diagnóstico de enfermedades respiratorias. A continuación se definen las técnicas más utilizadas para estimar la tasa respiratoria.

- **Parámetros del aire respiratorio:** se basan en que los parámetros del aire son distintos según si se recibe o expulsa durante los procesos de inspiración y espiración. Estiman la tasa respiratoria a partir de conocer cuándo se producen dichos procesos y para ello se utilizan sensores de distintos tipos capaces de medir el volumen del aire, su temperatura, humedad, niveles de CO₂ o los sonidos que provoca [7]
- **Pulsioximetría:** se trata de una prueba no invasiva que mide la saturación de oxígeno en la sangre (SpO₂) utilizando un pulsioxímetro. Para llevar a cabo la prueba el pulsioxímetro debe colocarse en una parte del cuerpo que sea translúcida y tenga un buen flujo sanguíneo: dedos, tanto de la mano como del pie o en el lóbulo de la oreja. El pulsioxímetro emite luces con longitudes de onda roja e infrarroja que pasan secuencialmente desde un emisor hasta un fotodetector a través del paciente. El SpO₂ se obtiene midiendo la capacidad de absorción de cada longitud de onda causada por la sangre arterial, excluyendo sangre venosa, piel, huesos, músculo y grasa [8]. Leonard et al [9] desarrollan en su trabajo una técnica para estimar la tasa respiratoria mediante transformadas Wavelet aplicadas a los resultados obtenidos de pulsioximetrías
- **Pletismografía inductiva respiratoria:** es una prueba no invasiva que permite estimar la tasa respiratoria a partir de los movimientos abdominales o torácicos del cuerpo recogidos por dos bandas elásticas colocadas en el tórax y abdomen. Tiene el inconveniente que requiere de material muy específico y personal cualificado [10]
- **Actividad cardíaca:** se basan en el hecho de que la respiración tiene efectos directos sobre la frecuencia cardíaca del paciente por lo que se puede monitorizar la respiración a partir de ella. Los métodos más utilizados para extraer dicha frecuencia son utilizando una señal ECG o una fotopletismografía (PPG) [7]

Para este trabajo se ha decidido utilizar la prueba ECG para estimar la tasa respiratoria debido a la facilidad de su realización y a las ventajas que ofrece frente a otras pruebas como se verá en el siguiente capítulo.

2.3. Electrocardiograma

El ECG es una prueba médica no invasiva que registra la actividad eléctrica del corazón, es decir, los cambios que ocurren en las pequeñas corrientes eléctricas producidas con cada latido. Se realiza comúnmente con el objetivo de diagnosticar y controlar diferentes enfermedades relacionadas con el corazón como la arritmia, obstrucción de las arterias o infarto de miocardio. El ECG suele ser el primer estudio realizado a un paciente en el que se sospecha de alguna patología cardíaca debido a que, a diferencia de otras técnicas, se trata de una prueba inofensiva, indolora, relativamente barata, disponible en todo el mundo y con capacidad de realizarse de manera portátil lo que lo convierte en un método de diagnóstico muy atractivo [11].

Las corrientes eléctricas del corazón son registradas por varios electrodos colocados en distintos puntos del paciente. La prueba ECG más habitual es la de 12 derivaciones en la que se utilizan 10 electrodos. Una derivación se define como el registro de la diferencia de potencial eléctrico entre dos puntos, ya sean dos electrodos o un punto virtual y un electrodo. Cada una de estas derivaciones proporciona un punto de vista diferente del mismo estímulo eléctrico [12].

El resultado de la prueba es una señal ECG cuasiperiódica formada por varias ondas que representan acciones producidas por el corazón. En la figura 1 se puede ver un periodo de la señal obtenida de la derivación 2 definida como la diferencia de potencial los electrodos colocados en el hombro derecho y pierna izquierda. Las ondas que aparecen en dicha figura son las que se definen a continuación.

- **Onda P:** despolarización de las aurículas. Su duración es inferior a 0.12 s y su amplitud es de 0.25 mV como máximo
- **Complejo QRS:** formado por las ondas Q, R y S, describe la despolarización de los ventrículos y suele utilizarse como punto de referencia en diferentes análisis de la señal ECG. Su duración oscila entre 0.07 - 0.10 s y la amplitud de la onda R es mucho mayor que la del resto en el rango de 2.5 - 3 mV
- **Onda T:** repolarización ventricular. Tiene una duración de 0.10 - 0.25 s y una amplitud inferior a 0.5 mV

- **Onda U:** no se conoce con certeza que representa. Su amplitud es aproximadamente $1/3$ de la amplitud de la onda T y no siempre aparece

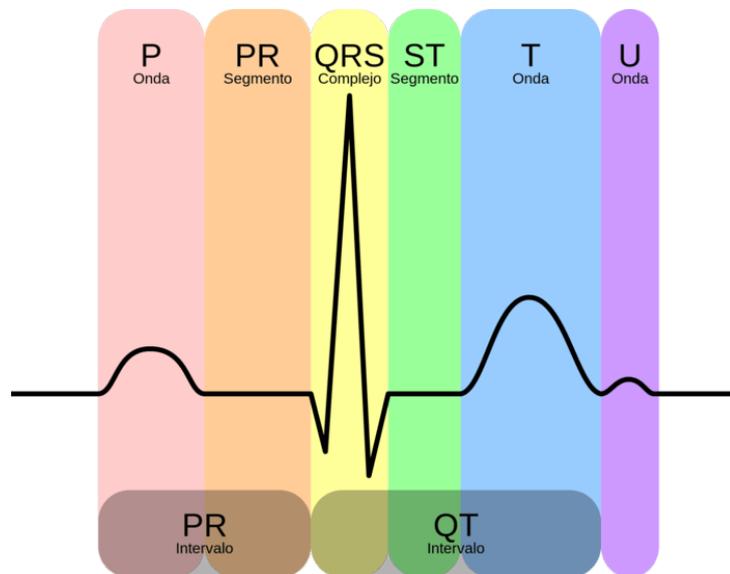


Figura 1: Estructura de la señal ECG. Extraída de [13]

Desde un punto de vista médico, las ondas P y T así como el complejo QRS ofrecen información relevante del paciente y existe una gran variedad de estudios que utilizan esta información para el diagnóstico de enfermedades. Sin embargo, dada la variabilidad de la señal ECG según el paciente, además de los ruidos que puedan introducirse en la señal, la detección e identificación de estas ondas se vuelve complicada.

2.3.1. Ruidos e interferencias en el ECG

Durante la adquisición de la señal ECG, ésta puede verse afectada por varios tipos de ruidos o interferencias provenientes de distintas fuentes lo que puede provocar una pérdida importante de la calidad de la señal y dificultar la extracción de información de la misma. Algunos de los más comunes son:

- **Interferencia de línea de potencia:** provocada por la red eléctrica, consiste en una señal de 50 Hz, en el caso de la red europea, o de 60 Hz, en el caso de la americana, y sus armónicos los cuales pueden modelarse como sinusoides o combinación de sinusoides [14] [15]. Dado que se conoce la frecuencia de la señal interferente, para eliminarla lo más habitual es utilizar un filtro Notch a dicha frecuencia [16]. En la

figura 2 puede verse un tramo de una señal ECG afectada por esta interferencia y el resultado obtenido tras eliminarla

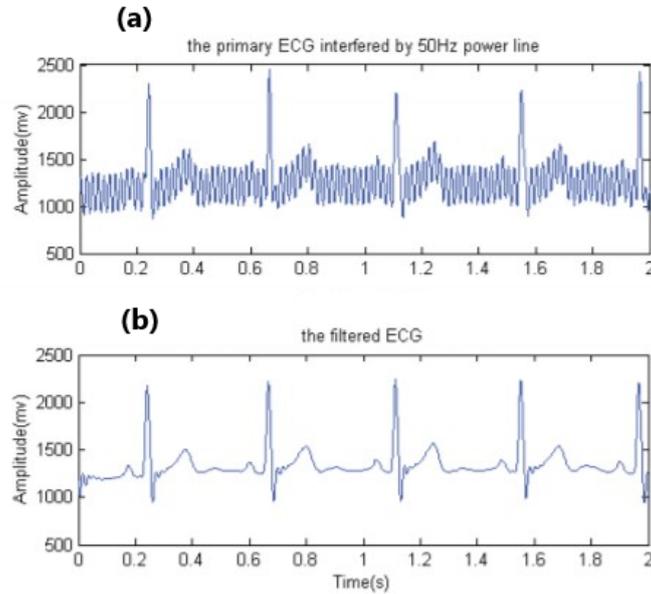


Figura 2: Comparación entre una señal ECG con y sin interferencia de línea de 50 Hz. (a) Señal ECG con interferencia de línea. (b) Resultado de la señal ECG tras filtrar la interferencia.

Extraída de [17]

- **Ruido electromiográfico (EMG):** las contracciones musculares producen señales eléctricas con frecuencia máxima de 10 kHz y una amplitud del orden de microvoltios que se superponen con la señal ECG [14] [15] [16]. No es fácil filtrar este tipo de ruido sin afectar a la señal ECG por lo que la mejor solución es evitar los tramos donde aparezca. En la figura 3 aparece una señal ECG con ruido EMG

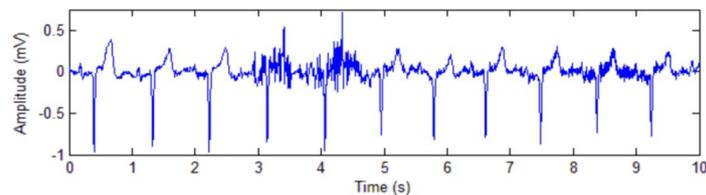


Figura 3: Señal ECG afectada por ruido electromiográfico. Extraída de [16]

- **Ruido de línea base (Baseline Wander):** se trata de una componente de baja frecuencia que aparece en la señal ECG debido a movimientos del paciente. Puede representarse como una componente sinusoidal y suele tener una amplitud en el

rango de los microvoltios y se puede eliminar mediante un filtro paso alto [14] [15] [16]. En la figura 4 se ve el efecto que provoca este ruido sobre una señal ECG

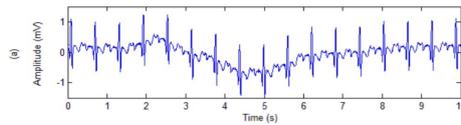


Figura 4: Señal ECG afectada por ruido de línea base. Extraída de [16]

- **Contacto de electrodos:** ruido debido a la pérdida de contacto entre los electrodos y la piel que puede producirse durante la prueba. Esta pérdida de contacto puede ser permanente o intermitente a causa de un electrodo mal fijado o por movimientos del paciente. Se puede modelar como una transición rápida de gran amplitud de la línea base que posteriormente vuelve de manera exponencial a su valor original [14] [15]
- **Artefactos de movimiento (Motion Artifacts):** transiciones de la línea base de la señal ECG que se producen debido a cambios en la impedancia entre los electrodos y la piel [14] [15]. Tienen una amplitud y duración variable y son muy difíciles de eliminar debido a que su espectro se superpone con el de componentes importantes la señal ECG. Se suele utilizar un filtro paso alto para tratar de reducir su impacto aunque esto puede provocar que la señal ECG se distorsione [18]. En la figura 5 se puede ver un ejemplo de la transición que provoca este tipo de interferencia

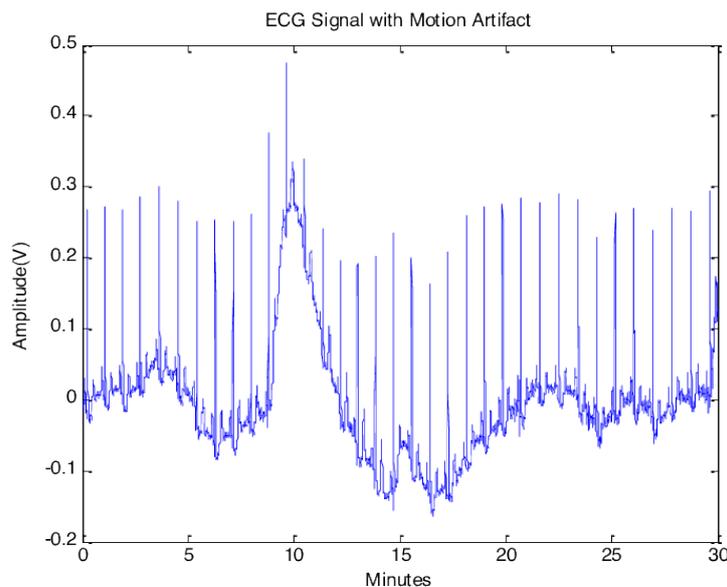


Figura 5: Señal ECG afectada por artefactos de movimiento. Extraída de [19]

Hoy en día, la mayoría de los equipos con los que se realiza el ECG cuentan con etapas de pre-procesado encargadas de eliminar el ruido que pueda acoplarse a la señal. Sin embargo, algunos de estos ruidos son difíciles de eliminar y junto con los tramos en los que se produzca una pérdida de la señal van a provocar una degradación en la calidad de la señal ECG que impedirá la realización de un correcto diagnóstico. Es por ello que será necesario evaluar la calidad de la señal con el objetivo de eliminar aquellos tramos que no cumplan un requisito mínimo de calidad.

2.3.2. Respiración derivada del ECG

Aparte de las ventajas ya comentadas al comienzo del apartado 2.3 que ofrece la señal ECG frente a otras técnicas utilizadas en cardiología, es una señal muy utilizada en diferentes estudios debido a la información que proporciona sobre multitud de parámetros relacionados con el estado de salud del paciente además de ser rápida, económica y puede ser obtenida con equipos portables, lo que la hace más popular frente a otras. Uno de estos parámetros es el esfuerzo respiratorio o movimiento de la caja torácica que se ve reflejado en la señal *ECG-Derived Respiration* (EDR). Esta señal afecta a la amplitud del ECG en las frecuencias equivalentes a la frecuencia de la respiración, que está en torno a los 0.2-0.33 Hz de media en adultos sanos (de 12 a 20 respiraciones por minuto). Sin embargo, el proceso de extracción de esta señal respiratoria no es sencillo puesto que la señal ECG se ve influenciada por multitud de ruidos e interferencias como ya se ha visto.

Existen en la literatura numerosas técnicas de obtención de la EDR, siendo las más utilizadas dada su fácil implementación, las basadas en la extracción de características de la señal ECG, como las propuestas por Solà-Soler et al. en su trabajo [20]. En él se analizan cuatro métodos para estimar la señal EDR a partir de los complejos QRS. Cada complejo QRS proporciona un valor que se corresponderá con una muestra de la señal EDR estimada. En el primer método (Up Slope), la señal se construye con los valores de las pendientes formadas entre los picos de las ondas Q y R. El segundo método (Down Slope) es similar al primero pero se utilizan los valores de las pendientes entre las ondas R y S. El tercer método (Angle) utiliza el valor del ángulo de cada onda R, obtenido a partir de la intersección de las dos pendientes comentadas en los métodos 1 y 2. En el cuarto método (Area), se calcula el área bajo cada complejo QRS tomando como base del área encerrada la línea que une los picos de las ondas Q y S. En la figura 6 podemos ver

un ejemplo de los valores utilizados en los cuatro métodos mencionados.

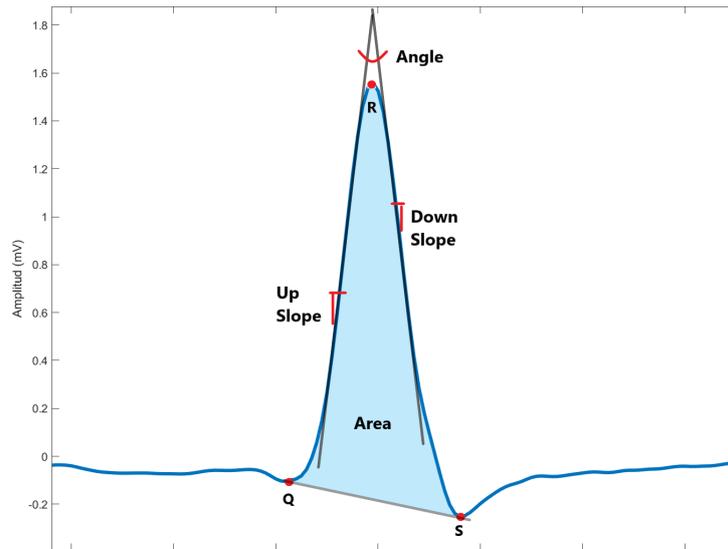


Figura 6: Representación de los valores de los cuatro métodos usados en [20] para la obtención de la señal EDR

O'Brien et al. utilizan en [21] dos métodos para estimar la señal respiratoria utilizando características relacionadas con la amplitud de la señal ECG. En el primer método toman directamente los valores de amplitud de las ondas R para formar la señal EDR. En el segundo toman el valor medio de las muestras de la señal ECG en una ventana de 20 ms alrededor de cada onda R.

Otras técnicas más complejas se basan en la utilización de diferentes filtros o transformadas. La más habitual es filtrar la señal ECG con un filtro paso banda de frecuencias de corte similares al rango de la frecuencia de la respiración, obteniéndose a la salida una estimación de la EDR. Boyle et al. comparan en [22] varios métodos de estimación de la EDR entre los que se incluyen dos filtros paso banda con frecuencias de corte de 0.2-0.4 Hz y 0.2-0.8 Hz, los rangos más habituales, y concluyen que el filtrado con el rango de 0.2-0.8 Hz proporciona mejores resultados. También analizan en su trabajo un método muy utilizado en la literatura y que se basa en la transformada discreta de Wavelet (DWT). Al aplicar la DWT a la señal ECG ésta se descompone en dos señales, una que se conoce como señal detallada la cual representa la mitad superior de las componentes frecuenciales, y otra conocida como señal de aproximación que representa la otra mitad. El proceso se repite aplicando la transformada sobre la señal de aproximación hasta la novena descomposición, que representa la banda de frecuencia de 0.2-0.4 Hz. La señal

respiratoria se corresponde con la señal detallada obtenida como resultado de esa novena descomposición.

Una técnica similar a la de la DWT es utilizar un algoritmo EMD (Empirical Mode Decomposition). Está basado en la transformada de Hilbert-Huang (HHT) y fue propuesto inicialmente por Huang et al. [23]. Este algoritmo permite descomponer una señal en una función de modo intrínseco (IMF), correspondiente a la parte de alta frecuencia, y una señal residual que se corresponde con la bajas frecuencias. El proceso se realiza de nuevo sobre la señal residual obteniéndose una nueva IMF y una nueva señal residual. Con cada iteración del algoritmo la frecuencia de la IMF obtenida es menor, por tanto para estimar la señal respiratoria, éste se aplica hasta obtener una IMF cuya frecuencia esté en un rango similar al de la respiración.

Labate et al. comparan en [24] el rendimiento de las técnicas que utilizan la DWT frente a las que usan el EMD. Como resultado concluyen que aunque ambas técnicas son capaces de extraer una señal respiratoria fiable, la señal obtenida mediante EMD se asemeja más a la propia señal respiratoria. En la figura 7 se muestra la señal respiratoria original y las obtenidas con los métodos de EMD y WDT y visualmente se puede comprobar como la obtenida por EMD se parece más a la original.

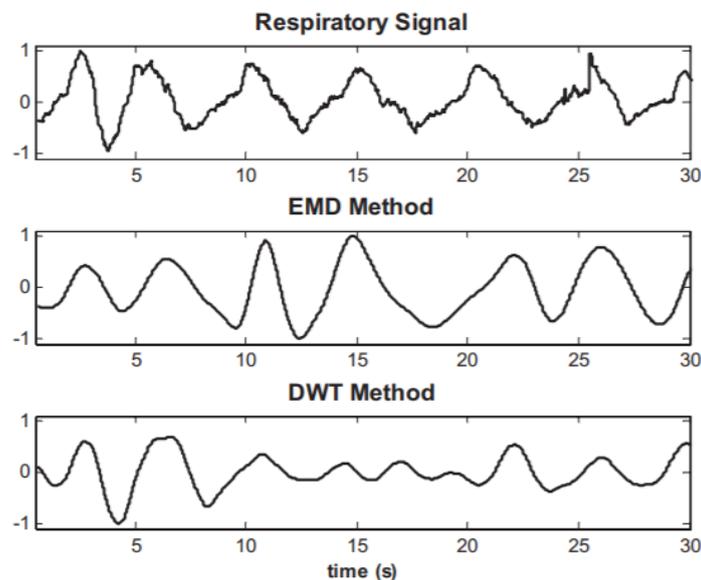


Figura 7: Señal respiratoria original y las obtenidas con los métodos EMD y DWT. Extraída de [24]

Sin embargo, algunos estudios revelan que el rendimiento de las técnicas basadas en

EMD baja en presencia de ruido. Una alternativa a estas técnicas es la utilización del algoritmo VMD (Variational Mode Decomposition) que es más robusto frente al ruido aunque supone un aumento de la carga computacional. Nazari et al. analizan esto en [25] donde comparan diferentes técnicas y proponen una variación del algoritmo VMD a la que denominan VME (Variational Mode Extraction). Concluyen que con su algoritmo propuesto los resultados son ligeramente superiores a los del algoritmo VMD mientras que la carga computacional es 40 veces inferior. En la figura 8 se ven los resultados de las diferentes técnicas analizadas en este estudio.

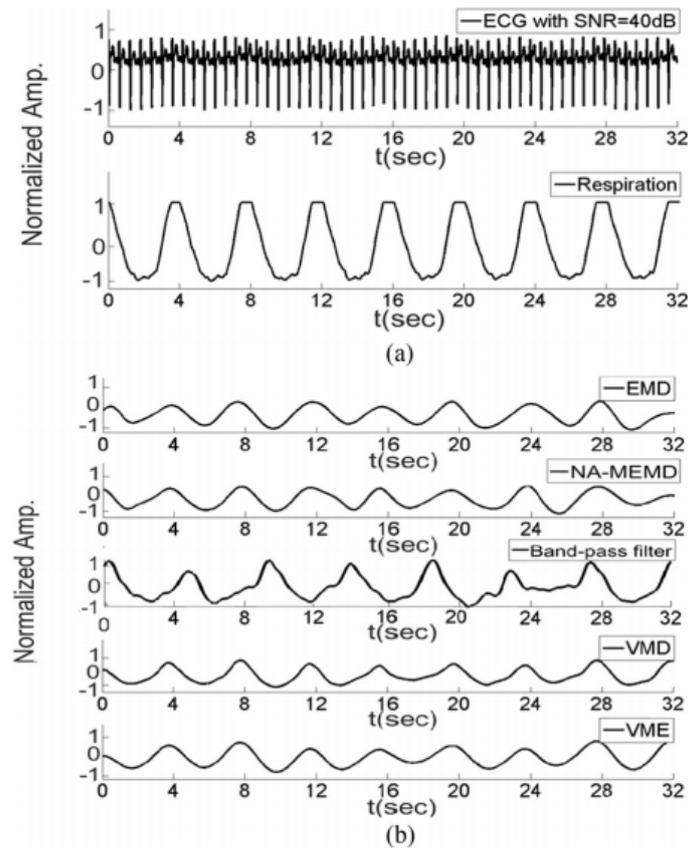


Figura 8: (a) Señales ECG y respiratoria adquiridas simultáneamente. (b) Señales EDR estimadas con diferentes métodos. Extraída de [25]

Charlton et al. recogen en [26] la mayoría de las técnicas utilizadas en la literatura hoy en día sobre la estimación de la señal respiratoria a partir de las señales de ECG y PPG. Además, comentan la opción de fusionar las señales obtenidas de diferentes técnicas para conseguir una mejor señal resultante.

En este trabajo se van a utilizar dos técnicas basadas en la extracción de características de la señal ECG dada su fácil implementación y buenos resultados que ofrece. En la

primera se estimará la señal EDR a partir de la amplitud de las ondas R, y en la segunda a partir del área alrededor de las mismas. Dado que las dos técnicas implementadas para la estimación de la señal EDR se basan exclusivamente en características de las ondas R, es necesario realizar primero una etapa de identificación y localización de los picos de dichas ondas.

2.3.3. Algoritmo de detección del complejo QRS

Los complejos QRS son la parte más significativa de la señal ECG debido a que son la componente de mayor amplitud y más distintiva. Esto hace que sea la parte más fácilmente detectable de la señal y suelen utilizarse como punto de referencia en muchos estudios por lo que existen una gran variedad de algoritmos de detección de complejos QRS en la literatura.

El más utilizado y que se ha convertido en un referente es el algoritmo de Pan-Tompkins desarrollado por J. Pan y W. J. Tompkins [27] en 1985 y basado en la utilización de una ventana móvil con dos umbrales adaptativos. Antes de llevar a cabo el proceso de detección se realiza un pre-procesado de la señal ECG formado por tres etapas. La primera es un filtro paso banda formado por un filtro paso bajo y uno paso alto en cascada que permiten eliminar en gran medida las frecuencias asociadas a la interferencia de línea de potencia y el ruido de línea base. A continuación se lleva a cabo una etapa de derivación con el objetivo de realzar las transiciones rápidas de la señal. Estas transiciones se corresponden con las pendientes de las ondas R puesto que son las más pronunciadas. En la última etapa se eleva al cuadrado la señal provocando que todas sus muestras sean positivas y se enfatizan los complejos QRS. Para la detección de picos R se va recorriendo la señal mediante una ventana con dos umbrales dinámicos, uno para la identificación de los picos R y el otro para filtrar los posibles picos provocados por el ruido. Cuando se localiza un pico, se actualizan los valores de los dos umbrales en función de si se trata de un pico R o un pico de ruido.

Las técnicas de detección más utilizadas que no se emplean el algoritmo de Pan-Tompkins son las basadas en la transformada Wavelet (WT). Li et al. [28] propusieron por primera vez en 1995 la utilización de este tipo de transformada para identificar características de la señal ECG. Este algoritmo emplea la transformada diádica de Wavelet (DYWT) para localizar las variaciones más bruscas del ECG, que se corresponden con

los complejos QRS y las ondas P y T. Estas variaciones van a ser los resultados de la transformada a diferentes escalas que superen un umbral dinámico definido inicialmente durante una etapa de pre-procesado.

A raíz de este estudio, muchos autores han desarrollado otros algoritmos basados en la WT. Zidelmal et al. [29] utiliza la DWT para localizar los complejos QRS. Se basan en que la mayor parte de la energía de la señal ECG se concentra en dichos complejos, y esa energía se encuentra en el rango de frecuencias de 5-22 Hz. Por tanto, aplican en su estudio la DWT a la señal ECG hasta la quinta descomposición que se corresponde con el rango de frecuencias comentado. Wee et al. [30] aplican la transformada en su forma continua (CWT) a diferentes escalas y definen un pico en la señal ECG cuando se producen un par de máximo/mínimo consecutivos en los resultados de las transformadas.

Sin embargo, el estado del arte más actual al respecto se centra en las redes neuronales dado que ofrecen mayor robustez frente a los ruidos típicos de la señal ECG aunque requieren de una mayor carga computacional. Laitala et al. [31] han desarrollado recientemente un detector basado en una red neuronal con arquitectura de memoria a corto y largo plazo (LSTM) consiguiendo resultados superiores a los que obtienen utilizando algoritmos tradicionales.

Para este trabajo se utilizará una técnica desarrollada por Gutiérrez-Rivas et al. [32] basada en el algoritmo de Pan-Tompkins y que emplea un único umbral dinámico el cual se actualiza mediante una máquina de estados finita (FSM). El pre-procesado de la señal ECG sigue un procedimiento similar al del algoritmo de Pan-Tompkins. Comienza con una etapa de derivación que reduce el ruido de baja frecuencia. A continuación se lleva a cabo una integración de la señal, que actúa como un filtro paso bajo, para eliminar las interferencias de alta frecuencia. Por último se elevan todas las muestras de la señal al cuadrado para enfatizar las ondas R. En la figura 9 puede verse el diagrama de bloques de las tres etapas de pre-procesado.

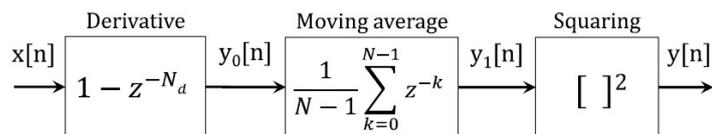


Figura 9: Diagrama de bloques del procedimiento de pre-procesado de la señal ECG. Extraída de [32]

La FSM está formada por tres estados que se definen a continuación:

- **Estado 1 (Localización del pico máximo):** se busca el pico máximo de la señal en un intervalo igual a la suma de la duración mínima de un intervalo entre ondas R (definido por ellos como $RR_{min} = 200$ ms) más la duración estándar de un complejo QRS (típicamente 60 ms). La muestra de la señal ECG correspondiente al máximo localizado se clasifica como pico R y se fija como valor del umbral la media de las amplitudes de todos los picos R clasificados hasta el momento. Una vez recorrido todo el intervalo se pasa al estado 2
- **Estado 2 (Espera):** la FSM espera un tiempo igual a la diferencia entre la duración de RR_{min} y la duración del intervalo entre la posición en la que se localizó en último pico R y el final del estado 1. La finalidad de este estado es evitar falsos positivos como podría ser clasificar una onda T como pico R
- **Estado 3 (Reducción del valor del umbral):** se decrementa el valor de umbral t_h con cada muestra n de la señal ECG según la ecuación 1.

$$t_h[n] = t_h[n - 1] \cdot e^{-\frac{P_{Th}}{f_s}} \quad (1)$$

Donde el valor del parámetro P_{Th} se estima a partir de la frecuencia de muestreo f_s . Cuando el valor de la señal ECG es superior al valor del umbral en la misma muestra se cambia al estado 1 de nuevo

En la figura 10 se puede ver un ejemplo del funcionamiento de la FSM sobre un tramo de una señal ECG.

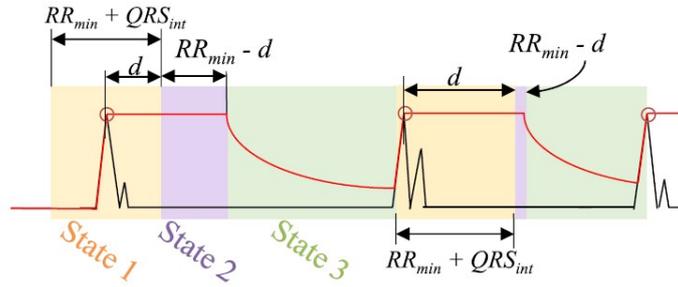


Figura 10: Ejemplo del funcionamiento de la FSM. La línea negra se corresponde con la señal ECG mientras que la roja se corresponde con el valor del umbral. Extraída de [32]

Es importante estar seguros de que las muestras clasificadas como picos R sean correctas puesto que las estimaciones de la señal respiratoria se basan exclusivamente en

dichos picos. Por tanto, una vez localizados, es necesario llevar a cabo una evaluación de calidad para garantizar que los picos son válidos.

2.3.4. Evaluación de la calidad de la señal ECG

La evaluación de calidad no es solo un procedimiento importante para verificar que los picos R son correctos, también nos permitirá evaluar la calidad de la propia señal ECG. Como se ha visto en el apartado 2.3.1, la señal ECG se ve afectada por multitud de ruidos e interferencias que provocan que la calidad de la misma disminuya. Algunos de estos ruidos e interferencias son difíciles de eliminar por lo que la mejor opción para evitar que puedan afectar al algoritmo es eliminar directamente los tramos donde aparezcan. El hecho de que la señal ECG sea una señal cuasiperiódica, nos permite eliminar los tramos en los que se ha degradado la señal sin que afecte al resto de la misma.

El estado del arte actual sobre la evaluación de la señal ECG y la validez de los picos R identificados se basa en la utilización de algoritmos SQI (Signal-Quality Index) en los que se definen diferentes índices que debe cumplir la señal. La mayoría de los autores sigue el mismo procedimiento, se divide la señal ECG en tramos y se evalúa cada tramo con los diferentes SQI. El resultado obtenido de cada evaluación se compara con los índices de los SQI definidos por cada autor y se clasifica cada tramo según el resultado de la comparación. Lo más habitual es utilizar una clasificación de dos grados definidos como “buena calidad” o “mala calidad”. Sin embargo, algunos autores utilizan un tercer grado de clasificación que sitúan entre los dos grados anteriores.

Podemos dividir los SQI en dos grupos en función de si evalúan la calidad de la señal ECG o la calidad de la identificación de los picos R. Los SQI más utilizados en la literatura hoy en día para el primer grupo de algoritmos son los que se definen a continuación:

- **kSQI:** se basa en el cuarto momento o *kurtosis* de la señal. Los procesos aleatorios e incorrelados, como es el caso del ruido, tienden a tener una distribución de probabilidad Gaussiana. Por otro lado, las señales correladas, como es el caso de la señal ECG, tienden a una distribución no Gaussiana. La *kurtosis* de una señal proporciona información sobre cuanto se aleja dicha señal de una distribución Gaussiana, por tanto, se puede esperar una *kurtosis* elevada de una señal ECG no contaminada por

ruido. La *kurtosis* puede definirse como

$$kSQI = \frac{E\{X - \mu\}^4}{\sigma^4} \quad (2)$$

Siendo X el tramo de la señal ECG, μ y σ la media y la desviación estándar del propio tramo, respectivamente, y E el operador esperanza matemática [34] [35]

- **sSQI:** se basa en el tercer momento o *skewness* de la señal. El *skewness* es una medida de la falta de simetría de la distribución de probabilidad de una señal. Similar al caso de la kurtosis, al ser la señal ECG una señal con una densidad de probabilidad no Gaussiana, podemos esperar que dicha densidad no sea demasiado simétrica y, por tanto, que tenga un skewness alto. Este algoritmo puede definirse como

$$sSQI = \frac{E\{X - \mu\}^3}{\sigma^3} \quad (3)$$

Siendo los parámetros los mismos que en la expresión 3 [35] [34]

- **pSQI:** se centra en evaluar la calidad del complejo QRS a partir de su distribución espectral de potencia (SPD). Los complejos QRS acumulan la mayor parte de la energía de la señal ECG, por tanto, calculando el ratio de DSP entre la banda de frecuencia de los QRS y la banda de la energía total de la señal ECG, se puede obtener una medida de la calidad de los complejos QRS según el valor obtenido. En este caso se define un límite superior para el resultado puesto que un ratio muy elevado puede implicar la presencia de interferencias asociadas a los complejos QRS. La energía de estos complejos se concentra en una banda de frecuencia de 10 Hz de ancho aproximadamente y centrada alrededor de los 10 Hz [36], por tanto, la mayoría de los autores definen esta banda en el intervalo de 5-15 Hz. En cuanto a la energía total de la señal ECG los rangos más utilizados son los de 5-40 Hz y 5-50 Hz. Este algoritmo se calcula como

$$pSQI = \frac{\int_{f_1}^{f_2} P(f)df}{\int_{f_3}^{f_4} P(f)df} \quad (4)$$

Definiendo como P la potencia de la señal ECG, f_1 y f_2 como los límites inferior y superior de la banda de frecuencia de los complejos QRS, y f_3 y f_4 como los límites de la energía de la señal [34]

- **basSQI:** evalúa el impacto del ruido de línea base sobre la señal. Comparando la SPD de esta banda y la SPD de la banda de frecuencia de señal ECG se puede obtener una medida sobre cuanto está afectando este tipo de ruido a la señal. Cuanto más alto sea el resultado, siendo como máximo 1, menos ruido habrá presente en la señal. El ruido de línea base suele aparecer en el rango de 0-1 Hz y la mayoría de autores utilizan ese rango para definirlo. Similar al caso del pSQI, no hay consenso sobre el límite superior de la banda de frecuencia de la energía de la señal siendo los rangos más habituales 0-40 Hz y 0-50 Hz. El algoritmo queda definido por la siguiente expresión

$$basSQI = \frac{1 - \int_{f_1}^{f_2} P(f)df}{\int_{f_3}^{f_4} P(f)df} \quad (5)$$

Siendo f_1 y f_2 los límites inferior y superior de la banda de frecuencia del ruido de línea base y f_3 y f_4 los límites de la energía de la señal [34]

En cuanto al grupo de algoritmos que validan la identificación de picos R, los más utilizados son los que se definen a continuación:

- **cSQI:** centrado en evaluar el ritmo cardíaco (HR) a partir de la duración de los intervalos entre picos R (intervalos RR) consecutivos. Se espera que el HR sea mas o menos constante y no haya una diferencia muy alta en los valores de intervalos RR consecutivos. En los casos en que el algoritmo de identificación de picos R falle debido a que algún pico no se detecte o que se clasifique incorrectamente algún pico de ruido como pico R se incrementará la variabilidad en los valores de los intervalos RR consecutivos. Se puede obtener una medida de esta variabilidad entre intervalos RR como se ve en la ecuación 6 donde cuanto menor sea el resultado menor variabilidad existirá.

$$cSQI = \frac{\sigma_{RR}}{\mu_{RR}} \quad (6)$$

Definiendo μ_{RR} y σ_{RR} como los valores de media y desviación estándar de la distribución de los valores de los intervalos RR [34]

- **hSQI:** evalúa el HR según el número de picos R identificados. A partir del valor típico del HR en un adulto sano que oscila entre 40 y 180 latidos por minuto, se puede estimar el número de picos R que se deberían identificar en un tramo de la señal ECG. En caso de no coincidir el número estimado con el HR típico se puede atribuir a que el algoritmo no ha identificado algún pico o a falsos positivos [37]

- **gSQI:** evalúa la distancia entre picos R consecutivo estableciendo un valor máximo a dicha distancia con el objetivo de averiguar si el algoritmo se ha dejado algún pico R sin identificar. El valor típico de distancia máxima utilizado por la mayoría de autores es de 3 segundos [37]
- **rSQI:** similar al algoritmo cSQI, se centra en evaluar el HR en función de la duración de los intervalos RR. El HR no debería cambiar bruscamente por lo que los valores de los intervalos RR cercanos deberían ser parecidos. Se calcula el ratio entre el intervalo de mayor duración y el de menor duración en un tramo de la señal ECG esperando que el valor obtenido no supere un umbral establecido por el autor. El valor típico utilizado en la literatura es de 2.2 [37]
- **qSQI:** evalúa el rendimiento conjunto de dos técnicas de identificación de picos R diferentes. Se comparan el número de picos identificados por ambas técnicas para así evitar la posible identificación de falsos positivos. La idea es utilizar técnicas basadas en algoritmos muy diferentes para evitar que ambas clasifiquen el mismo pico ruidoso como pico R. Se busca obtener un resultado próximo a 1 mediante la siguiente ecuación

$$qSQI = \frac{2N}{N_1 + N_2} \quad (7)$$

Siendo N el número de picos identificados por las dos técnicas y N_1 y N_2 el número de picos identificados por el algoritmo 1 y 2 [34] [38]

Una alternativa al uso de algoritmos SQI para evaluar la calidad de una señal es la de comparar la señal a estudiar con una señal patrón de buena calidad y observar cuánto se parecen. El problema de esta técnica es que la señal ECG no es exactamente igual para cada individuo por lo que habría que extraer una señal patrón para cada uno. Shahriari et al. proponen en [39] un método similar en el que, mediante un modelo de *Machine Learning* (ML), comparan la imagen de la señal a estudiar con diferentes imágenes de señales patrón. Para evaluar la comparación utilizan el índice de similitud estructural (SSIM) que cuantifica la similitud entre dos imágenes.

En este trabajo se han probado algunos de los SQI comentados y con los resultados obtenidos tras estudiarlos individualmente y en conjunto, se va a emplear el algoritmo kSQI para evaluar la calidad de la señal y los algoritmos hSQI y rSQI para validar los picos R identificados.

2.4. Métodos de detección de apneas

Existen multitud de trabajos dedicados a la identificación de apneas a partir de la señal ECG dadas las facilidades que ofrece la obtención de dicha señal. El estado del arte al respecto se centra en la utilización de métodos basados en el estudio de características extraídas de la señal ECG o de señales derivadas de ella tanto en el dominio del tiempo como el de la frecuencia. El procedimiento es similar al de la evaluación de la calidad descrito en el apartado 2.3.4, se divide la señal en tramos de igual longitud y se estudia cada uno individualmente. Los métodos basados en el dominio temporal utilizan características obtenidas directamente de la señal como su media o desviación estándar o características obtenidas de sus componentes, sobre todo de los picos R, como su posición, amplitud o duración del intervalo entre picos consecutivos [40] [41]. En cuanto al dominio frecuencial, se suele recurrir a la transformada rápida de Fourier (FFT) como proponen Huang et al. en [42]. Tras aplicar la transformada sobre distintos tramos de una señal EDR, identifican la componente frecuencial de mayor amplitud y clasifican cada tramo como episodio de apnea o respiración normal en función de en que rango de frecuencia se encuentre dicha componente y si su amplitud supera un determinado umbral. En la figura 11 se ve la comparación de dos análisis frecuenciales realizados sobre un tramo de respiración normal y uno con apnea.

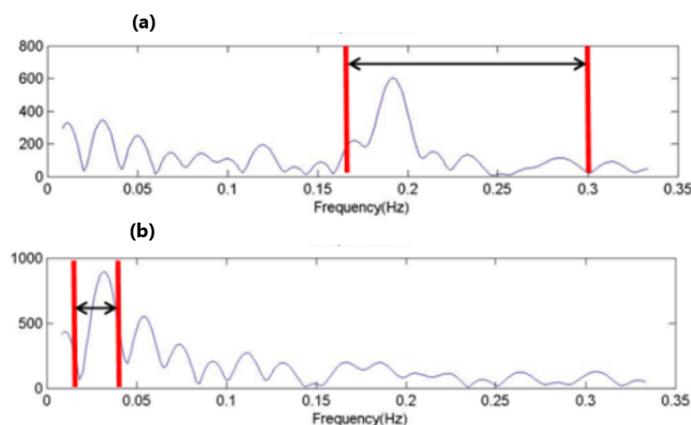


Figura 11: Comparación de los resultados de la FFT obtenidos de dos tramos diferentes de una señal EDR. Las líneas rojas indican los límites de los rangos de frecuencias elegidos por los autores en los que debe encontrarse la componente de mayor amplitud para clasificar un tramo como respiración normal o apnea. (a) Tramo de respiración normal. (b) Tramo de apnea.

Extraída de [42]

Otra opción muy utilizada para realizar este análisis frecuencial es mediante el periodograma de Lomb-Scargle. El procedimiento es similar al comentado sobre la FFT, basando el análisis en la posición de la componente frecuencial de mayor amplitud. Según concluyen Fan et al. en [43], la ventaja de utilizar este método frente al de la FFT es que se consigue una mayor resolución y menor ruido en el dominio frecuencial. En la figura 12 se puede ver como el resultado del periodograma es más suave que el obtenido de la FFT.

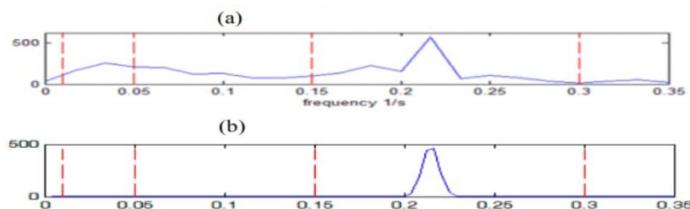


Figura 12: Comparación del análisis frecuencial del EDR de los dos métodos. (a) Resultado de la FFT. (b) Resultado de Lomb-Scargle. Extraída de [43]

Sin embargo, los estudios más recientes sobre la identificación de apneas se centran en la utilización de modelos de ML para la extracción de características. Wang et al. [44] proponen una versión modificada de la red neuronal convolucional LeNet-5 formada por siete capas en la que las cuatro primeras capas realizan la extracción de características de la señal ECG y las tres últimas la clasificación en apneas o no apneas. Li et al. [45] desarrollaron una red neuronal únicamente para extraer características de los intervalos entre picos R consecutivos de señales ECG sin realizar la clasificación con esa misma red. También son comunes redes de dos dimensiones como la que proponen Singh and Majumder [46] basada en un modelo AlexNet con la que extraen características de imágenes 2D de señales ECG.

En este trabajo se van a utilizar algunos de los métodos de extracción de características comentadas para los dos clasificadores. En el caso del algoritmo de detección se emplearán tres técnicas diferentes aplicadas sobre tramos de las señales EDR. La primera consiste en un análisis frecuencial utilizando el periodograma de Lomb-Scargle. Las otras dos técnicas se basan en un análisis temporal de la señal EDR en el que se estudiará la amplitud de las muestras de la señal. Para la red neuronal se van a utilizar algunas de las técnicas más empleadas en la literatura, nueve basadas en la obtención de características a partir de la duración de los intervalos entre picos R consecutivos y tres basadas en

la obtención de características a partir de un análisis frecuencial utilizando de nuevo el periodograma de Lomb-Scargle.

2.5. Técnicas de fusión de datos

Lo más habitual en los trabajos relativos a la detección de apneas es aplicar varias de las técnicas de identificación comentadas en el apartado anterior sobre los diferentes tramos de la señal ECG. De este modo se disponen de varias evidencias sobre la existencia o no de apnea en cada tramo de la señal. Sin embargo, esto implica que será necesario combinar los resultados obtenidos de cada método de identificación hasta conseguir un único resultado final para cada tramo de la señal.

El estado del arte referente a la fusión de datos obtenidos de diferentes sensores se centra principalmente en dos teoremas. El más antiguo de ellos es el teorema de Bayes, una variación del teorema clásico de probabilidad. Este teorema se utiliza para calcular la probabilidad condicional de un suceso a partir de resultados previos ya observados. Es decir, establece que el comportamiento de una hipótesis H se puede determinar según el conocimiento previo obtenido de una evidencia E y se define como

$$P(H|E) = \frac{P(E|H)P(H)}{P(E)} \quad (8)$$

Donde

- $P(H|E)$ es la probabilidad a posteriori de que la hipótesis H sea verdadera cuando haya ocurrido la evidencia E
- $P(E|H)$ es la probabilidad de observar la evidencia E cuando la hipótesis H es verdadera
- $P(H)$ es la probabilidad de que la hipótesis H sea verdadera
- $P(E)$ es la probabilidad de observar la evidencia E

En lo referente a la fusión de datos, dados n sensores que proporcionan n evidencias (E^n), éstas se pueden combinar utilizando una generalización de la ecuación (8) para obtener una probabilidad de que la hipótesis H . Esta probabilidad se obtiene como

$$P(H|E^1 \cap E^2 \cap E^3 \cap \dots \cap E^n) \quad (9)$$

Los trabajos [47] [48] son algunos ejemplos de estudios que emplean el teorema de Bayes para llevar a cabo una fusión de datos.

El otro teorema más utilizado es el de la teoría de la evidencia de Dempster-Shafer basado en la teoría de la probabilidad clásica. Esta teoría es muy útil cuando a la información proporcionada por los sensores no se le puede atribuir el 100 % de la certeza. Los parámetros más destacados de esta teoría son [49]:

- **Propuesta** (a_i): es la suposición de que algo podría, o no, ser posible
- **Masa de probabilidad** (m_i): probabilidad asignada a una propuesta
- **Marco de discernimiento** (Θ): conjunto de propuestas mutuamente excluyentes que forman el espacio hipotético de modo que para n propuestas

$$\Theta = \{a_1, a_2, \dots, a_n\} \quad (10)$$

En el caso de que un sensor no proporcione la información suficiente como para asignar toda la masa de probabilidad a una propuesta a una unión de éstas, el restante de dicha masa se asigna al marco de discernimiento (11) o a la negación de una propuesta (12) [49].

$$m(\Theta) = \{a_1 \cup a_2 \cup \dots \cup a_n\} \quad (11)$$

$$m(\bar{a}_1) = \{a_2 \cup a_3 \cup \dots \cup a_n\} \quad (12)$$

La fusión de datos se lleva a cabo combinando las diferentes propuestas reportadas por los sensores para encontrar los conjuntos e intersecciones de dichas propuestas y, por consiguiente, los conjuntos e intersecciones de sus masas de probabilidad. Cuando la intersección de varias propuestas da como resultado un conjunto vacío, la masa de probabilidad asignada a dicho conjunto se reparte con los conjuntos no vacíos [49].

Rottensteiner et al. utilizan en [50] la fusión de datos basada en la teoría de la evidencia de *Dempster-Shafer* (DS) para identificar edificios en zonas urbanas mediante la combinación de datos recogidos por un lidar. En [51], Feng et al. la utilizan para detectar en tiempo real la somnolencia en conductores.

Del mismo modo que ocurre con las técnicas de detección de apneas, el estado del arte respecto a la fusión de datos en los últimos años se basa en la utilización de algoritmos de ML. La fusión de los datos se lleva a cabo en el proceso de clasificación donde los resultados obtenidos de diferentes sensores se combinan mediante estos algoritmos para obtener la clase más probable a la que pertenece la entrada.

Dentro de los algoritmos más utilizados encontramos algunos que emplean técnicas como la del k-vecino más próximo (*k-Nearest Neighbor*, kNN) [52], máquinas de vector soporte (*Support Vector Machines*, SVM) [53], modelos ocultos de Markov (*Hidden Markov Models*, HMM) [54], redes neuronales (*Neural Networks*, NN) [55] o regresión logística [56]. En este trabajo se van emplear dos técnicas de fusión, una basada en un decisor estadístico y otra basada en ML.

3. Algoritmo de detección de apneas

En este capítulo vamos a comentar en detalle el algoritmo de detección de apneas centrales, el primero de los dos clasificadores que se han desarrollado en este trabajo. El algoritmo utiliza un decisor estadístico basado en la teoría de la evidencia de DS para combinar las certezas sobre la existencia o no de apnea procedentes de seis métodos de identificación de apneas diferentes. En la figura 13 se muestra una visión general del diagrama de bloques relativo al algoritmo. La primera de las etapas consistirá en un pre-procesado de la señal ECG necesario para, a continuación, llevar a cabo la detección de sus picos R. El siguiente paso será evaluar tanto la calidad de la señal como las posiciones de los picos R obtenidos en la etapa anterior mediante un algoritmo de calidad. A continuación, se obtendrán dos señales EDR estimadas mediante dos técnicas diferentes basadas en la extracción de características. A cada una de estas señales EDR se le aplicará tres métodos de identificación de apneas, uno basado en un análisis frecuencial y dos análisis temporal obteniéndose en total seis certezas sobre la existencia o no de apnea a lo largo de la señal ECG. Por último, se combinarán estas seis certezas mediante el decisor estadístico para obtener una única certeza final en los diferentes tramos de la señal ECG.

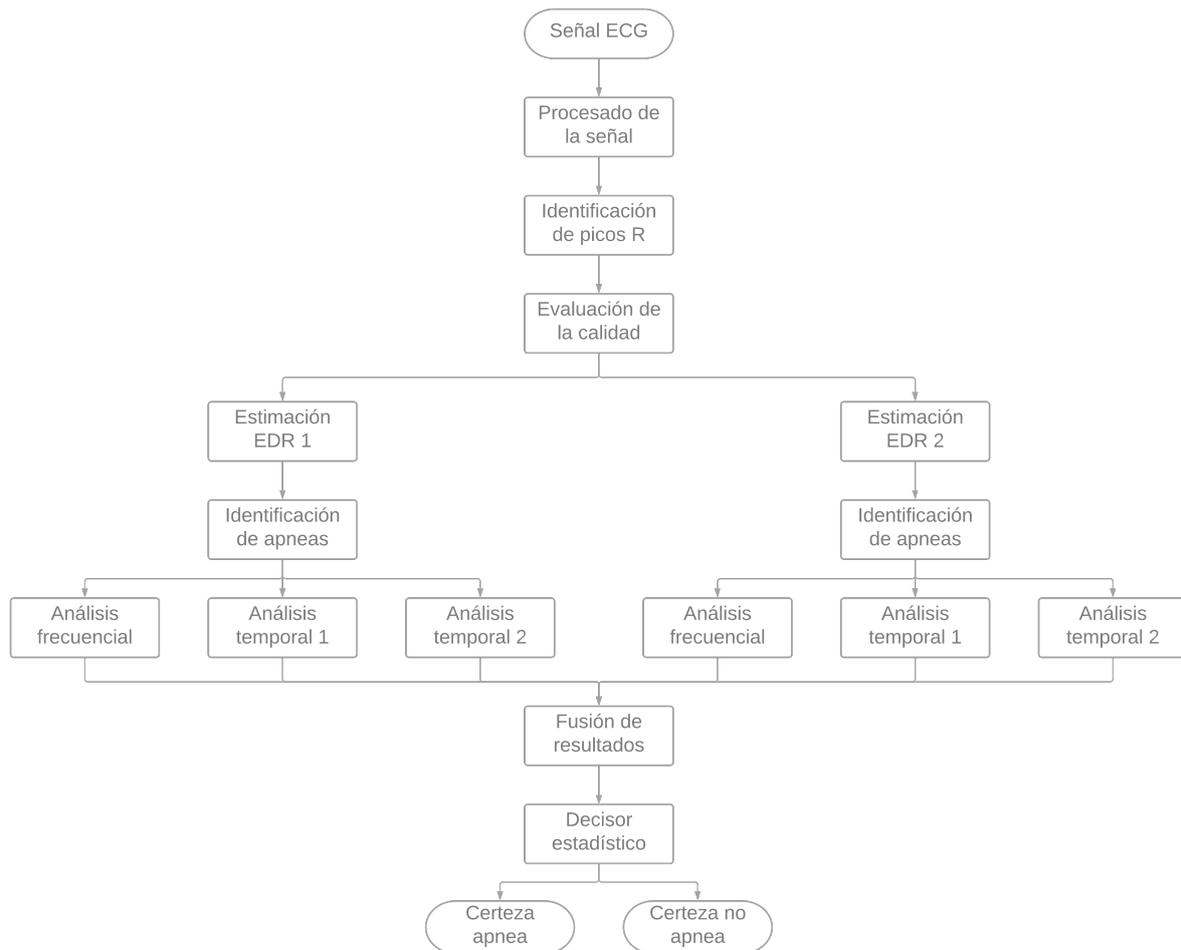


Figura 13: Diagrama de bloques del algoritmo de detección desarrollado en este TFM

3.1. Adecuación del ECG y localización de picos R

Antes de extraer información de la señal ECG, es necesario realizar un pre-procesado de la misma con el objetivo de mejorar su calidad eliminando algunos de los ruidos por los que se ve afectada y facilitar también la posterior localización de los picos R. Este pre-procesado será el propuesto por Gutiérrez-Rivas et al. en [32] para su algoritmo de detección de complejos QRS y que se introdujo en el apartado 2.3.3. En cuanto a la localización de los picos R, se seguirá este mismo algoritmo propuesto en [32] y que se comentó también en ese apartado.

Para el caso particular de este trabajo, las señales ECG que componen la base de datos que se describirá en el apartado 5.1 son señales de pacientes reales y presentan un inconveniente relacionado con la posición de los picos R, parte fundamental del proyecto. A la hora de adquirir las señales, éstas se registraron con una saturación de 1 mV, y dado

que la amplitud de las ondas R suelen superar con creces este límite, nos encontramos con que se ha perdido la información relativa a la posición de la gran mayoría de los picos R. En la figura 14 se muestra un ejemplo de esta saturación.

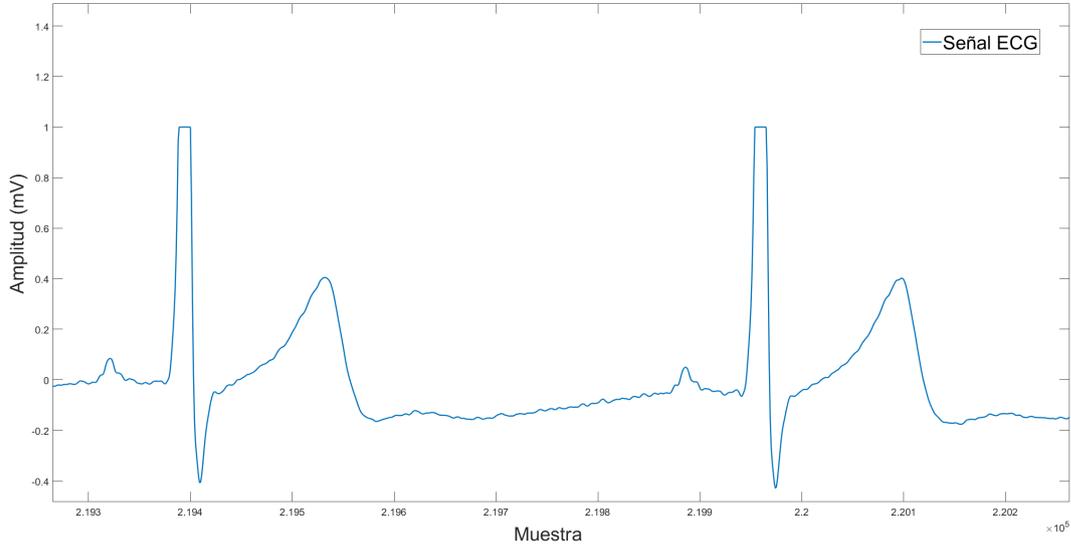


Figura 14: Señal ECG saturada a una amplitud de 1 mV

Para solucionar este problema se va a utilizar una serie de Fourier con 2 términos (ecuación 13) para estimar la curva empleando las muestras de las pendientes de la onda R y excluyendo las muestras saturadas. En la figura 15 podemos ver el resultado obtenido tras aplicar esta ecuación a una onda R saturada.

$$f(t) = \frac{a_0}{2} + \sum_{n=1}^N \left[a_n \cdot \cos \frac{2n\pi}{T} t + b_n \cdot \sin \frac{2n\pi}{T} t \right] ; \quad N = 2 \quad (13)$$

Siendo $f(t)$ una función periódica con periodo T y a_0 , a_n y b_n los coeficientes de Fourier que toman los siguientes valores:

$$a_0 = \frac{2}{T} \int_{-T/2}^{T/2} f(t) dt \quad (14)$$

$$a_n = \frac{2}{T} \int_{-T/2}^{T/2} f(t) \cdot \cos \frac{2n\pi}{T} t dt \quad (15)$$

$$b_n = \frac{2}{T} \int_{-T/2}^{T/2} f(t) \cdot \sin \frac{2n\pi}{T} t dt \quad (16)$$

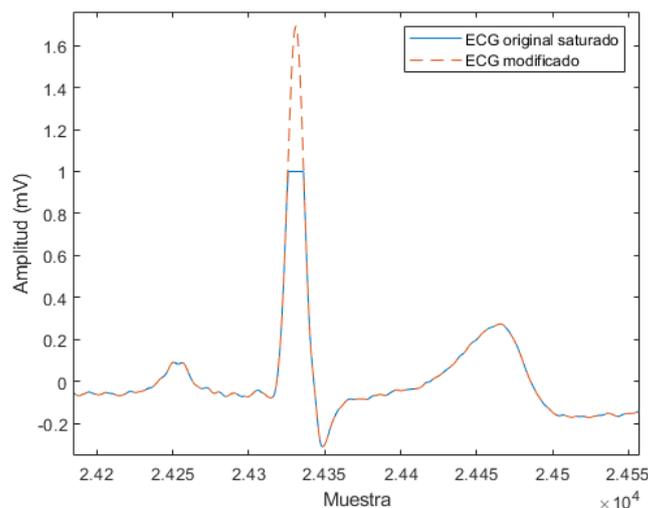


Figura 15: Señal ECG saturada (azul) y señal estimada (rojo)

3.2. Evaluación de la calidad

El siguiente paso tras la localización de los picos R será realizar una evaluación de la calidad de la señal ECG. La finalidad de esta evaluación es eliminar del análisis de apneas aquellas partes de la señal que puedan dar resultados erróneos o poco fiables. Como se mostró en el apartado 2.3.4, los análisis de calidad de este tipo de señales se centran principalmente en eliminar los tramos de la señal afectados por los dos siguientes problemas:

- Tramos con ruido que no se haya filtrado en la etapa de pre-procesado: como se vio en el apartado 2.3.1, existen varios tipos de ruidos en las señales ECG difíciles de filtrar, por lo que la manera más práctica de eliminarlos es eliminar directamente el tramo afectado.
- Tramos con picos R no válidos: los picos R son una parte fundamental en este trabajo ya que se utilizarán en la mayoría de los métodos desarrollados para la detección de apneas. Por tanto, debemos asegurarnos que los picos identificados durante la etapa de localización sean verdaderamente picos R.

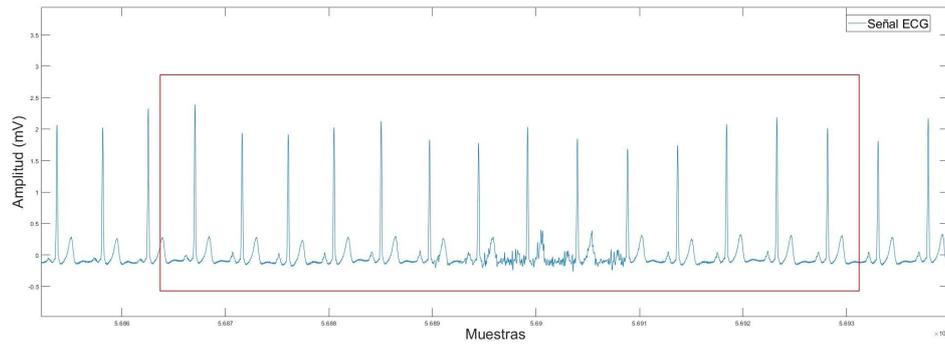
Para este proyecto se ha desarrollado un algoritmo de calidad basado en algunos de los SQI que se vieron en el apartado 2.3.4. En primer lugar se dividirá la señal ECG en ventanas de 5 segundos con solapamiento de 2.5 segundos y se calcularán los SQI de

cada una. Aquellos tramos que no cumplan todos los SQI que componen el algoritmo se eliminarán de la señal. Es muy probable que, en más de una ocasión, el inicio o fin de una ventana coincida con las partes donde se producen las ondas características del ECG. Por tanto, si se eliminara esa ventana, se alteraría la morfología de la señal perjudicando el posterior análisis de apneas al modificar la distancia entre picos R consecutivos.

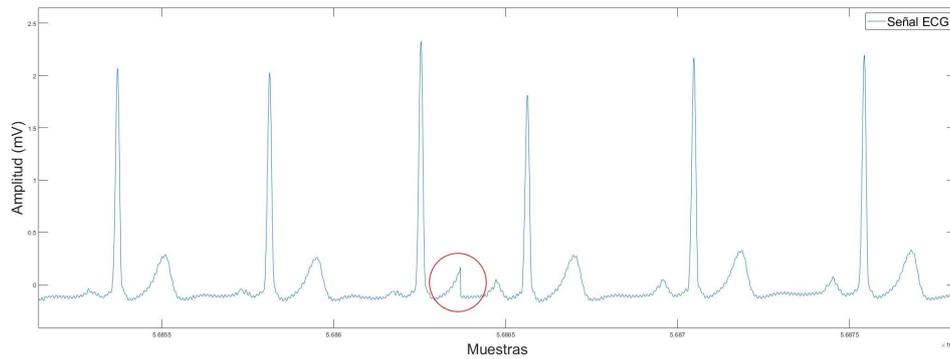
Para tratar de alterar lo mínimo la señal, al eliminar una ventana se tomará como punto de corte inicial y final las siguientes muestras:

- **Inicial:** punto medio entre la posición del último pico R previo al inicio de la ventana y la posición del primer pico R perteneciente a la ventana
- **Final:** punto medio entre la posición del último pico R perteneciente a la ventana y la posición del primer pico R posterior al final de la ventana

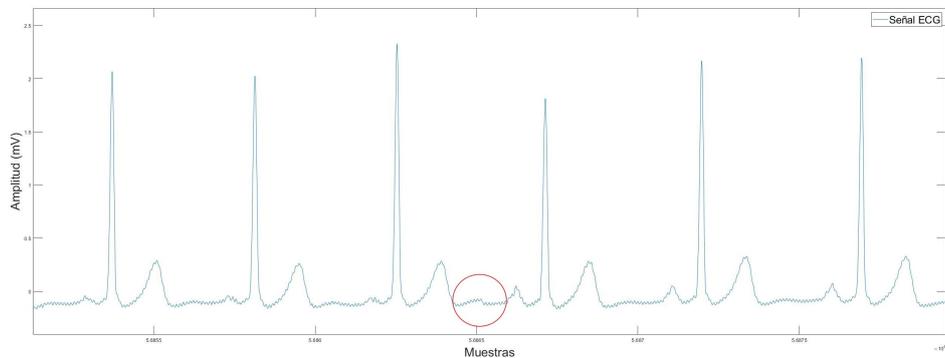
En la figura 16 podemos ver un ejemplo de como quedaría la señal tras hacer el corte en las dos situaciones, por una lado coincidiendo los puntos de corte con el inicio y fin de la ventana, y por otro lado tal y como finalmente se hará en este trabajo, es decir, coincidiendo con el punto medio entre picos R.



(a)



(b)



(c)

Figura 16: Comparación de las dos maneras de seleccionar los puntos de corte de una zona de mala calidad. (a) Ejemplo de un tramo de mala calidad de una señal ECG y la ventana (rectángulo rojo) que lo abarca. (b) Resultado de la señal ECG tras realizar el corte en los puntos de inicio y fin de la ventana. El círculo rojo indica el punto donde se ha realizado el corte. (c) Resultado de la señal ECG tras realizar el corte en los puntos medios entre picos R.

El círculo rojo indica el punto donde se ha realizado el corte

De este modo, tal y como se ve en la figura 16, el corte en la señal se produce en la zona menos relevante para nuestro análisis (fuera de las ondas del ECG) y la morfología de la señal no se ve muy afectada. Además, evitamos también alterar en exceso el valor de la distancia entre picos R consecutivos, una característica que se utilizará en la red neuronal.

En cuanto a los SQI que forman el algoritmo de calidad, se hará una prueba inicial evaluando dos señales ECG con los algoritmos hSQI, gSQI, rSQI, cSQI y kSQI explicados en el apartado 2.3.4. El objetivo de esta primera prueba es descartar aquellos que no aporten información nueva respecto al resto, es decir, que todas las ventanas que identifiquen de mala calidad también hayan sido identificadas por otros SQIs.

Tras realizar esta prueba, se ha descartado el uso de los algoritmos gSQI y cSQI puesto que todos los tramos de mala calidad identificados por estos dos algoritmos fueron descartados también por al menos otro algoritmo. Por tanto, solo se utilizará el algoritmo kSQI para evaluar la calidad de la señal y eliminar ruidos, y los algoritmos hSQI y rSQI para validar los picos R identificados.

3.3. Estimación del EDR

Una vez localizados los picos R de la señal y eliminados los tramos de mala calidad, se realiza la estimación de la señal EDR, a partir de la cual se hará la identificación de apneas. De las técnicas vistas en el apartado 2.3.2, se van a utilizar en este trabajo dos basadas en la extracción de características de la señal ECG, concretamente de los picos de las ondas R, dada su fácil implementación. Cada valor obtenido de un pico R se corresponderá con una muestra de la señal EDR por lo que la longitud de dicha señal será igual al número de picos R que contenga la señal ECG. Las técnicas utilizadas se describen a continuación.

- **Área alrededor del pico R (EDR_área):** para cada complejo QRS, se calcula la suma de los valores de las muestras de la señal ECG durante un intervalo de 40 ms alrededor de cada pico R siguiendo la técnica propuesta por Cuevas Notario en [33]. En la figura 17 se puede ver el ejemplo del área de un complejo QRS.

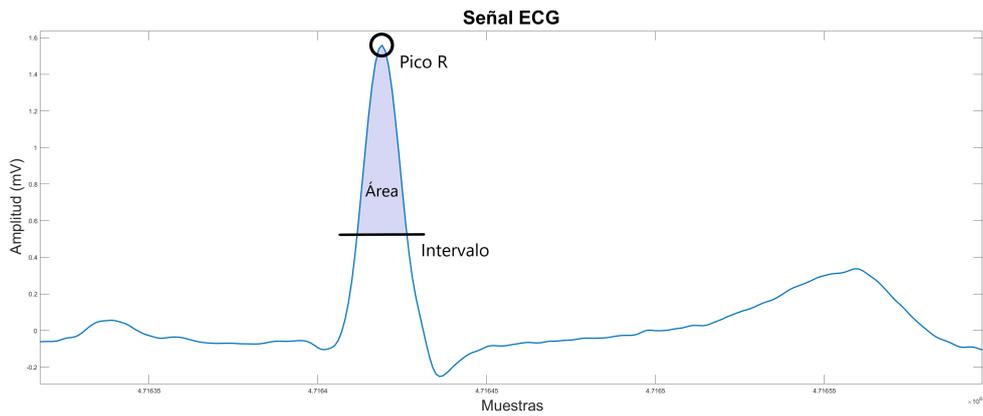


Figura 17: Representación de la estimación del área alrededor de un pico R

- **Amplitud del pico R (EDR_amp):** se obtiene la amplitud desde el eje de abscisas del pico R para cada complejo QRS. En la figura 18 se muestra un ejemplo.

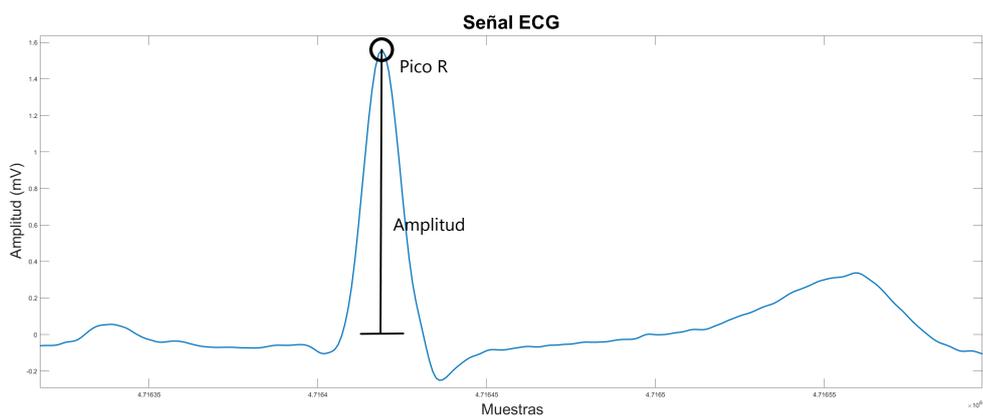
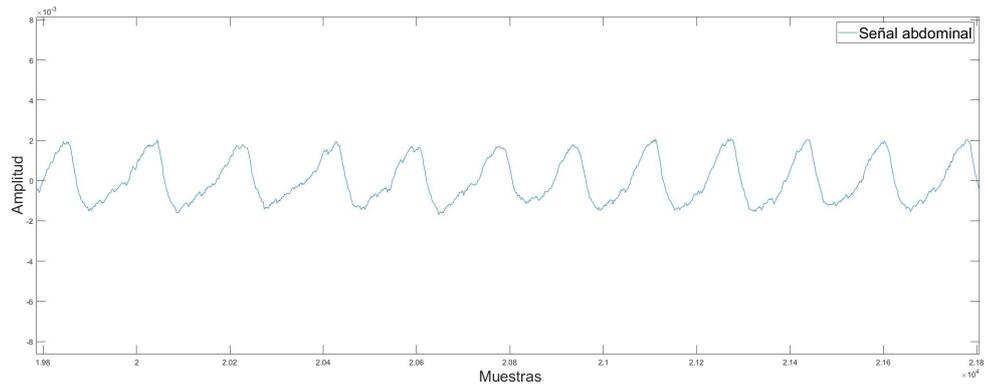
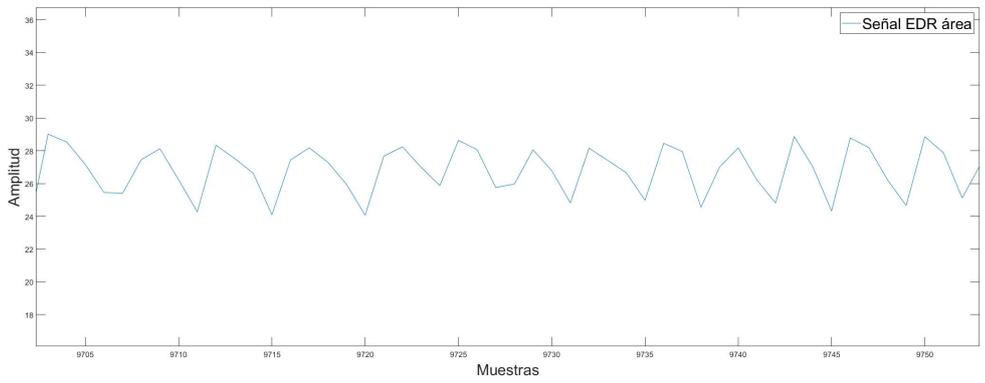


Figura 18: Representación de la estimación de la amplitud de un pico R

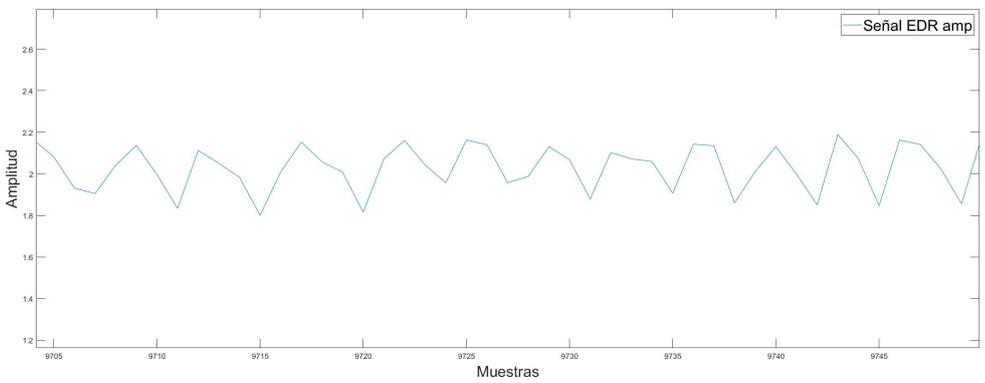
La señal EDR representa el esfuerzo respiratorio o movimiento de la caja torácica del paciente por lo que se comparan las estimaciones obtenidas con la señal de una cinta abdominal que registra los movimientos del abdomen. En la figura 19 se muestra un tramo de la señal abdominal de uno de los pacientes de la base de datos empleada y las señales EDR correspondientes a ese mismo tramo estimadas a partir de los dos métodos comentados. Como se puede ver en la figura la dos señales estimadas tienen la misma apariencia que la señal abdominal de referencia.



(a)



(b)



(c)

Figura 19: Comparación de una señal abdominal (a), una señal EDR estimada mediante el método EDR_área (b) y una señal EDR estimada mediante el método EDR_amp (c)

3.4. Identificación de apneas centrales

La etapa final del algoritmo de detección es la propia identificación de apneas centrales utilizando las señales EDR estimadas en el paso anterior. Para ello, como se comentó en el apartado 2.4, se han empleado tres técnicas clásicas de extracción de características una basada en un análisis frecuencial del EDR y las otras dos en un análisis temporal del mismo. Cada una de las técnicas proporcionará una evidencia de apnea en cada muestra de la señal EDR, o lo que es lo mismo, en cada pico R de la señal ECG. Dado que se han estimado dos señales EDR distintas (EDR_área y EDR_amp), tras aplicar las tres técnicas de identificación de apneas sobre ellas se van a obtener 6 evidencias de apneas diferentes para cada pico R del ECG a la salida de esta etapa.

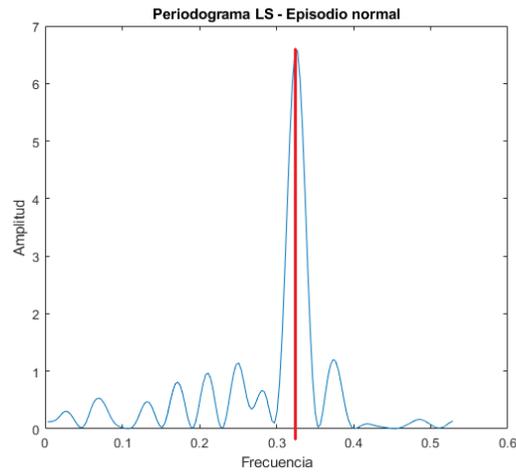
3.4.1. Analisis frecuencial

Esta técnica, que denominaremos F-EDR, se basa en el uso del periodograma de Lomb-Scargle sobre la señal EDR obtenida sin procesar. Como se vio en el apartado 2.4, las técnicas que emplean análisis frecuenciales dividen la señal en tramos y estudian la posición de la componente frecuencial de mayor amplitud del espectro. Esto se debe a que cuando se produce una apnea, esta componente suele aparecer en las frecuencias más bajas. Por tanto, el procedimiento seguido divide la señal EDR en ventanas de 30 segundos de duración, con solapamiento de 10 segundos, y estima el periodograma sobre cada una de ellas. Una vez hecho esto, se analiza cada ventana individualmente considerando que se ha producido una apnea si se cumple uno de los dos siguientes criterios y se considerará que no es apnea en caso contrario. Los dos criterios asociados a la presencia de apnea son:

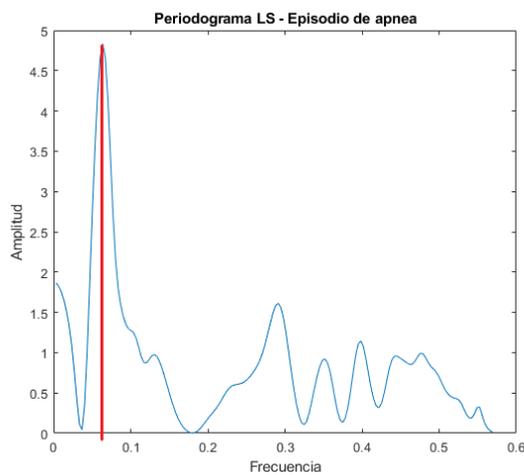
- La posición frecuencial de la componente de mayor amplitud del resultado del periodograma es inferior a un determinado umbral. Para este trabajo dicho umbral tendrá un valor de 0.1 Hz siguiendo los resultados obtenidos por Vijendra et al. en su trabajo sobre identificación de apneas donde realizan un análisis frecuencial considerando diferentes bandas de frecuencia de apnea y concluyendo que la mejor es la de 0-0.1 Hz
- La posición de la segunda componente de mayor amplitud es inferior al umbral utilizado en el primer criterio y su valor de amplitud no se aleja demasiado del de la

componente de mayor amplitud. Para comprobar esto se calculará la relación entre ambas componentes y el resultado deberá tener un valor entre 1 y 1.6. Estos valores se han extraído del trabajo realizado por Cuevas Notario en [33]

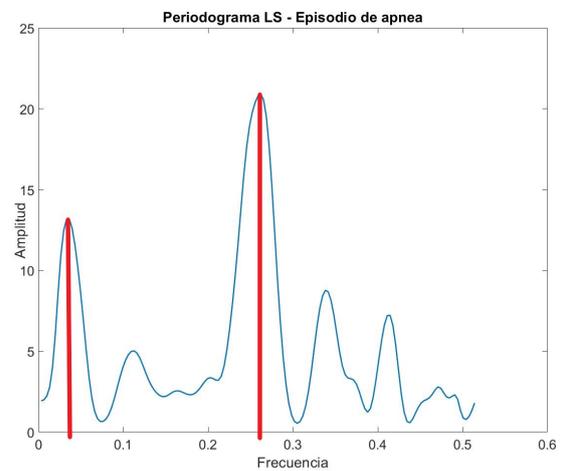
En la figura 20 se muestra el periodograma de tres ventanas diferentes de la señal EDR_área del mismo paciente. El resultado de la figura 20a se corresponde con una ventana en la que no se produjo una apnea mientras que en las ventanas correspondiente a las figuras 20b y 20c sí se produjeron apneas.



(a)



(b)



(c)

Figura 20: Comparación del resultado del periodograma de Lomb-Scargle para una ventana con un episodio de respiración normal (a) y dos con un episodio de apnea (b) (c) según los dos criterios comentados

Como se ve en la figura 20 en el análisis frecuencial de la ventana sin apnea la componente de mayor amplitud se encuentra entre los 0.3 y 0.4 Hz indicada con una línea roja. Por otro lado, en los otros dos casos aparece una componente de gran amplitud por debajo de los 0.1 Hz. En el primer caso (figura 20b) esta componente es la de mayor amplitud por lo que se cumple el primero de los criterios. En el segundo caso (figura 20c) no es la componente de mayor amplitud la que se encuentra por debajo de los 0.1 Hz, sin embargo, la relación entre las dos componentes de mayor amplitud es de 1.58, cumpliéndose el segundo de los criterios establecidos. Por tanto, se considera que en el caso (a) no hay apnea pero sí en el (b) y (c).

3.4.2. Análisis temporal

Las dos técnicas desarrolladas se han extraído del trabajo realizado por Cuevas Notario en [33] y se basan en estudiar la disminución en el movimiento de la caja torácica que se da cuando tiene lugar una apnea central. Esta disminución se va a ver reflejada en la señal EDR dado que, como comentamos en el apartado anterior, esta señal representa el movimiento de la caja torácica, por tanto, podemos identificar una apnea a partir la amplitud de esta señal. El procedimiento seguido será evaluar cada pico de la señal EDR comparando su amplitud con la media de los seis picos anteriores. La diferencia entre las dos técnicas radica en el procesado que se le aplica a la señal EDR previo al estudio sobre la identificación de apneas.

- **Técnica 1 (D-EDR):** se deriva la señal EDR para ubicarla en el eje de abscisas. El criterio utilizado en esta técnica para considerar una apnea será que se produzcan dos picos consecutivos cuyas amplitudes sean inferiores a un determinado umbral dinámico. Dicho umbral será igual al 35 % de la media de los seis picos anteriores al primero de los dos picos. Es decir, en caso de que se identifique un pico que cumpla este criterio, el siguiente pico se evaluará comparando su amplitud con el mismo umbral que el anterior, sin incluir a este último en la media.
- **Técnica 2 (D2-EDR):** además de derivar la señal, ésta se eleva al cuadrado para resaltar los picos R. El criterio será el mismo que en la técnica anterior pero en este caso el umbral tomará un valor igual al 65 % de la media de los seis anteriores al primero de los dos picos.

En la figura 21 se muestra un tramo de la señal EDR_área procesada según la técnica D-EDR en el que se ha producido una apnea. En el círculo rojo se indican los dos picos que cumplen el criterio para que sean clasificados como apnea mientras que la flecha roja se corresponde con los picos que forman la media de amplitudes con la que se comparan los dos picos evaluados.

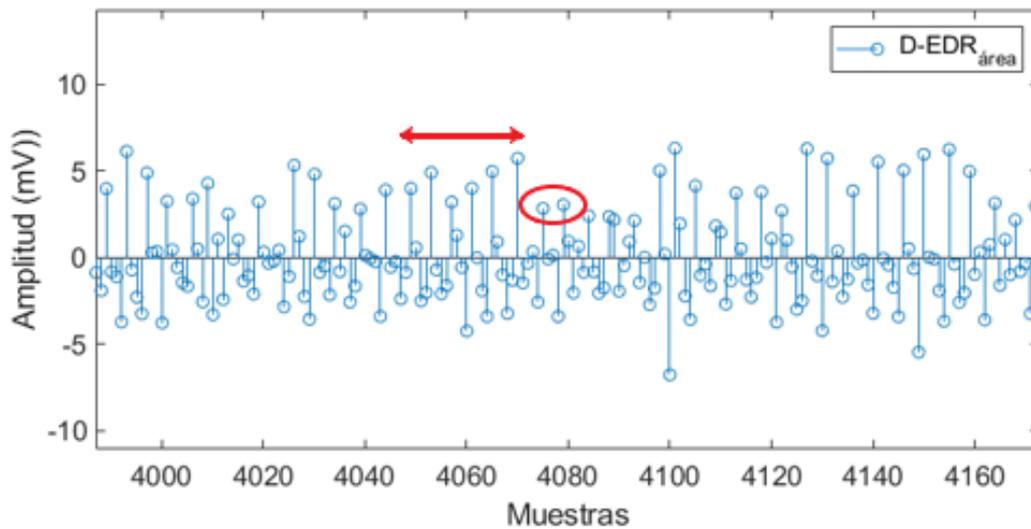


Figura 21: Tramo de una señal EDR procesada según D-EDR en el que se ha producido una apnea

3.5. Cálculo de certeza

Se dispone de dos señales EDR obtenidas a través de dos métodos distintos (EDR_área, EDR_amp) que han sido evaluadas por tres técnicas diferentes para detectar la presencia de apneas, por lo tanto se dispone de seis evidencias acerca de la existencia o no de apnea en cada ventana de la señal ECG pero estos resultados se corresponden con una clasificación binaria (apnea, no-apnea). Para tratar de ofrecer una mayor precisión a la hora de hacer la clasificación final tras el proceso de fusión, a los resultados obtenidos de cada una de las técnicas de identificación de apneas se les va a otorgar una determinada certeza de existencia de apnea que denominaremos m . Esta certeza tomará valores entre 0 y 1 siendo 1 una certeza absoluta de que existe apnea y 0 una certeza absoluta de lo contrario. En la figura 22 podemos ver un diagrama de este proceso.

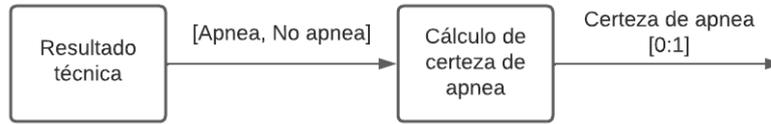


Figura 22: Diagrama de bloques del cálculo de la certeza para cada uno de los resultados obtenidos a través de las distintas técnicas

El valor de la certeza dependerá de lo mucho o poco que se acerquen los resultados obtenidos de las técnicas de detección de apneas a los respectivos umbrales de cada técnica según los criterios establecidos. En todos los casos las certezas tendrán unos valores máximo y mínimo definidos a partir de [33]. Estos límites dependerá de la técnica evaluada y de si se ha identificado o no una apnea. En el caso de que se identifique una apnea, el valor mínimo de certeza que se le podrá otorgar será de $m_{a-min} = 0.6$ para todas las técnicas. Esta certeza mínima implica que la técnica ha identificado una apnea pero el valor obtenido del análisis está muy próximo al umbral establecido por el criterio. Por ejemplo, en el caso del análisis frecuencia, el primer criterio de apnea establecía que la posición frecuencial del pico de mayor amplitud debía ser inferior a un umbral igual a 0.1 Hz. De este modo, en el caso de que el periodograma de una ventana del ECG de como resultado un pico máximo situado por debajo de los 0.1 Hz pero muy próximo a ese valor, el algoritmo clasificará la ventana como apnea pero la certeza de existencia de la misma en dicha ventana será igual al valor mínimo, un 0.6. En el caso de la certeza de apnea cuando se ha identificado una apnea (m_{a-min}) dependerá de la técnica utilizada. Análogamente, el valor máximo de certeza de existencia de apnea para todas las técnicas cuando no se identifique una apnea es de $m_{na-max} = 0.4$ mientras que el valor mínimo (m_{na-min}) dependerá de la técnica utilizada.

En cuanto a los valores intermedios entre los límites que podrá tomar la certeza será diferente para cada una de las tres técnica de identificación de apneas y dependerá, como se ha comentado, de los resultados de los análisis.

- Análisis frecuencial:** en esta técnica la certeza de apnea ($m(F - EDR)$) se calculará en función del valor de una variable f_{max} tal como se muestra en la expresión 17. En los casos en que se identifique una apnea la variable f_{max} tomará el valor de posición frecuencial de la componente de mayor amplitud para el primero de los cri-

terios expuestos en el apartado 3.4 y la segunda componente de mayor amplitud en el caso del segundo criterio. Para las ventanas en las que no se identifiquen apneas, f_{max} será igual a la posición de la componente de mayor amplitud. En la figura 23 se muestra una representación de los valores que puede tomar la certeza en función de la variable f_{max} tanto para los casos de apnea como de no apnea. Partiendo de los valores definidos en [33], éstos se han modificado en función de los resultados tras probar entre varias opciones.

$$m(F-EDR) = \begin{cases} m_{a-max}, & f_{max} \leq 0.05 \\ \frac{m_{a-min} - m_{a-max}}{0.03} \cdot (f_{max} - 0.05) + m_{a-max}, & 0.05 < f_{max} \leq 0.08 \\ m_{a-min}, & f_{max} > 0.08 \\ m_{na-max}, & f_{max} \leq 0.15 \\ \frac{m_{na-min} - m_{na-max}}{0.1} \cdot (f_{max} - 0.15) + m_{na-max}, & 0.15 < f_{max} \leq 0.25 \\ m_{na-min}, & f_{max} > 0.25 \end{cases} \quad (17)$$

Donde los valores límites que puede tomar la certeza son:

- $m_{a-max} = 0.85$
- $m_{a-min} = 0.6$
- $m_{na-max} = 0.4$
- $m_{na-min} = 0.15$

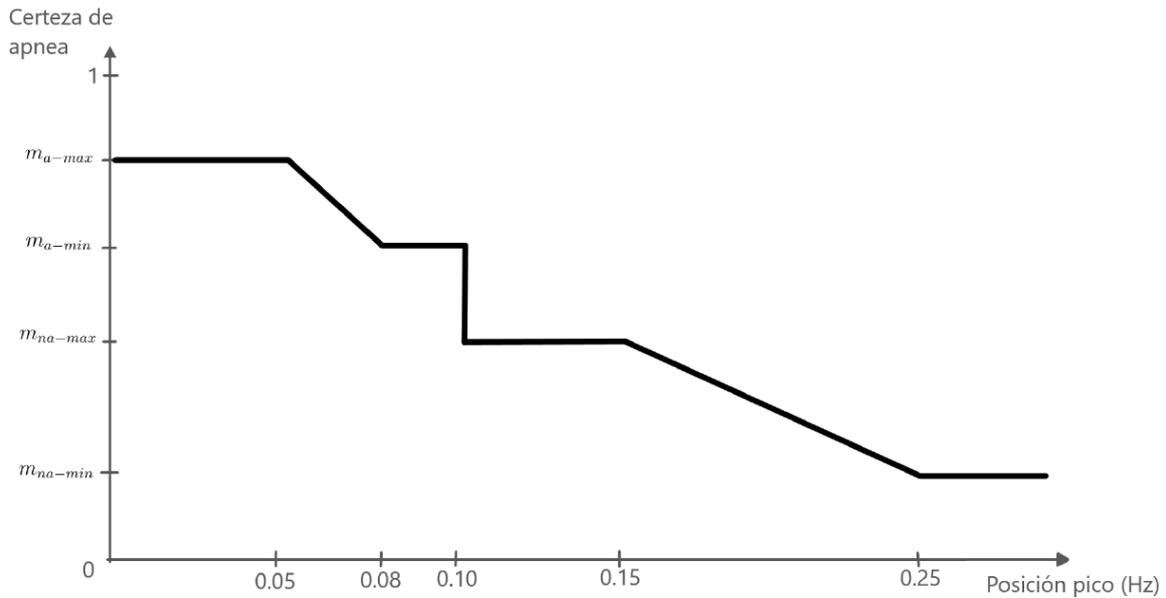


Figura 23: Representación de la función del cálculo de certeza para la técnica de identificación de apneas F-EDR

- Análisis temporal:** en estas dos técnicas la certeza ($m(D-EDR)$ y $m(D2-EDR)$) dependerá del valor de la variable D que será igual al cociente de la amplitud del pico del EDR a evaluar y la media de los picos anteriores. A diferencia de la función de certeza utilizada en el análisis frecuencial, para estas dos técnicas no se va a utilizar una única función para los casos de apnea y no apnea. Como se vio en el apartado 3.4, el criterio para identificar una apnea era que las amplitudes de dos picos consecutivos de la señal EDR fueran inferiores al umbral por lo que un pico puede cumplir la condición pero el siguiente no, así que el algoritmo no clasificara ninguno de ellos como apnea. Sin embargo, el valor de la variable D del primero de los picos va a tener un valor dentro de los rangos de los clasificados como apnea aunque no sea clasificado como tal. En las funciones 18 y 19 podemos ver los valores que puede tomar la certeza en los casos de apnea y no apnea respectivamente para la técnica D-EDR, mientras que las de la técnica D2-EDR se corresponden con las funciones 20 y 21. Por último, en la figura 24 se muestra una representación gráfica de las cuatro funciones, donde al igual que en el análisis frecuencial, los diferentes parámetros se definieron según pruebas iniciales.

$$m(D - EDR) = \begin{cases} m_{a-max}, & D \leq 0.4 \\ \frac{m_{a-min} - m_{a-max}}{0.1} \cdot (D - 0.4) + m_{a-max}, & 0.4 < D \leq 0.5 \\ m_{a-min}, & D > 0.5 \end{cases} \quad (18)$$

$$m(D - EDR) = \begin{cases} m_{na-max}, & D \leq 0.7 \\ \frac{m_{na-min} - m_{na-max}}{0.3} \cdot (D - 0.7) + m_{na-max}, & 0.7 < D \leq 0.8 \\ m_{na-min}, & D > 0.8 \end{cases} \quad (19)$$

$$m(D2 - EDR) = \begin{cases} m_{a-max}, & D \leq 0.2 \\ \frac{m_{a-min} - m_{a-max}}{0.05} \cdot (D - 0.2) + m_{a-max}, & 0.2 < D \leq 0.25 \\ m_{a-min}, & D > 0.25 \end{cases} \quad (20)$$

$$m(D2 - EDR) = \begin{cases} m_{na-max}, & D \leq 0.35 \\ \frac{m_{na-min} - m_{na-max}}{0.15} \cdot (D - 0.35) + m_{na-max}, & 0.35 < D \leq 0.5 \\ m_{na-min}, & D > 0.5 \end{cases} \quad (21)$$

Donde los valores límites que puede tomar la certeza para las cuatro funciones son:

- $m_{a-max} = 0.80$
- $m_{a-min} = 0.6$
- $m_{na-max} = 0.4$
- $m_{na-min} = 0.20$

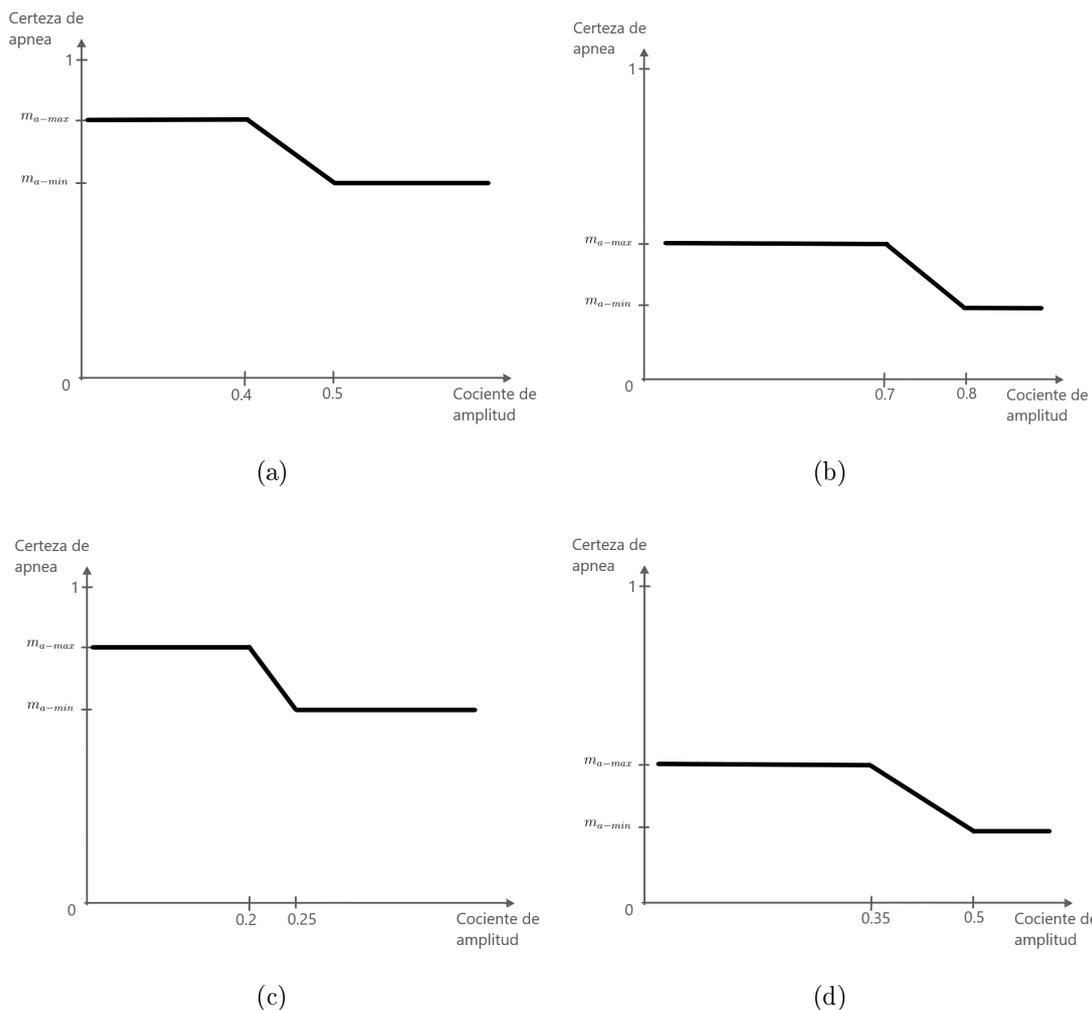


Figura 24: Arriba la representación de las funciones del cálculo de certeza para la técnica de identificación de apneas D-EDR en los casos en los que se haya identificado una apnea (a) y en los que no (b). Abajo la representación de las mismas funciones para la técnica D2-EDR (c) (d)

Los valores de certeza calculados para el análisis frecuencial se corresponden con una ventana completa de la señal ECG, mientras que los obtenidos de las técnicas de análisis temporal son relativos a los picos de la señal EDR, es decir, a algunos picos del ECG. La idea en este trabajo es otorgarle una certeza de apnea a cada pico de la señal ECG, por lo que, en el primer caso, le asignaremos la certeza obtenida para la ventana a todos los picos R contenidos en ella. Sin embargo, debido al solapamiento entre ventanas habrá algunos picos que tendrán dos certezas asignadas. En estos casos se les asignará la media de las dos certezas. Para el análisis temporal, a las muestras del EDR que no sean picos les asignaremos la media de las certezas de los picos anterior y posterior más próximos.

3.6. Fusión de resultados

La última etapa del algoritmo de detección consiste en la fusión de las seis certezas obtenidas de la etapa anterior para cada pico de la señal ECG. Esta fusión se llevará a cabo mediante un decisor estadístico basado en la teoría de la evidencia de Detspiter-Shafer que se introdujo en el apartado 2.5 y cuyo esquema general se muestra en la figura 25 donde el término de masa de probabilidad se corresponde con la certeza de apnea para el caso particular de este proyecto.

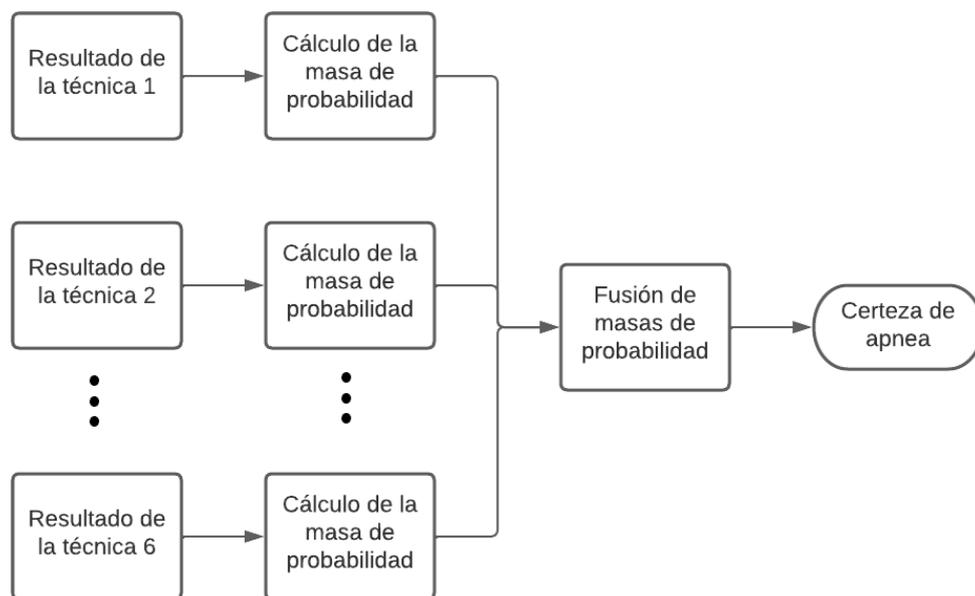


Figura 25: Diagrama de bloques del proceso de fusión de datos según la teoría de DS. Extraído de [49]

En cuanto a los parámetros utilizados en la teoría de DS y que se describieron en el apartado 2.5, para este trabajo la propuesta será la existencia de apnea, por lo que el marco de discernimiento estará formado por un único elemento:

$$\Theta = \{a\} = \{Apnea\} \quad (22)$$

Mientras que las masas de probabilidad (m_i) se corresponderán con las seis certezas calculadas, es decir, la probabilidad de apnea para cada pico R de la señal ECG. Dado

que en este trabajo se emplea una única propuesta (a), el restante de la probabilidad se le asignará a la negación de la propuesta (\bar{a}). Tras combinar las seis masas de cada pico R mediante el decisor obtendremos como resultado final del algoritmo un valor de probabilidad de apnea en cada pico R de la señal ECG.

Cada una de las masas de probabilidad estará formada por una matriz de probabilidad compuesta por la masa de la propuesta a y la masa de su negada \bar{a} .

$$m_i = \begin{bmatrix} m_i(a) = \text{probabilidad de apnea} \\ m_i(\bar{a}) = \text{probabilidad de no apnea} \end{bmatrix} \quad (23)$$

La fusión de dos masas de probabilidad se lleva a cabo mediante el producto de cada elemento de una matriz de probabilidad con los elementos de la otra matriz. En la tabla 1 podemos ver el resultado de combinar las masas m_1 y m_2 .

$m_1(a)$	$m_1(a) * m_2(a)$	$m_1(a) * m_2(\bar{a})$
$m_1(\bar{a})$	$m_1(\bar{a}) * m_2(a)$	$m_1(\bar{a}) * m_2(\bar{a})$
	$m_2(a)$	$m_2(\bar{a})$

Tabla 1: Resultado de la combinación de dos matrices de masas de probabilidad. Extraída de [49]

Es probable que tras realizar la combinación de dos matrices de probabilidad algunas de las masas obtenidas sean conjuntos vacíos (ϕ) por lo que se deben redistribuir sus probabilidades a los elementos no vacíos. Para ello se utilizará la siguiente ecuación [49]:

$$K^{-1} = 1 - \sum [m_i(\phi)] \quad (24)$$

El valor de K resultante se multiplicará por cada elemento no vacío de la matriz (tabla 2) dando como resultado, ahora sí, las probabilidades de apnea ($m(a)$) y no apnea ($m(\bar{a})$) resultantes de la combinación de las dos masas [49].

$m_1(a)$	$m(a) = m_1(a) * m_2(a) * K$	$m(\phi) = 0$
$m_1(\bar{a})$	$m(\phi) = 0$	$m(\bar{a}) = m_1(\bar{a}) * m_2(\bar{a}) * K$
	$m_2(a)$	$m_2(\bar{a})$

Tabla 2: Resultado de la combinación de dos matrices de masas de probabilidad tras aplicar la redistribución de probabilidad de los elementos vacíos. Extraída de [49]

Este procedimiento se repetirá utilizando los resultados obtenidos como una nueva matriz de probabilidad y combinándola con la matriz de otra de las masas de probabilidad hasta fusionar las seis masas y obtener la probabilidad final de apnea.

4. Red neuronal

En este apartado se va a comentar el segundo de los clasificadores utilizados en este proyecto basado en ML. Hoy en día, se habla mucho de la inteligencia artificial (IA) debido a las posibilidades que ofrece (coches autónomos, asistentes personales virtuales, automatización de procesos industriales, etc.) y que puede llegar a ofrecer en el futuro. La IA puede definirse como una tecnología con la que se dota a un sistema de funciones cognitivas como percepción, planificación, razonamiento, resolución de problemas, etc. El auge actual de esta tecnología se debe sobre todo a los avances tanto en Big Data como en la capacidad de procesamiento de los ordenadores dado que trabaja con grandes cantidades de datos. ML es una rama de la IA cuya característica principal es la capacidad del sistema de ir aprendiendo por sí mismo. Los algoritmos de ML se entrenan con grandes conjuntos de datos y aprenden de los resultados obtenidos durante ese entrenamiento.

El algoritmo que se utilizará en este clasificador es una red neuronal. Éstas se inspiran en la manera en la que el cerebro humano procesa la información y se definen como una colección de unidades más pequeñas denominadas neuronas que se conectan entre sí y se almacenan en distintas capas. En toda red neuronal existe una primera capa denominada capa de entrada, formada por neuronas que reciben los datos, y una última capa denominada capa de salida compuesta de neuronas que proporcionan el resultado visible de la red. Entre estas dos capas, pueden aparecer multitud de capas que se denominan ocultas las cuales reciben un conjunto de entradas ponderadas y producen una salida a partir de una función de activación.

Siguiendo el objetivo principal de este trabajo, la identificación de apneas en este clasificador se hará utilizando únicamente la señal ECG. Esta señal será la misma que la utilizada con el algoritmo de detección, es decir, una vez realizado el pre-procesado de la señal con la evaluación de su calidad y la eliminación de los tramos de baja calidad. Tras el pre-procesado, se dividirá la señal ECG resultante en ventanas de 30 segundos

con solapamiento de 10 segundos del mismo modo que se hizo con el primer clasificador. A cada una de estas ventanas se le asignará una de las dos posibles clases, apnea o no apnea, en función del *Ground Truth* (GT) y se comparará con el resultado obtenido de la red para evaluar su desempeño.

4.1. Extracción de características

Los datos que recibirá la capa de entrada de la red consistirán en un conjunto de características extraídas directamente de la señal ECG del paciente. El cálculo de estas características se hará sobre cada una de las ventanas de segmentación del ECG. Por tanto, se dispondrán de varios vectores, uno por cada ventana de la señal, de un tamaño igual al número de características extraídas. Se han considerado 12 características por ventana, que se detallan a continuación.

- **M-RR:** media de la duración de los intervalos entre picos R consecutivos (intervalos RR) obtenida como

$$x_{M-RR} = \sum_{i=1}^N \frac{RR_i}{N} \quad (24)$$

Donde RR es la duración de los intervalos RR y N el número de intervalos RR que contiene la ventana

- **SD-RR:** desviación estándar de la duración de los intervalos RR obtenida como

$$x_{SD-RR} = \sqrt{\frac{\sum_{i=1}^N (RR_i - x_{M-RR})^2}{N}} \quad (25)$$

- **Md-RR:** mediana de la duración de los intervalos RR. Esta característica se obtiene como el valor de la duración del intervalo RR que ocupa la posición central tras ordenar por sus valores de duración el conjunto de intervalos RR de la ventana. En caso de ser un número par de intervalos RR se obtendrá como la media de los dos valores de duración centrales
- **NN50-1:** número de pares de intervalos RR consecutivos en los que la duración del segundo intervalo supera en al menos 50 ms a la duración del primero
- **NN50-2:** número de pares de intervalos RR consecutivos en los que la duración del primer intervalo supera en al menos 50 ms a la duración del segundo

- **pNN50-1:** valor de la característica $NN50-1$ dividido entre el número de intervalos RR
- **pNN50-2:** valor de la característica $NN50-2$ dividido entre el número de intervalos RR
- **SD-NN:** desviación estándar de la diferencia de la duración de los intervalos RR adyacentes
- **RMSSD:** raíz cuadrada de la diferencia cuadrática media entre intervalos RR adyacentes obtenida como

$$x_{RMSSD} = \sqrt{\frac{\sum_{i=1}^{N-1} (RR_i - RR_{i+1})^2}{N}} \quad (26)$$

- **VLF:** componentes de muy baja frecuencia, consideradas como las frecuencias entre 0.03 y 0.06 Hz, del resultado del periodograma de Lomb-Scargle de la señal EDR
- **LF:** componentes de baja frecuencia, consideradas como las frecuencias entre 0.06 y 0.12 Hz, del resultado del periodograma de Lomb-Scargle de la señal EDR
- **HF:** componentes de alta frecuencia, consideradas como las frecuencias entre 0.12 y 0.488 Hz, del resultado del periodograma de Lomb-Scargle de la señal EDR

4.2. Estructura de la red neuronal

La red neuronal utilizada en este clasificador será una de tipo *Fully Connected* y seguirá la misma estructura que la que se propone en la documentación de Matlab para redes cuyos datos de entrada son características numéricas [57], como es el caso de este trabajo. Este tipo de redes se caracterizan porque todas las neuronas de salida de cada capa se conectan con todas las neuronas de entrada de la siguiente capa y se emplean cuando los datos de entrada están formados por características, a diferencia de las redes Convolucionales que suelen utilizarse para clasificar imágenes de dos o tres dimensiones. En la figura 26 se muestra un esquema de la estructura de la red. Los vectores de salida de cada una de las capas, denominados a partir de ahora como y , serán igual a los vectores de entrada de la siguiente capa, denominados como x . La red se compone de siete capas, una de entrada, una de salida y cinco capas ocultas que se describen a continuación.

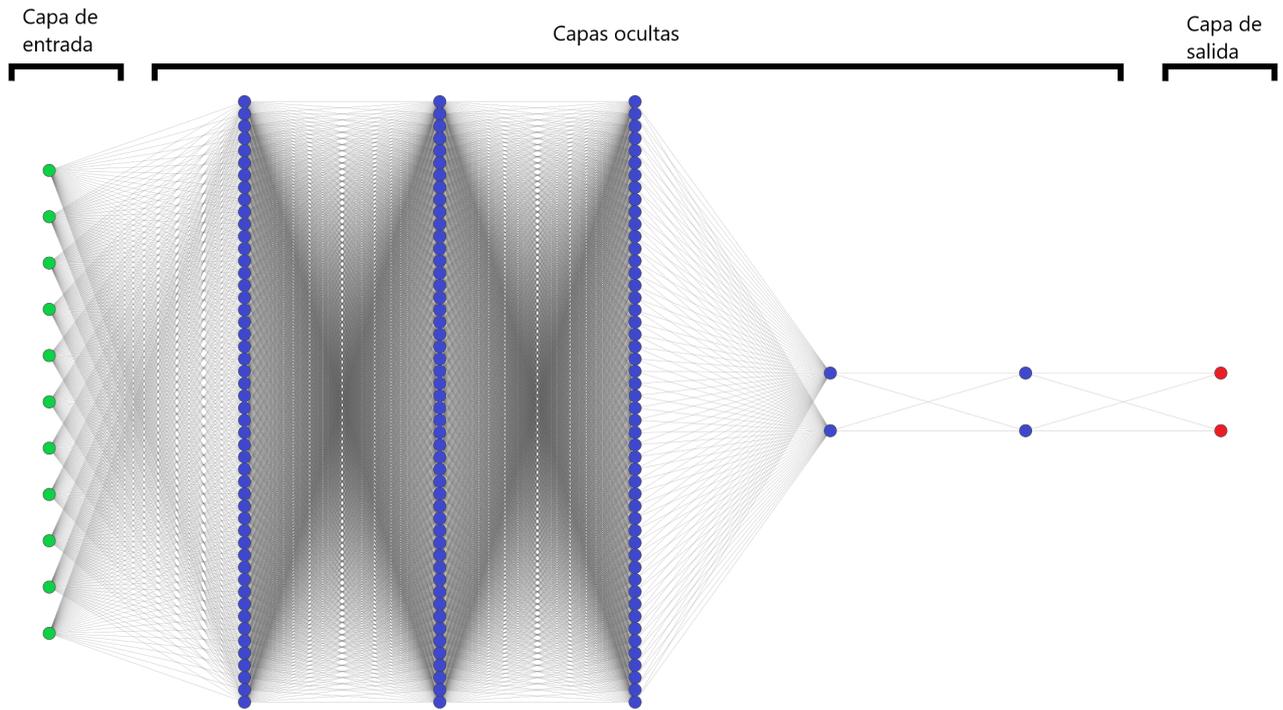


Figura 26: Esquema de la red neuronal Fully Connected

- Capa de entrada:** tiene un tamaño igual al número de características extraídas de la señal y está formada por los propios datos obtenidos del cálculo de las características. Además, en esta capa se aplica una normalización de cada valor de entrada respecto al conjunto total de los datos de entrada que se obtiene según la ecuación 27.

$$y_1 = \frac{x_1 - \bar{x}}{s} \quad (27)$$

Donde x_1 es el dato que se quiere normalizar, \bar{x} se corresponde con la media del conjunto total de los datos y s con la desviación estándar del mismo.

- Capa de convolución Fully Connected:** mediante esta capa se conectan entre sí todas las características de entrada a la red con el objetivo de tratar de identificar patrones entre ellas. Para ello se utiliza la ecuación

$$y_2 = Wx_2 + b \quad (28)$$

Donde W es una matriz de pesos de dimensiones $P \times N$ y b es un vector bias de dimensiones $P \times 1$ siendo P el tamaño de la capa anterior y N el tamaño de la propia capa de convolución. Estos parámetros se denominan parámetros de aprendizaje

dado que los valores que toman son asignados por la propia red y se van modificando durante el entrenamiento de la red. Mediante estos parámetros la red puede decidir cuánta influencia tendrán las entradas de esta capa sobre las salidas [58]. En cuanto al tamaño de la capa, se ha elegido un tamaño de 50 neuronas según otras referencias [57] por lo que a la salida (y_2) se obtendrá un vector de tamaño igual a 50.

- **Capa de normalización Batch:** el objetivo de esta capa es acelerar el proceso de entrenamiento de la red y hacerlo más estable. Para ello se lleva a cabo una normalización similar a la realizada en la capa de entrada (ecuación (27)) sobre el vector de entradas. Sin embargo, en esta caso no se aplica la normalización respecto a todo el conjunto de datos, sino que se realiza respecto a pequeños lotes de datos del conjunto total escogidos aleatoriamente. Tras la normalización, se aplica una transformación lineal mediante los parámetros de aprendizaje γ y β como se ve en la ecuación 29.

$$y_3 = \gamma x_3 + \beta \quad (29)$$

Donde x_3 es el vector de entradas ya normalizado. Los parámetros γ y β se van ajustando durante el entrenamiento y permiten modificar la media y la varianza del vector de salida con el objetivo de optimizar las capas posteriores de la red. Además, tras finalizar el entrenamiento, la red guarda estos parámetros y los utiliza como media y varianza en esta misma capa durante la evaluación [59].

- **Capa de activación ReLU (Unidad Lineal Rectificada):** en esta capa se lleva a cabo una función no lineal ReLU (30) que transforma los valores de entrada negativos en 0 y mantiene los positivos con su mismo valor de entrada [60].

$$y_4 = \begin{cases} x_4, & x_4 \geq 0 \\ 0, & x_4 < 0 \end{cases} \quad (30)$$

En las capas anteriores a esta se han llevado a cabo únicamente sumas ponderadas, o lo que es lo mismo, transformaciones lineales. El objetivo de esta capa es proporcionar una no linealidad a la red para que sea capaz de resolver problemas más complejos. Sin esta función ReLU la red se comportaría como un modelo de regresión lineal con capacidades de aprendizaje más limitadas [61].

- **Capa de convolución Fully Connected:** su comportamiento es igual al de la capa Fully Connected anterior pero en este caso el tamaño va a ser igual a dos con

el objetivo de obtener un vector de salida con tamaño igual al número de clases del clasificador, es decir, dos (apnea y no apnea).

- **Capa de activación Softmax:** en esta capa se comprimen las salidas a unos valores entre 0 y 1 de forma que la suma sea igual a 1. Para ello se utiliza la ecuación 31 que calcula la probabilidad, entre 0 y 1, de que la entrada pertenezca a cada una de las clases [62].

$$y_5 = \frac{e^{x_5}}{\sum_{j=1}^K e^{x_j}} \quad (31)$$

Donde K es el número de clases del clasificador.

- **Capa de salida:** en esta última capa se asigna a cada entrada una de las K clases mutuamente excluyentes mediante el método de entropía cruzada. Con este método se puede caracterizar la distancia entre dos distribuciones de probabilidad utilizando una función de pérdidas (32). De este modo, durante el entrenamiento de la red, se puede obtener para cada entrada la distancia entre la salida real, la probabilidad obtenida en la capa Softmax, y la salida esperada, la probabilidad real de cada clase (1 para apnea y 0 para no apnea) definida en el GT. Cuanto menor sea el valor de entropía cruzada, más cerca estarán los valores de probabilidad estimados en la capa Softmax de los valores de probabilidad esperados [63] [64].

$$f_{perdidas} = \sum_{i=1}^K t_i \log(p_i) \quad (32)$$

Donde t_i es el indicador de que la entrada evaluada pertenece a la i clase (1 o 0 en este caso) y p_i es la probabilidad obtenida en la capa de Softmax para la clase i . A partir del resultado obtenido de la función de pérdidas, la red buscará en las futuras iteraciones del entrenamiento optimizar los valores de aprendizaje del resto de capas con el objetivo de minimizar el resultado de esta función.

5. Resultados y discusión

En este apartado se van a comentar y estudiar los resultados obtenidos tanto del algoritmo de detección como la red neuronal desarrollados. Para ello, se utilizarán diferentes métricas que se explicarán en detalle más adelante y que permitirán evaluar el rendimiento del algoritmo y la red en cuanto a la identificación de apneas centrales. Por un lado, se analizará el desempeño del algoritmo comenzando por evaluar individualmente cada uno de los seis métodos de detección con el fin de conocer su rendimiento por separado. A continuación, se repetirá el proceso de evaluación aplicando esta vez las métricas al resultado de la fusión de los datos de los seis métodos. Por otro lado, se analizarán los resultados obtenidos de la red neuronal para, finalmente, compararlos con los obtenidos del algoritmo tras el proceso de fusión.

5.1. Base de datos

La base de datos utilizada en el proyecto ha sido proporcionada por el Hospital Universitario de Guadalajara (HUGU). En ella se recogen los resultados de doce pruebas de polisomnografía realizadas a pacientes reales con trastornos del sueño con edades comprendidas entre los 20 y los 62 años y de ambos sexos. Las pruebas se realizaron durante una noche completa con una duración de entre 7 y 9 horas y se obtuvieron como resultados las señales que se definen a continuación, aunque no todas se utilizarán en este trabajo.

- Dos señales de electrooculograma (EOG) que registran el movimiento de los ojos obtenidas con dos derivaciones: E1-M2, E2-M1
- Seis señales de electroencefalograma (EEG) que registran las actividades del cerebro obtenidas mediante seis derivaciones: C4-M1, F4-M1, O2-M1, F3-M2, C3-M2, O1-M2

- Chin1-Chin2: señal de electromiograma (EMG) la cual registra la actividad eléctrica producida por los músculos
- ECG: señal de electrocardiograma
- Ronquido: registra el sonido producido por los ronquidos del paciente
- Canula: registra el flujo oronasal obtenido mediante una cánula nasal
- Termistor: registra el flujo oronasal obtenido mediante un termistor
- Torax: registra el movimiento del tórax
- Abdomen: registra el movimiento del abdomen
- Torax+Abdomen: formada por la suma de las señales de Torax y Abdomen
- SaO2: señal de saturación de oxígeno la cual registra el nivel de oxígeno en sangre
- Leg/L: registra el movimiento de la pierna izquierda
- Leg/R: registra el movimiento de la pierna derecha
- FC: registra la frecuencia cardíaca
- Posicion: registra la posición del paciente
- tPCO2: señal de presión transcutánea de CO2 la cual registra la presión de dióxido de carbono sobre la piel

Durante cada prueba de polisomnografía, los médicos anotaron los instantes de inicio y duración de cada apnea además de su tipo, clasificándolas como apnea central (CEN), apnea obstructiva (OBS), apnea mixta (MIX) e hipopnea (HYP). Estas anotaciones serán las que se utilizarán en este trabajo como *Ground Truth* a la hora de evaluar el rendimiento de los dos clasificadores.

En la tabla 3 se muestran los datos de cada uno de los pacientes que se sometieron a la prueba así como la duración de la misma y el número de apneas de cada tipo que se registraron en cada uno.

ID	Edad	Sexo	Duración (horas)	CEN	OBS	MIX	HYP
P01	55	M	6.75	0	31	114	101
P02	62	M	8	2	1	123	94
P03	48	M	6.70	2	9	10	87
P04	53	F	7.95	0	2	13	50
P05	36	M	7.14	0	1	8	133
P06	49	F	6.58	1	2	0	112
P07	24	M	8	11	27	49	124
P08	49	F	7.83	0	0	2	107
P09	20	F	8.02	0	0	8	48
P10	56	M	8	0	12	72	237
P11	44	F	8.17	4	1	13	82
P12	60	F	6.92	2	1	70	91

Tabla 3: Información de la base de datos utilizada

Como puede verse en la tabla 3, el número total de apneas centrales registradas durante las pruebas es muy bajo y éstas se produjeron tan solo en 6 de los 12 pacientes. Además, se ha descartado el uso de la señal ECG del paciente 7 dado que al realizar la evaluación de calidad de la señal, se eliminó una gran parte de la señal (54 %) debido a su mala calidad. Por tanto, para este estudio se disponen de un total de 11 apneas centrales procedentes de 5 pacientes diferentes.

5.2. Métricas de evaluación

Para evaluar correctamente el desempeño de los dos clasificadores, se van a emplear algunas de las métricas de evaluación más utilizadas a día de hoy en modelos de clasificación. Comparando los resultados arrojados por el algoritmo y la red con los diferentes GT de apneas se van a obtener unos parámetros estadísticos a partir de los cuales se calcularán las métricas de evaluación. Estos parámetros son los que se definen a continuación.

- **Verdadero Positivo (VP):** el tramo de la señal ECG se ha clasificado correctamente como apnea

- **Verdadero Negativo (VN):** el tramo de la señal ECG se ha clasificado correctamente como no apnea
- **Falso Positivo (FP):** el tramo de la señal ECG se ha clasificado incorrectamente como apnea
- **Falso Negativo (FN):** el tramo de la señal ECG se ha clasificado incorrectamente como no apnea

Utilizando estos parámetros de la matriz de confusión se van a calcular las métricas de sensibilidad (Se), especificidad (Sp), precisión ($Prec$) y exactitud (Acc), ya que son las más utilizadas en la literatura para evaluar clasificadores binarios. La Se se define como la capacidad del clasificador de identificar correctamente los casos positivos, las apneas en este proyecto, mientras que la Sp se define como la capacidad del clasificador de identificar correctamente los casos negativos, las no apneas. La $Prec$, por otro lado, indica la proporción de positivos predichos por el clasificador que realmente lo son, y la Acc evalúa su capacidad de realizar predicciones correctas, tanto de casos positivos como negativos. Estos indicadores se suelen expresar en tanto por ciento y su valor se obtiene como se muestra a continuación.

$$Se = \frac{VP}{VP + FN} \cdot 100 \quad (33)$$

$$Sp = \frac{VN}{VN + FP} \cdot 100 \quad (34)$$

$$Prec = \frac{VP}{VP + FP} \cdot 100 \quad (35)$$

$$Acc = \frac{VP + VN}{VP + VN + FN + FP} \cdot 100 \quad (36)$$

5.3. Procedimiento del análisis del algoritmo de detección

Para el caso del algoritmo de detección se van a analizar tanto los resultados de los seis métodos que lo componen como el resultado obtenido del proceso de fusión. Estos resultados se corresponden con una certeza evaluada como un tanto por ciento donde un valor de 100 % se correspondería con una certeza absoluta de la existencia de una apnea y un 0 % con una certeza absoluta de su no existencia. Para clasificar los resultados según los parámetros estadísticos definidos anteriormente, se comparará la certeza obtenida con un determinado umbral el cual va a tomar tres valores diferentes, 50 %, 75 % y 90 %.

Como se vio en el apartado 3.5, la asignación de las certezas obtenidas de cada una de las tres técnicas del algoritmo de detección se hace sobre tramos de la señal ECG. Para la técnica F-EDR, la certeza se asigna sobre todos los picos R contenidos en una ventana de 30 segundos mientras que en las técnicas D-EDR y D2-EDR, se hace sobre un conjunto de picos consecutivos de la señal EDR. Si la certeza de apnea otorgada a estos tramos supera el umbral utilizado, se considerará que se ha producido una apnea en dicho tramo. A continuación, se evaluará cada uno de estos tramos identificados como apnea comparándolos con los GT con el objetivo de obtener los parámetros estadísticos definidos al comienzo del capítulo. En la figura 27 se muestra un diagrama de bloques del proceso seguido para obtener estos parámetros. En los casos en los que un tramo coincida temporalmente con al menos 10 segundos de la duración de una apnea del GT, se considerará dicho tramo como VP. En caso contrario, si no coincide con una apnea, será un FP. Del mismo modo, en los tramos en los que la certeza no supere el umbral, se considerará que se ha producido un FN por cada apnea del GT. Por último, en las zonas restantes del ECG, zonas en las que la certeza no supera el umbral y no se ha producido una apnea según el GT, se contará un VN por cada 10 segundos de duración de la señal ECG.

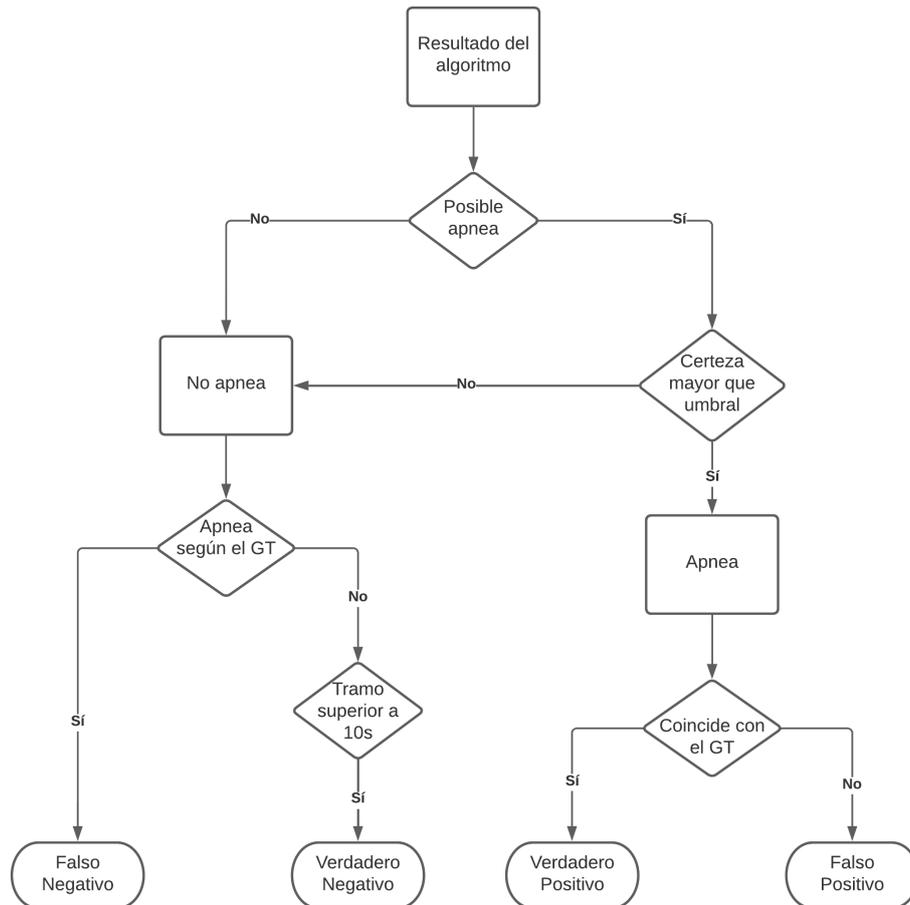


Figura 27: Proceso de obtención de los parámetros estadísticos para el algoritmo de detección

5.4. Resultados del algoritmo de detección

Dado que el objetivo principal de este trabajo es la identificación de apneas centrales y los métodos de detección utilizados se centran en este tipo, se comenzará realizando una prueba empleando únicamente los GT de apneas centrales correspondientes a los 5 pacientes que sufrieron alguna apnea central por lo que se dispondrán de los datos mostrados en la tabla 4. Se analizarán tanto los resultados obtenidos de los seis métodos del algoritmo como los resultados obtenidos del proceso de fusión.

Tipo de apnea	Nº apneas
Centrales	11

Tabla 4: Datos empleados en el análisis del algoritmo de detección con el GT de apneas centrales

Al emplear únicamente los GT de apneas centrales en este análisis los instantes en los que se hayan producido apneas obstructivas, mixtas e hipopneas van a ser considerados como no apneas lo que va a provocar que aparezcan numerosos FP dado que el algoritmo puede detectar que se ha producido una apnea en esos instantes.

Se comenzará evaluando el algoritmo para un umbral del 50 % cuyos resultados se muestran en la tabla 5. Para este valor de umbral el cálculo de la certeza en los casos en que cualquiera de los seis métodos identifique una apnea en un tramo no va a ser relevante dado que la certeza mínima (60 %) otorgada en estos casos es superior al umbral. Y por eso los tramos de la señal ECG correspondientes a estos casos se van a clasificar siempre como positivos, ya sea como verdaderos positivos o falsos positivos.

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
F-EDR_area	11	0	10335	453	100	95.80	2.37	95.80
D-EDR_area	9	2	11417	519	81.82	95.65	1.70	95.64
D2-EDR_area	7	4	11662	400	63.63	96.68	1.72	96.65
F-EDR_amp	11	0	10524	452	100	95.88	2.38	95.89
D-EDR_amp	8	3	11416	519	72.73	95.65	1.52	95.63
D2-EDR_amp	8	3	11633	407	72.73	96.62	1.93	96.60
Fusión	9	2	11626	353	81.82	97.92	3.46	97.91

Tabla 5: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 50 % y el GT de apneas centrales

Como puede verse en la tabla anterior los métodos que ofrecen mejores resultados respecto a la identificación de apneas centrales son los dos basados en el análisis frecuencial obteniendo una sensibilidad del 100 %. A pesar de que en el resto de métodos la sensibilidad es menor, llegando incluso a ser de 63.63 % para el método D-EDR_área, tras el proceso de fusión se obtiene un resultado por encima del 80 %. Además, se cumple lo comentado anteriormente referente al elevado número de FP debido a que no se están teniendo en cuenta las apneas del resto de tipos y se están considerando como no apneas. Esto sumado al escaso número total de positivos provoca que se obtengan unos resultados muy bajos de precisión en todos los casos. A diferencia de lo que ocurre con los negativos, donde puede verse que el algoritmo funciona bien obteniéndose buenos resultados de especificidad. Esto sumado a la gran diferencia en el número de datos negativos respecto

a los positivos provoca que se obtengan también buenos resultados en exactitud.

En la tabla 6 se muestran los resultados obtenidos tras repetir la evaluación pero modificando el valor del umbral a un 75 %. A diferencia de la prueba anterior, en este caso no todos los tramos identificados como apnea por los diferentes métodos van a ser finalmente clasificados como positivos debido a que ahora el umbral es superior a la certeza mínima de apnea.

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
F-EDR_area	7	4	11307	236	63.64	97.96	2.88	97.92
D-EDR_area	6	5	12001	127	54.55	98.95	4.51	98.91
D2-EDR_area	1	10	11846	169	9.09	98.59	0.59	98.51
F-EDR_amp	8	3	11368	214	72.73	98.15	3.60	98.13
D-EDR_amp	4	7	11482	152	36.36	98.69	2.56	98.63
D2-EDR_amp	3	8	12125	168	27.27	98.63	1.75	98.57
Fusión	9	2	11869	251	81.82	97.93	3.46	97.91

Tabla 6: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 75 % y el GT de apneas centrales

Como era de esperar, al incrementar el umbral se van a reducir el número de positivos e incrementar los negativos. La sensibilidad baja notablemente en todos los métodos llegando a valores por debajo del 80 % e incluso a menos de un 10 % en el caso del método D2-EDR_area. A pesar de esto, tras el proceso de fusión se obtiene el mismo resultado de 81.82 % que para el análisis con el umbral al 50 % lo que demuestra la utilidad de la fusión de datos. Sin embargo esto no siempre es así como puede verse en los casos de especificidad y exactitud donde los resultados tras la fusión son algo peores que en los métodos por separado.

Por último, en la tabla 7 se pueden ver los resultados de los análisis para un umbral del 90 %. Dado que ninguno de los seis métodos tiene un nivel de certeza máximo superior a este valor de umbral, no se va a identificar ningún positivo por separado. Sin embargo, tras el proceso de fusión el nivel de certeza total puede aumentar y superar el 90 % por lo que en este caso tan solo se mostrarán los resultados obtenidos tras la fusión.

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
Fusión	7	4	11803	170	63.64	98.58	3.95	98.55

Tabla 7: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 90 % y el GT de apneas centrales

Como puede observarse tras la fusión el algoritmo de detección es capaz de identificar hasta siete apneas centrales con más de un 90 % de certeza a pesar de que ninguno de los seis métodos por separado supera en ningún caso el valor de 80 % de certeza.

Una vez evaluado el rendimiento del algoritmo de detección en la identificación de apneas centrales, se repetirá el estudio incluyendo en el análisis los GT de todos los pacientes válidos pero excluyendo los GT de las hipopneas. La definición de este tipo de apneas se aleja más de la de apnea central en comparación con las definiciones de las de tipo obstructiva y mixta. Por tanto, dado que los métodos utilizados en este trabajo se basan en la identificación de apneas centrales, se espera que el algoritmo sea capaz de identificar mejor las apneas de tipo obstructiva y mixta que las hipopneas.

De forma similar a como ocurría en la prueba anterior, al no tener en cuenta los GT de hipopneas, los tramos en los que se hayan producido apneas de este tipo serán considerados como no apnea. En esta prueba se utilizarán todos los pacientes válidos (once pacientes) por lo que se dispondrán del número de apneas que se muestra en la tabla 8.

Tipo de apnea	Nº apneas
Centrales	11
Obstructivas	60
Mixtas	431

Tabla 8: Datos empleados en el análisis del algoritmo de detección con los GT de apneas centrales, obstructivas y mixtas

Se comenzará mostrando en la tabla 9 los resultados del análisis para un umbral de 50 %. Al incluir en el análisis los GT de apneas obstructivas y mixtas podría esperarse que el número de FP correspondientes en las evaluaciones anterior a las detecciones de este tipo de apneas disminuyese. Sin embargo, hay que recordar que se ha aumentado el

número de pacientes evaluados de 5 a 11 y además se sigue dejando fuera del análisis los GT de hiponeas por lo que por esta parte el número de FP va a aumentar.

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
F-EDR_area	317	185	19971	1248	64.15	94.12	20.26	93.40
D-EDR_area	152	350	23189	1293	30.28	94.72	10.52	93.42
D2-EDR_area	132	370	23772	1145	26.29	95.40	10.34	94.04
F-EDR_amp	285	217	20383	1259	57.77	94.18	18.46	93.33
D-EDR_amp	141	361	23222	1309	28.09	94.66	9.72	93.33
D2-EDR_amp	146	356	23785	1135	29.08	95.45	11.40	94.14
Fusión	164	338	23641	1083	32.67	95.62	13.65	94.37

Tabla 9: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 50 % y el GT de apneas centrales, obstructivas y mixtas

Se mantiene la misma tónica que en la evaluación de apneas centrales siendo las técnicas basadas en el análisis frecuencial las que mejores resultados ofrecen en la identificación de apneas. En el resto se obtienen valores de especificidad más pobres lo que provoca que el resultado de sensibilidad tras la fusión sea bajo. Tal y como se esperaba el número de FP ha aumentado respecto a la prueba anterior debido al aumento en el número de datos. Sin embargo, los resultados de precisión son notablemente mejores debido al consiguiente aumento en el número de positivos. Respecto a los valores de especificidad y exactitud se mantienen en los mismos valores que en la prueba de apneas centrales debido a la gran diferencia entre las dos clases.

A continuación se muestran los resultados de la misma prueba para un valor del umbral del 75 %.

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
F-EDR_area	153	349	23598	646	30.48	97.33	19.15	95.98
D-EDR_area	56	446	24692	569	11.16	97.75	8.96	96.06
D2-EDR_area	55	447	24928	620	10.96	97.57	8.15	95.90
F-EDR_amp	135	367	23786	583	26.89	97.61	18.80	96.18
D-EDR_amp	56	446	24450	620	11.16	97.53	8.28	95.83
D2-EDR_amp	61	441	25107	613	12.15	97.62	9.05	95.98
Fusión	102	400	24307	851	20.32	96.62	10.70	95.12

Tabla 10: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 75 % y el GT de apneas centrales, obstructivas y mixtas

Al igual que en la prueba de apneas centrales el número de VP positivos en cada método se reduce considerablemente respecto al análisis con el umbral de 50 % aunque no lo hace tanto el obtenido tras la fusión. Sin embargo, en cuanto a los FP puede verse en este caso como la fusión de los datos provoca unos resultados peores en comparación con los de los métodos individuales.

En cuanto a la prueba con el valor de umbral en 90 % puede verse en la tabla 11 como el algoritmo de detección de apenas es capaz de identificar un 15 % de las mismas.

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
Fusión	75	427	25233	657	14.94	97.39	10.25	95.78

Tabla 11: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 90 % y el GT de apneas centrales, obstructivas y mixtas

Por último, se van a añadir al análisis los GT de hipopneas utilizando la base de datos al completo con el objetivo de comprobar cual sería el desempeño del clasificador en una prueba real. Se repetirán las tres evaluaciones utilizando los mismos pacientes que en el caso de la prueba anterior por lo que dispondremos de los datos que se muestran en la tabla 12.

Tipo de apnea	Nº apneas
Centrales	11
Obstructivas	60
Mixtas	431
Hipopneas	1123

Tabla 12: Datos empleados en el análisis del algoritmo de detección con los GT de apneas centrales, obstructivas, mixtas e hipopneas

Como se puede ver en las tablas 13, 14 y 15 los resultados obtenidos siguen la misma línea de lo que se ha ido observando en las pruebas anteriores. El número de VP aumenta respecto a la prueba anterior pero lo hace en mayor proporción el de FN lo que provoca peores resultados de sensibilidad indicando que el algoritmo no tiene un buen desempeño en la identificación de hipopneas.

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
F-EDR_area	943	682	18007	862	58.03	95.43	52.24	92.47
D-EDR_area	447	1178	20376	1012	27.51	95.27	30.64	90.48
D2-EDR_area	370	1255	20853	913	22.77	95.81	28.84	90.73
F-EDR_amp	878	747	18334	874	54.03	94.45	50.11	92.22
D-EDR_amp	442	1183	20424	1022	27.20	95.23	30.19	90.44
D2-EDR_amp	388	1237	20888	896	23.88	95.89	30.22	90.89
Fusión	431	1194	20839	825	25.52	96.19	34.32	91.33

Tabla 13: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 50% y el GT de apneas centrales, obstructivas, mixtas e hipopneas

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
F-EDR_area	482	1143	20880	443	29.66	97.92	52.11	93.09
D-EDR_area	172	1453	21605	452	10.58	97.95	27.56	91.96
D2-EDR_area	173	1452	21846	503	10.65	97.75	25.59	91.85
F-EDR_amp	418	1207	21022	400	25.72	98.13	51.10	93.03
D-EDR_amp	186	1439	21745	491	11.45	97.79	27.47	91.91
D2-EDR_amp	180	1445	21963	495	11.08	97.80	26.67	91.94
Fusión	303	1322	21388	656	18.65	97.02	31.60	91.64

Tabla 14: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 75 % y el GT de apneas centrales, obstructivas, mixtas e hipopneas

Método	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
Fusión	224	1401	21541	511	13.78	97.68	30.48	91.92

Tabla 15: Resultados de las métricas sobre el análisis del algoritmo de detección para un umbral del 90 % y el GT de apneas centrales, obstructivas, mixtas e hipopneas

5.5. Procedimiento del análisis de la red neuronal

Los resultados obtenidos de la red neuronal, clasificados como apnea o no apnea, se corresponden con tramos de la señal ECG de una duración de 30 segundos como se ha comentado anteriormente. Para poder comparar correctamente los resultados con los diferentes GT de apneas, éstos se dividirán de la misma forma que su señal ECG correspondiente y se le asignará a cada tramo de 30 segundos de duración una de las dos clases. Para considerar un tramo del GT como apnea, éste debe contener un tramo de apnea de al menos 10 segundos de duración.

Debido a la escasez de apneas, especialmente de apneas centrales, de la base de datos (tabla 3), aparece un problema de desbalanceo de datos entre las dos clases, apnea y no apnea, debido a que la duración de los tramos en los que el paciente no ha sufrido ninguna apnea es superior a la de los tramos en los que ha sufrido alguna. Debido a este problema, el desempeño de la red neuronal puede bajar por lo que, a la hora de escoger los datos de entrada, reduciremos el número de los datos pertenecientes a la clase mayoritaria, la de

no apnea, para que no haya tanta diferencia entre ambas clases aunque esto suponga que no se utilicen todos los datos disponibles. Para evitar esto último, cada prueba se repetirá varias veces escogiendo aleatoriamente los datos de entrada, tanto de entrenamiento como de evaluación. De este modo se aprovecharán mejor los pocos datos sobre apneas de los que se dispone dado que en cada iteración los datos de entrenamiento y evaluación serán unos datos diferentes.

Antes de evaluar la red, se va a realizar una prueba al conjunto de características extraídas de las señales ECG con el objetivo de descartar aquellas características que puedan reducir el desempeño de la red y evitar el sobreentrenamiento. Para ello se va a realizar varias pruebas descartando en cada prueba una de las características. Se realizaron 100 iteraciones para cada prueba empleando únicamente los datos relativos a las apneas centrales y cambiando en cada iteración los datos utilizados de manera aleatoria. En la tabla 16 se muestra el número total de datos disponibles de la base de datos y los que se utilizarán en cada iteración para el entrenamiento y evaluación de la red. Como se dijo anteriormente, no se van a emplear todos los datos disponibles de la clase mayoritaria debido al desbalanceo entre las dos clases. En lugar de eso se escogerá un número de datos de modo que la clase minoritaria represente un 10 % de datos de la mayoritaria. Para ello, en cada prueba se utilizarán todos los datos disponibles de apneas y el número de datos de no apneas necesario para cumplir la proporción comentada. Respecto al número de datos empleados para el entrenamiento y la evaluación, en el caso de los datos de la clase apnea se van a repartir siguiendo la proporción habitual empleada en la literatura de un 80 % de los datos para entrenamiento y un 20 % para evaluación. En cuanto a los datos de la clase no apnea, se utilizarán para entrenamiento aproximadamente un 250 % más de datos respecto a los utilizados en la clase apnea para entrenamiento. El resto de los datos de esta clase se emplearán para evaluación.

	Nº total de datos	Entrenamiento	Evaluación
Apneas centrales	11	8	3
No apneas	10953	20	80

Tabla 16: Datos empleados en el análisis de las características que se utilizarán para evaluar la red neuronal

En la tabla 17 se presentan ver los resultados de la evaluación de la red para las

100 iteraciones obtenidos de las métricas utilizando todas las características y en la tabla 18 los obtenidos para cada prueba eliminando una características. Para decidir cuales se eliminarán en los futuros análisis, se evalúa la capacidad de la red para identificar las apneas, es decir, en el parámetro de sensibilidad. Un valor alto de sensibilidad significará que la red tiene un rendimiento mejor sin esa característica eliminada. Se descartarán las características de los casos en los que este parámetro sea superior a un 85% que, tal y como se ve en la tabla 17, se da en las pruebas en las que se han eliminado las características *Md_RR*, *NN50_1*, *pNN50_1* y *VF*.

Características	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
Todas	246	54	7430	570	82	92.88	30.15	92.48

Tabla 17: Resultados de las métricas sobre el análisis de todas las características en la red neuronal

Característica eliminada	VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
M_RR	241	59	7412	588	80.33	92.65	29.07	92.20
SD_RR	224	76	7378	622	74.67	92.23	26.48	91.59
Md_RR	261	39	7452	548	87	93.15	32.26	92.93
NN50_1	257	43	7369	631	85.67	92.11	28.94	91.88
NN50_2	248	52	7431	569	82.67	92.89	30.35	92.52
pNN50_1	257	43	7434	566	85.67	92.93	31.23	92.66
pNN50_2	254	46	7428	572	84.67	92.85	30.75	92.55
SDNN	242	58	7453	547	80.67	93.16	30.67	92.71
RMSSD	244	56	7482	518	81.33	93.53	32.02	93.08
VLF	253	47	7404	596	84.33	92.55	29.80	92.25
VF	259	41	7445	555	86.33	93.06	31.81	92.82
HF	249	51	7414	586	83	92.68	29.82	92.33

Tabla 18: Resultados de las métricas sobre el análisis del desempeño de cada característica en la red neuronal

5.6. Resultados de la red neuronal

Una vez realizada la evaluación sobre las características de la red y descartadas las que no se utilizarán, se comienza, igual que con el otro clasificador, realizando un análisis únicamente sobre las apneas centrales. Los datos serán los mismos que en la prueba anterior sobre el conjunto de características y que pueden verse en la tabla 16. Se realizarán de nuevo 100 iteraciones empleando cada vez unos datos de entrada diferentes. En la tabla 19 podemos ver los resultados obtenidos de las métricas para esta prueba.

VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
266	34	7494	506	88.67	93.68	34.46	93.49

Tabla 19: Resultados de las métricas sobre el análisis de la red neuronal y el GT de apneas centrales

Como se puede observar los resultados en cuanto a la identificación de apneas centrales son bastante buenos llegando casi al 90 % de sensibilidad. Además, tampoco se ha obtenido un gran número de FP respecto al número total de negativos empleados, lo que provoca un buen nivel de especificidad. Sin embargo, al compararlos con los VP los resultados son peores, como se observa en el valor de precisión. Esto es un síntoma claro del problema del desbalanceo de datos entre clases. A pesar de eso, el desempeño de la red en general a la hora de diferenciar apneas centrales de casos de no apnea es bueno con un valor de exactitud del 93.49 %.

A continuación se repite la prueba con las apneas de tipos central, obstructiva y mixta para la que se dispondrán de los datos que se ven en la tabla 20, siguiendo la mismas proporciones de datos que en las evaluaciones anteriores. En este caso, dado que se disponen de mayor cantidad de datos, se realizarán 50 iteraciones pero alternado también los datos en cada una. Los resultados obtenidos se muestran en la tabla 21.

	Nº total de datos	Entrenamiento	Evaluación
Apneas centrales	11	8	3
Apneas obstructivas	104	83	21
Apneas mixtas	739	591	148
No apneas	10953	2100	6400

Tabla 20: Datos empleados en el análisis de la red neuronal con los GT de apneas centrales, obstructivas y mixtas

VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
4545	4055	291982	28018	52.85	91.24	13.96	90.24

Tabla 21: Resultados de las métricas sobre el análisis de la red neuronal y el GT de apneas centrales, obstructivas y mixtas

Los resultados obtenidos son peores en todos los casos pero especialmente en el valor de sensibilidad donde baja hasta casi un 50%. En este trabajo se emplean clasificadores binarios por lo que todas las apneas se han considerado como una única clase independientemente de su tipo. Al hacer esto es posible que el desempeño de la red baje dado que las características extraídas de la señal ECG y utilizadas para entrenar la red no sean tan parecidas según el tipo de apnea.

Por último, vamos a realizar la misma prueba que en el caso anterior pero añadiendo el GT de hipopneas para utilizar la base de datos al completo. Se realizarán 30 iteraciones con los datos mostrados en la tabla 22 obteniéndose los resultados que se muestran en la tabla 23.

	Nº total de datos	Entrenamiento	Evaluación
Apneas centrales	11	8	3
Apneas obstructivas	104	83	21
Apneas mixtas	739	591	148
Hipopneas	2251	1800	451
No apneas	10953	6200	4753

Tabla 22: Datos empleados en el análisis de la red neuronal con los GT de apneas centrales, obstructivas, mixtas e hipopneas

VP	FN	VN	FP	Se(%)	Sp(%)	Prec(%)	Acc(%)
6418	12272	129891	12699	34.34	91.09	33.57	84.52

Tabla 23: Resultados de las métricas sobre el análisis de la red neuronal y el GT de apneas centrales, obstructivas, mixtas e hipopneas

Al introducir otro tipo de apnea más en la evaluación los resultados obtenidos tanto en sensibilidad como en exactitud son aún peores siguiendo lo comentado en la evaluación anterior. En cuanto al nivel de precisión se ve como su valor es considerablemente mejor, sin embargo, esto se debe a que la proporción de los datos de la clase no-apnea utilizados para la evaluación respecto a los utilizados para entrenamiento es menor en comparación con las pruebas anteriores. Como prueba puede verse que el valor de especificidad es prácticamente el mismo que en la evaluación anterior.

5.7. Comparativa entre los dos clasificadores

Como se ha ido comentado a lo largo del capítulo el principal problema que se ha encontrado en este trabajo es el escaso número de datos positivos, apneas centrales, en comparación con los negativos, las no apneas. A pesar de ello, con los pocos datos de los que se disponen, el desempeño de ambos clasificadores en cuanto a la identificación de apneas centrales es bueno llegando a ser superior a un 80 % con una certeza del 75 % en el caso del algoritmo de detección y casi de un 90 % en el caso de la red neuronal. El desbalanceo de clases provoca también que los resultados de exactitud en las distintas pruebas no sean del todo representativos puesto que los altos valores obtenidos se deben sobre todo al buen desempeño de los clasificadores en la identificación de la clase de no apneas más que de la de apneas.

Respecto a la prueba de evaluación de apneas centrales hay que destacar también que en el caso de la red únicamente se utilizan datos de apneas centrales y no apneas, a diferencia del algoritmo de detección donde se utilizan todos los datos considerando además a los tramos de apneas pertenecientes al resto de tipos como no apneas. Por un lado esto supone que la red es capaz de diferenciar fácilmente las dos clases cuando se trata únicamente de apneas centrales pero no es representativo de una prueba real dado que lo normal es que se produzcan apneas de varios tipos. Por otro lado esto provoca unos

resultados pobres en cuanto a precisión en el algoritmo de detección puesto que se están tratando como no apneas tramos donde sí se produjeron.

Por lo general, la red neuronal ofrece mejores resultados que el algoritmo de detección en las pruebas de apneas centrales, debido sobre todo al hecho de que únicamente se emplean los datos de este tipo de apneas, excluyendo el resto de tipos. Esto supone que la red es capaz de diferenciar fácilmente las dos clases cuando se trata únicamente de apneas centrales. Sin embargo, al incluir otros tipos de apnea en la evaluación el desempeño de la red se reduce considerablemente

Cuando se introducen el resto de tipos en la evaluación el rendimiento de ambos clasificadores se reduce considerablemente. En el caso del algoritmo, este descenso se debe sobre todo a los malos resultados de las técnicas de análisis temporal puesto que éstas se basan en la reducción del esfuerzo respiratorio, lo cual se produce durante una apnea central. En cuanto a la red neuronal, como se ha comentado, el descenso del rendimiento probablemente se deba a la diferencia entre características extraídas de las señales ECG según el tipo de apnea. Esto se acentúa más en el caso de las hipopneas dado que su definición difiere en gran medida con las del resto de tipos.

6. Conclusiones y trabajo futuro

En este último apartado se resumen las conclusiones finales obtenidas a lo largo del proyecto y se proponen algunas posibles líneas de trabajo para el futuro.

6.1. Conclusiones

El objetivo principal de este TFM consiste en la identificación de apneas centrales utilizando únicamente la señal ECG de pacientes reales. Para alcanzar dicho objetivo se han desarrollado dos clasificadores, uno basado en un decisor estadístico y otro en técnicas de ML. En el primero de ellos se han seguido los siguientes pasos:

- Pre-procesado de las señales ECG incluyendo una etapa de corrección de saturación de la misma debido a problemas en la adquisición de las señales utilizadas en este trabajo
- Localización de los picos R de las señales ECG utilizando una técnica basada en el algoritmo de Pan-Tompkins y evaluación de la calidad de dicha señal mediante algoritmos de calidad SQI
- Estimación de la señal EDR de dos maneras diferentes, una a partir del área alrededor de los picos R (EDR_área) y otra según la amplitud de dichos picos (EDR_amp)
- Desarrollo de tres técnicas de identificación de apneas, una basada en un análisis frecuencial (F-EDR) que consiste en el uso del periodograma de Lomb-Scargle sobre tramos de la señal EDR y dos basadas en análisis temporales (D-EDR y D2-EDR) que consisten en el estudio de la disminución de la amplitud de dicha señal
- Cálculo de la certeza de apnea para cada técnica desarrollada y posterior fusión de las certezas mediante un decisor estadístico basado en la teoría de la evidencia de Dempster-Shafer

Las tres técnicas de identificación de apneas se han aplicado sobre las dos señales EDR estimadas obteniéndose 6 resultados diferentes. Los mejores resultados en la identificación de apneas centrales se han obtenido con la técnica de análisis frecuencial. Con una certeza de existencia de apnea del 75 %, con la técnica F-EDR_área se ha obtenido una sensibilidad de 64 % mientras que en la técnica F-EDR_amp la sensibilidad obtenida es del 73 %. Las técnicas D-EDR_área y D-EDR_amp han reportado una sensibilidad del 55 % y 36 % respectivamente con un nivel de certeza del 75 %. Por último, para la misma certeza, con las técnicas D-EDR_área y D-EDR_amp se han obtenido los peores resultados con un 9 % y un 27 % de sensibilidad respectivamente. Tras el proceso de fusión se han obtenido mejores resultados generalmente. Para una certeza del 75 % se ha conseguido una sensibilidad del 82 % mientras que para una certeza del 90 % el resultado es de un 64 %.

Para el segundo clasificador se han llevado a cabo los siguientes pasos:

- Extracción de 12 características de la señal ECG aunque finalmente se utilizaron únicamente 8, seis basadas en la obtención de características a partir de la duración de los picos R y dos basadas en análisis frecuenciales de la señal
- Diseño de una red neuronal *Fully Connected* de siete capas, con una capa de entrada, una de salida y cinco capas ocultas, utilizando como entradas a la red la características extraídas de la señal ECG

Los resultados obtenidos de la red en la identificación de apneas centrales son superiores a los del algoritmo de detección con una sensibilidad del 89 %.

6.2. Trabajo futuro

A pesar de que se han obtenido resultados satisfactorios en cuanto a la detección de apneas de tipo central, se proponen a continuación algunas mejoras que podrían implementarse en el futuro.

- Debido al escaso número de apneas centrales disponibles para el estudio, no se han podido validar los clasificadores de forma tan exhaustiva como se hubiese deseado por lo que una de las primeras pruebas a realizar en el futuro sería la de evaluar los dos clasificadores con una base de datos de apneas centrales mucho más extensa

- En este trabajo únicamente se ha calculado la certeza de existencia de apnea en diferentes tramos de la señal ECG mientras que la certeza de la no existencia de apnea se calcula como la negación de la certeza de apnea. Se propone por tanto realizar el estudio de la certeza de la no existencia de apnea con el objetivo de mejorar el proceso de fusión de datos del algoritmo de detección basado en la teoría de DS al utilizar dos hipótesis en lugar de una
- Como se ha comentado en este apartado, ambos clasificadores tienen un buen desempeño en cuanto a la identificación de apneas centrales, con resultados de detección por encima del 80 %. Sin embargo, cuando se incluyen en el estudio apneas del resto de tipos los resultados son pobres. Por tanto, se deberían implementar técnicas de identificación de apneas centradas en las de tipo obstructivo, mixto y especialmente hipopneas que son las más frecuentes
- Por último se podría modificar la red neuronal de manera que en lugar de utilizar únicamente dos clases (apnea, no-apnea), se emplee una clase para cada tipo de apnea

V. Pliego de condiciones

En este capítulo se evaluarán las condiciones necesarias para trabajar con los dos clasificadores desarrollados a lo largo de este documento.

A. Pliego de condiciones generales

En el pliego de condiciones generales se recoge el alcance del proyecto. Con este trabajo se busca implementar un método de identificación de apneas centrales a partir de un análisis del ECG. Para ello

- Se han estimado de manera fidedigna señales EDR a partir del ECG
- Se han probado diferentes algoritmos de detección de apneas a partir de la señal EDR
- Se han utilizado técnicas de ML para la clasificación de apneas

B. Pliego de condiciones particulares

En el pliego de condiciones particulares se definen los componentes requeridos para la ejecución del proyecto.

B.1. Requisitos de hardware recomendados

El equipo hardware recomendado es el siguiente:

- PC de 64 bits con al menos 4 núcleos
- 8 GB de memoria RAM
- Disco duro SSD

- Tarjeta gráfica (GPU)

Los clasificadores requieren de grandes cantidades de datos y las señales ECG al ser de varias horas de duración suelen ser pesadas por lo que se recomienda disponer de varios GB de espacio libre. Además, estos datos deben ser procesados y analizados por lo que se recomienda disponer de un volumen considerable de memoria RAM y una GPU, especialmente para trabajar con la red neuronal.

B.2. Requisitos de software

El desarrollo del proyecto se ha llevado a cabo en un equipo con el sistema operativo Windows 10 aunque podría utilizarse en otros. Los requisitos de software para este proyecto son:

- Cualquier sistema operativo compatible con Matlab
- Matlab en su versión 2022a aunque podría funcionar en versiones anteriores
- Base de datos de señales ECG en formato edf
- Microsoft Office 365 que incluye el software de hojas de cálculo Microsoft Excel

VI. Presupuesto

En este capítulo se incluye una estimación del coste total para la realización del proyecto. Los costes se dividen en función de su tipo calculando el subtotal de cada uno y mostrando al final el coste total.

A. Presupuesto de ejecución material

El presupuesto de ejecución material (PEM) es la suma de los costes de mano de obra y recursos hardware y software necesarios para llevar a cabo el proyecto.

A.1. Mano de obra

Concepto	Precio / Hora	Horas	Subtotal
Graduado	30,00 €	350	10500,00 €
TOTAL			10500,00 €

Tabla 24: Mano de obra

A.2. Recursos hardware

Concepto	Precio por Unidad	Uso / Duración	Subtotal
PC	1500,00 €	6 meses / 3 años	250,00 €
Material ofimático	60,00 €	6 meses / 3 años	10,00 €
TOTAL			260,00 €

Tabla 25: Recursos hardware utilizados

A.3. Recursos software

Concepto	Precio por Unidad	Uso / Duración	Subtotal
Licencia Windows 10 Home	145,00 €	6 meses / 3 años	24,17 €
Licencia anual Matlab R2022a	840,00 €	6 meses / 1 año	420,00 €
Licencia anual Microsoft Office 365	69,00 €	6 meses / 1 año	34,50 €
TOTAL			479,67 €

Tabla 26: Recursos software utilizados

El presupuesto total de ejecución material es el que se muestra en la tabla 27.

Concepto	Subtotal
Coste mano de obra	10500,00 €
Recursos hardware	260,00 €
Recursos software	479,67 €
TOTAL	11239,67 €

Tabla 27: Presupuesto de ejecución material

B. Presupuesto de ejecución por contrata

El presupuesto de ejecución por contrata (PEC) incluir los gastos derivados del uso de las instalaciones donde se ha llevado a cabo el trabajo, las cargas fiscales, los gastos financiero, las tasas administrativas y las obligaciones de control del proyecto. Dicho gasto se asume estableciendo un recargo sobre el coste del importe del presupuesto de ejecución material equivalente al 22 % de dicho importe.

Concepto	Valor	Subtotal
Presupuesto de ejecución por contrata	22 % PEM	2472,73 €

Tabla 28: Importe de ejecución por contrata

C. Honorarios facultativos

Los honorarios facultativos (HF) se fijan en un porcentaje del 7% sobre el PEM.

Concepto	Valor	Subtotal
Honorarios facultativos	7% PEM	786,78 €

Tabla 29: Importe de los honorarios facultativos

D. Presupuesto Total

En la tabla 30 se muestra la suma de todos los presupuestos calculados anteriormente con un IVA del 21%.

Concepto	Subtotal
Presupuesto de ejecución material	11239,67 €
Presupuesto de ejecución por contrata	2472,73 €
Horarios facultativos	786,78 €
TOTAL (sin IVA)	14499,18 €
IVA (21%)	3044,83€
TOTAL	17544,01 €

Tabla 30: Importe del presupuesto total del proyecto

VII. Bibliografía

- [1] J. Durán Cantolla, F. J. Puertas Cuesta, G. Pin Arboledas and J. Santa María Cano, “Consenso Nacional sobre el síndrome de apneas-hipopneas del sueño”, *Archivos de Bronconeumología*, vol. 41, 2005.
- [2] J. Durán-Cantolla, C. Martínez-Null and C. Egea Santaolalla, “Tratamiento del Síndrome de Apneas-Hipopneas del Sueño (SAHS) con Dispositivos Mecánicos Generadores de Presión”, *Revista Médica Clínica Las Condes*, vol. 24, 2013.
- [3] T. Young, E. Shahar and F. J. Nieto, “Predictors of Sleep-Disordered Breathing in Community-Dwelling Adults: The Sleep Heart Health Study”, *Arch Intern Med.*, vol. 162, 2002.
- [4] M. A. Martínez-García, J. Amilibia, E. Chiner, C. Queipo, et al., “Sleep Apnoea in Patients of Elderly: Care Activity in Spain”, *Archivos de Bronconeumología*, vol. 46, 2010.
- [5] R. B. Berry, R. Brooks, C. E. Gamaldo, S. M. Harding, R. M. Lloyd, C. L. Marcus and B. V. Vaughn, “The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications”, *Darien, Illinois: American Academy of Sleep Medicine*, version 1, 2007.
- [6] “Tipos de apnea del sueño”, <https://www.resmed.es/pacientes/diagnostico-y-tratamiento/apnea-del-sueno/tipos-de-apnea-del-sueno/> (accessed Mar. 17, 2021).
- [7] C. Massaroni, A. Nicolò, D. Lo Presti, M. Sacchetti, S. Silvestri and E. Schena, “Contact-Based Methods for Measuring Respiratory Rate”, *Sensors*, vol. 19, 2019.

- [8] “Pulsioxímetro: Qué es, cómo funciona, uso, resultados y limitaciones”, <http://blog.tecnomed2000.com/2017/07/03/pulsioximetro-que-es-como-funciona-uso-resultados-y-limitaciones/> (accessed Sept. 17, 2022).
- [9] P. Leonard, T. F. Beattie, P. S. Addison and J. N. Watson, “Standard pulse oximeters can be used to monitor respiratory rate”, *Emerg Med J.*, vol. 20, 2003.
- [10] J.M. Marín Trigo, “Pletismografía inductiva en la monitorización respiratoria”, *Archivos de Bronconeumología*, vol. 24, 1988.
- [11] “Pruebas Médicas: Electrocardiograma”, <https://medlineplus.gov/spanish/pruebas-de-laboratorio/electrocardiograma/> (accessed Mar. 17, 2021).
- [12] “Derivaciones del Electrocardiograma”, <https://www.my-ekg.com/generalidades-ekg/derivaciones-cardiacas.html> (accessed Mar. 17, 2021).
- [13] “Electrocardiograma, que es, como se hace, para que sirve”, <https://periodicosalud.com/electrocardiograma-que-es-como-se-hace-para-que-sirve/> (accessed Mar. 17, 2021).
- [14] G. M. Friesen, T. C. Jannet, M. Afify Jadallah, S. L. Yates, S. R. Quint and H. Troy Nagle, “A Comparison of the Noise Sensitivity of Nine QRS Detection Algorithms”, *IEEE Transactions on Biomedical Engineering*, vol. 37, 1990.
- [15] A. S. Barhatte, R. Ghongade and S. V. Tekale, “Noise Analysis of ECG Signals Using Fast ICA”, in *2016 Conf. on Advances in Signal Processing (CASP)*, Pune, India, 2016.
- [16] A. C. Vinzio Maggio, M. P. Bonomini, E. Laciari and P. D. Arini, “9 Quantification of Ventricular Repolarization Dispersion Using Digital Processing of the Surface ECG”, in *Advances in Electrocardiograms - Methods and Analysis*, 2012.
- [17] L. Gu, N. Zhou and H. Wu, “Applicatoin of Interference Canceller in Bioelectricity Signal Disposing”, in *3rd Int. Conf. on Enviromental Science and Information Application Technology (ESIAT)*, Chongqing, China, 2011.
- [18] X. An and G. K. Stylios, “Comparison of Motion Artefact Reduction Methods and the Implementation of Adaptive Motion Artefact Reduction in Wearable Electrocardiogram Monitoring”, *Sensors (Basel)*, vol. 20, 2020.

- [19] S. Abbaspour, H. Gholamhosseini and M. Linden, "Evaluation of Wavelet Based Methods in Removing Motion Artifact from ECG Signal", in *16th Nordic-Baltic Conf. on Biomedical Engineering and Medical Physics*, 2015.
- [20] J. Solà-Soler and B. F. Giraldo, "Comparison of ECG-Derived Respiration Estimation Methods on Healthy Subjects in function of Recording Site and Subject Position and Gender", in *2020 42nd Annu. Int. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Montreal, QC, Canada, 2020.
- [21] C. O'Brien and C. Heneghan, "A comparison of algorithms for estimation of a respiratory signal from the surface electrocardiogram", *Comput Biol Med.*, vol. 37, 2007.
- [22] J. Boyle, N. Bidargaddi, A. Sarela and M. Karunanithi, "Automatic detection of respiration rate from ambulatory single-lead ECG", *IEEE Trans Inf Technol Biomed.*, vol. 13, 2009.
- [23] N. E. Huang et al., "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis", *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, vol. 454, 1998.
- [24] D. Labate, F. L. Foresta, G. Occhiuto, F. C. Morabito, A. Lay-Ekuakille and P. Vergallo, "Empirical Mode Decomposition vs. Wavelet Decomposition for the Extraction of Respiratory Signal From Single-Channel ECG: A Comparison", *IEEE Sensors Journal*, vol. 13, 2013.
- [25] M. Nazari and S. Mahmoud Sakhaei, "Variational Mode Extraction: A New Efficient Method to Derive Respiratory Signals from ECG", *IEEE Journal of Biomedical and Health Informatics*, vol. 22, 2018.
- [26] P. H. Charlton et al., "Breathing Rate Estimation From the Electrocardiogram and Photoplethysmogram: A Review", *IEEE Reviews in Biomedical Engineering*, vol. 11, 2018.
- [27] J. Pan and W. J. Tompkins, "A Real-Time QRS Detection Algorithm", *IEEE Transactions on Biomedical Engineering*, vol. BME-32, 1985.
- [28] C. Li, C. Zheng and C. Tai, "Detection of ECG Characteristic Points Using Wavelet Transforms", *IEEE Transactions on Biomedical Engineering*, vol. 42, 1995.

- [29] Z. Zidelmal, A. Amirou, M. Adnane and A. Belouchrani, “QRS detection based on wavelet coefficients”, *Computer Methods and Programs in Biomedicine*, vol. 107, 2012.
- [30] A. Wee, D. B. Grayden, Y. Zhu, K. Petkovic-Duran and D. Smith, “A continuous wavelet transform algorithm for peak detection”, *Electrophoresis*, vol. 29, 2008.
- [31] J. Laitala et al., “Robust ECG R-peak detection using LSTM”, in *The 35th ACM/SIGAPP Symp. On Applied Computing*, Brno, Czech Republic, 2020.
- [32] R. Gutiérrez-Rivas, J. J. García, W. P. Marnane and Á. Hernández, “Novel Real-Time Low-Complexity QRS Complex Detector Based on Adaptive Thresholding”, *IEEE Sensors Journal*, vol. 15, 2015.
- [33] A. Cuevas Notario, “Desarrollo de algoritmos para análisis del ECG como ayuda al diagnóstico de trastornos del sueño”, Trabajo de Fin de Grado, Dept. Elect., Escuela Politécnica Superior (UAH), 2018.
- [34] Z. Zhao and Y. Zhang, “SQI Quality Evaluation Mechanism of Single-Lead ECG Signal Based on Simple Heuristic Fusion and Fuzzy Comprehensive Evaluation”, *Frontiers in Physiology*, vol. 9, 2018.
- [35] M. Nardelli, A. Lanata, G. Valenza, M. Felici, P. Baragli and E. P. Scilingo, “A tool for the real-time evaluation of ECG signal quality and activity: Application to submaximal treadmill test in horses”, *Biomedical Signal Processing and Control*, vol. 56, 2020.
- [36] V. K. Murthy, T. M. Grove, G. A. Harvey and L. J. Haywood, “Clinical Usefulness of ECG Frequency Spectrum Analysis”, *Proc. Annu. Symp. Comput. Appl. Med. Care.*, 1978.
- [37] C. Orphanidou, T. Bonnici, D. Vallance, A. Darrell, P. Charlton and L. Tarassenko, “A Method for Assessing the Reliability of Heart Rates obtained from Ambulatory ECG”, in *IEEE 12th Int. Conf. on Bioinformatics and Bioengineering (BIBE)*, Larnaca, Cyprus, 2012.
- [38] Q. Li, R. G. Mark and G. D. Clifford, “Robust heart rate estimation from multiple asynchronous noisy sources using signal quality indices and a Kalman filter”, *Physiol Meas.*, vol. 29, 2008.

- [39] Y. Shahriari, R. Fidler, M. M. Pelter, Y. Bai, A. Villaroman and X. Hu, “Electrocardiogram Signal Quality Assessment Based on Structural Image Similarity Metric”, *IEEE Transactions on Biomedical Engineering*, vol. 65, 2018.
- [40] A. Pinho, N. Pombo, B. M. C. Silva, K. Bousson and N. Garcia, “Towards an accurate sleep apnea detection based on ECG signal: The quintessential of a wise feature selection”, *Applied Soft Computing*, vol. 83, 2019.
- [41] S. M. Isa, M. I. Fanany, W. Jatmiko and A. Murni, “Feature and Model Selection on Automatic Sleep Apnea Detection using ECG”, in *Int. Conf. on Advanced Computer Science and Information Systems*, Bali, Indonesia, 2010.
- [42] T. Huang, H. Chen and W. Fang, “Real-time obstructive sleep apnea detection based on ECG derived respiration signal”, in *2012 IEEE Int. Symp. on Circuits and Systems (ISCAS)*, Seoul, Korea (South), 2012.
- [43] S. Fan, C. Chou, W. Chen and W. Fang, “Real-time obstructive sleep apnea detection from frequency analysis of EDR and HRV using Lomb Periodogram”, in *2015 37th Annu. Int. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Milan, Italy, 2015.
- [44] T. Wang, C. Lu, G. Shen and F. Hong, “Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet-5 convolutional neural network”, *PeerJ*, vol. 7, 2019.
- [45] Q. Shen, H. Qin, K. Wei and G. Liu, “Multiscale Deep Neural Network for Obstructive Sleep Apnea Detection Using RR Interval From Single-Lead ECG Signal”, *IEEE Transactions on Instrumentation and Measurement*, vol. 70, 2021.
- [46] S. A. Singh and S. Majumder, “A novel approach OSA detection using single-lead ECG scalogram based on deep neural network”, *Journal of Mechanics in Medicine and Biology*, vol. 19, 2019.
- [47] F. Chen, M. R. Jahanshahi and R. Wu, “A texture-Based Video Processing Methodology Using Bayesian Data Fusion for Autonomous Crack Detection on Metallic Surfaces”, *Computer-Aided Civil and Infrastructure Engineering*, vol. 32, 2017.

- [48] D. Fasbender, L. Peeters, P. Bogaert and A. Dassargues, “Bayesian data fusion applied to water table spatial mapping”, *Water Resources Research*, vol. 44, 2008.
- [49] L. A. Klein, “Dempster-Shafer Evidential Theory”, in *Sensor and Data Fusion: A Tool for Information Assessment and Decision Making*, Washington, USA: SPIE, 2004, ch. 6.
- [50] F. Rottensteiner, J. Trinder, S. Clode and K. Kubik “Using the Dempster-Shafer method for the fusion of LIDAR data and multi-spectral images for building detection”, *Information Fusion*, vol. 6, 2005.
- [51] R. Feng, G. Zhang and B. Cheng, “An on-board system for detecting driver drowsiness based on multi-sensor data fusion using Dempster-Shafer theory”, in *Int. Conf. on Networking, Sensing and Control*, Okayama, Japan, 2009.
- [52] J. Vitola, F. Pozo, D. A. Tibaduiza and M. Anaya, “A Sensor Data Fusion System Based on k-Nearest Neighbor Pattern Classification for Structural Health Monitoring Applications”, *Sensors*, vol. 17, 2017.
- [53] S. Liu, R. X. Gao, D. John, J. Staudenmayer and P. S. Freedson, “SVM-Based Multi-Sensor Fusion for Free-Living Physical Activity Assessment”, in *33rd Annu. Int. Conf. of the IEEE EMBS*, Boston, Massachusetts, 2011.
- [54] P. Kumar, H. Gauba, P. Pratim Roy and D. Prosad Dogra, “Coupled HMM-based multi-sensor data fusion for sign language recognition”, *Pattern Recognition Letters*, vol. 86, 2017.
- [55] J. J. Alves de Lima, L. F. Maldaner and J. Paulo Molin, “Sensor Fusion with NARX Neural Network to Predict the Mass Flow in a Sugarcane Harvester”, *Sensors*, vol. 21, 2021.
- [56] L. Liu, G. Luo, K. Qin and X. Zhang, “An algorithm based on logistic regression with data fusion in wireless sensor networks”, *EURASIP Journal on Wireless Communications and Networking*, vol. 2017, 2017.
- [57] “Documentación en Matlab de la función *trainNetwork*”, <https://es.mathworks.com/help/deeplearning/ref/trainnetwork.html> (accessed Sept. 3, 2022).

- [58] “Documentación en Matlab de la función *fullyConnectedLayer*”, <https://es.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.fullyconnectedlayer.html> (accessed Sept. 3, 2022).
- [59] “Documentación en Matlab de la función *batchNormalizationLayer*”, <https://es.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.batchnormalizationlayer.html> (accessed Sept. 3, 2022).
- [60] “Documentación en Matlab de la función *reluLayer*”, <https://es.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.reluLayer.html> (accessed Sept. 3, 2022).
- [61] “Neural networks”, https://ml4a.github.io/ml4a/neural_networks/ (accessed Sept. 3, 2022).
- [62] “What is the Softmax Function?”, <https://deepai.org/machine-learning-glossary-and-terms/softmax-layer> (accessed Sept. 3, 2022).
- [63] “Documentación en Matlab de la función *classificationLayer*”, <https://es.mathworks.com/help/deeplearning/ref/classificationlayer.html> (accessed Sept. 3, 2022).
- [64] K. Elijah Koech, “Cross-Entropy Loss Function”, *Towards Data Science*, Oct., 2020.

Universidad de Alcalá
Escuela Politécnica Superior



ESCUELA POLITECNICA
SUPERIOR



Universidad
de Alcalá