



Emma Artal Maurel

**Estimación de la respiración mediante un dispositivo
wearable de muñeca basado en fotopletismografía de pulso**

TRABAJO FINAL DE GRADO

**Dirigido por el Dr. Jesús Lázaro y tutorizado por el Dr.
David Girbau**

Grado de Ingeniería biomédica



UNIVERSITAT ROVIRA I VIRGILI

Tarragona

2024

Resumen

Este Trabajo Final de Grado hace el análisis de cuatro algoritmos implementados por el grupo de investigación BSICoS, a través de MATLAB, que estiman la respiración de forma indirecta mediante señales de fotopleletismografía de pulso (PPG) de diez sujetos, respirando a cinco frecuencias controladas (0.1, 0.2, 0.3, 0.4, 0.5 Hz) y que son recogidas por un *wearable* de muñeca diseñado por el Instituto de Investigación Biomédica de la Universidad Tecnológica de Kaunas, Lituania. Tres algoritmos calculan la derivación respiratoria mediante parámetros morfológicos de la señal PPG (amplitud, anchura y frecuencia), y, el cuarto algoritmo combina estas derivaciones respiratorias resultantes y calcula una nueva basada en la picudez de las señales. El uso de *wearables* para el diagnóstico de enfermedades, el cribado o la monitorización de parámetros de salud para un seguimiento preciso de los pacientes es un desafío prometedor en la investigación. A medida que la tecnología avanza, estos dispositivos no invasivos emergen como una alternativa viable a las herramientas de diagnóstico convencionales, como la polisomnografía utilizada en el diagnóstico del Síndrome de Apnea Obstructiva, ya que, esta técnica de diagnóstico requiere que los pacientes pasen una noche en la Unidad del Sueño de los hospitales, lo cual resulta incómodo para ellos y puede afectar en el análisis.

Índice

1	Introducción.....	1
1.1	Contexto y propósito principal	1
1.2	Estado del arte en monitorización de la respiración	3
1.3	Fotopleletismografía.....	5
1.4	Algoritmos PWV, PAV y PRV	7
1.5	Algoritmo basado en la picudez	9
1.6	Objetivos del TFG	10
1.7	Estructura de la memoria	10
2	Rutinas con los algoritmos	12
2.1	Bases de datos.....	12
2.2	Pulsera inteligente	13
2.3	Frecuencias de referencia	13
2.4	Descripción de la rutina 1	15
2.5	Descripción de la rutina 2.....	23
3	Resultados.....	25
3.1	Estadística.....	25
3.2	Discusión	26
3.3	Conclusión.....	27
3.4	Líneas futuras de trabajo.....	28
4	Referencias	30
5	Anexos.....	32
5.1	Etapas referencia.....	32
5.2	Código del recorte de las etapas de referencia para un sujeto	32
5.3	Código frecuencia dominante de la referencia para un sujeto.....	33
5.4	Errores rutina 1, $f > 0.085$ Hz.....	34
5.5	Errores rutina 1, $f > 0.15$ Hz.....	35
5.6	Errores rutina 2, $f > 0.085$ Hz.....	36
5.7	Errores rutina 2, $f > 0.15$ Hz.....	37
5.8	Código del preprocesado	38
5.9	Código completo de la rutina 1 para un sujeto	38
5.10	Código completo de la rutina 2 para un sujeto	43

1 Introducción

La monitorización de la respiración es fundamental en distintos ámbitos, por ejemplo, para el diagnóstico de enfermedades respiratorias como el asma, la apnea del sueño o enfermedades pulmonares obstructivas crónicas [1]. También se puede usar para identificar paro cardíaco o infarto [2], [3]. Por otro lado, hacer un seguimiento de la frecuencia respiratoria da seguridad al paciente en entornos críticos donde los pacientes están bajo anestesia general, en cuidados intensivos, o durante procedimientos quirúrgicos.

En relación con el rendimiento deportivo, también es un parámetro útil e importante para el seguimiento de la fatiga y esfuerzo físico. Además, con los datos y la información de la respiración de los atletas se puede optimizar su entrenamiento [4]. Se sabe que las emociones afectan a la ventilación normal de una persona, por lo que puede usarse también para analizar las emociones [5] o seguimiento de desórdenes como la ansiedad, relacionada con el incremento de la frecuencia respiratoria [6].

El control de la respiración se puede aplicar también en la seguridad laboral para la prevención de accidentes de trabajo, diseñar un ambiente óptimo, o mejorar la productividad, seguridad y bienestar de los trabajadores [7].

1.1 Contexto y propósito principal

A pesar de todas las aplicaciones posibles de este relevante parámetro, este trabajo se centrará en su importancia en la Apnea Obstructiva del Sueño (AOS). Este síndrome se caracteriza por interrupciones en la respiración durante el sueño debido a la obstrucción de las vías respiratorias. Este ciclo irregular implica que la respiración se reanude mediante pequeños despertares que reactivan la musculatura involucrada, permitiendo así la reapertura de las vías respiratorias previamente obstruidas.

La obstrucción puede ser causada por diversos factores, como la relajación excesiva de los músculos de la garganta, el colapso debido a la posición de la lengua hacia la parte posterior de la garganta, agrandamiento de las amígdalas o adenoides, exceso de peso u obesidad, anomalías estructurales en las vías respiratorias superiores, y el consumo de alcohol o sedantes antes de acostarse.

Las apneas e hipopneas pueden ocurrir hasta cientos de veces por noche, y su recurrencia puede provocar hipersomnolia, somnolencia diurna excesiva (aumenta significativamente los accidentes de tráfico e interfiere en la vida social y laboral), insomnio, nicturia, pérdida de memoria, déficit de atención y depresión, entre otros síntomas [8]. La apnea del sueño es notable por determinados síntomas frecuentes como: ronquidos, observación de otra persona de apneas durante el sueño, habitualmente de la pareja, somnolencia y cansancio diurnos excesivos, sueño no reparador y cefaleas. Otros síntomas menos frecuentes son la sequedad en la boca, cambios en el estado de ánimo (irritabilidad, depresión y ansiedad), pérdidas de la capacidad de concentración y de memoria o levantarse de manera frecuente a orinar por la noche.

Introducción.

Una vez se tiene sospecha de la posibilidad de sufrir el síndrome con los síntomas previamente descritos, se evalúa la escala de somnolencia *Epworth*, que es un cuestionario corto para intentar determinar la somnolencia diurna del sujeto, y el IMC (índice de masa corporal).

Para diagnosticarlo finalmente, se realiza un estudio del sueño, ya sea, la polisomnografía hospitalaria o la poligrafía respiratoria.

La polisomnografía implica pasar una noche en la Unidad del Sueño del hospital para detectar anomalías en las diferentes fases del sueño, por ejemplo, el esfuerzo y la frecuencia respiratoria, las ondas cerebrales, los movimientos oculares o cardíaca, entre otros. Resulta ser un análisis muy completo pero el sueño de los pacientes puede estar alterado por incomodidad de dormir en un sitio ajeno y de tener tantos sensores colocados en el cuerpo. La diferencia entre estas dos pruebas es que en la poligrafía el paciente se lleva un equipo portátil a casa, es más económica y no se estudian tantos parámetros ni se realiza el electroencefalograma.

La prevalencia de la apnea obstructiva del sueño (AOS) varía en diferentes estudios, pero en la mayoría de las investigaciones recientes se ha concluido que ha aumentado con el tiempo y está estrechamente relacionada con problemas cardiovasculares. Debido a esta alta prevalencia y al avance en el conocimiento de la enfermedad y sus consecuencias cardiovasculares, se ha generado una mayor demanda de servicios relacionados con el diagnóstico y tratamiento de la AOS. Sin embargo, las unidades de sueño convencionales, que suelen tener un número limitado de camas para polisomnografías (PSG), no son suficientes para satisfacer esta demanda creciente. Esto resulta en demoras en el diagnóstico y tratamiento de los pacientes [9].

Los diagnósticos en la unidad del sueño acaban en largas listas de espera. Por ejemplo, en 2022 se estimó que la Unidad de Sueño del hospital Insular de Gran Canaria tenía una lista de espera de aproximadamente 2 años [10]. En el Hospital Miguel Servet de Zaragoza afirman que se ha reducido notablemente la lista de espera en los últimos años pero que la gran demanda existente provoca que sea de alrededor de un año en este hospital [11].

Expertos de la SEPAR (Sociedad Española de Neumología y Cirugía Torácica) afirman que hay que cambiar el sistema de diagnóstico actual a uno interconectado entre la atención primaria y la unidad específica del sueño por ser un problema de salud pública [10]. Afirman que es una enfermedad infradiagnosticada, ya que, sólo se diagnostica alrededor del 20% de AOS grave y que, si se consiguiera aumentar la cifra al 50%, el sistema de sanidad pública se ahorraría más de 80 millones de euros [9].

Por ello, además de todas las aplicaciones que la monitorización de la respiración tiene, otros métodos de detección de las anomalías respiratorias podrían ser útiles para un cribaje del síndrome de la Apnea Obstructiva del Sueño, evitando así las largas listas de espera de los laboratorios del sueño y consiguiendo un gran ahorro económico.

1.2 Estado del arte en monitorización de la respiración

Existen diferentes técnicas de monitorización de la respiración que típicamente se dividen en sistemas portátiles (*wearables*) o sistemas ambientales. Los métodos portátiles requieren que las personas lleven los sensores, mientras que en los métodos ambientales los sensores se colocan alrededor de los sujetos. Para cada técnica existen localizaciones posibles donde colocar el sensor y los sensores también pueden ser distintos entre ellos, como se muestra en la *Figura 1* [11].




Figura 1. Localizaciones de los diferentes sensores de estimación de la respiración.

Dentro de ambas categorías (portátiles o ambientales) se pueden clasificar a grandes rasgos, según la técnica utilizada para obtener la información respiratoria y según la métrica respiratoria utilizada [12].

Introducción.

En la *Tabla 1* se muestran ejemplos de cada una, según la técnica y la métrica.

Técnica de obtención de la información respiratoria	Métrica respiratoria
Sonidos respiratorios	
Flujo respiratorio	Frecuencia respiratoria
Temperatura o humedad del aire	Volúmenes respiratorios
Movimientos del pecho	Patrones respiratorios
Modulación de la actividad cardiaca	

Tabla 1. Clasificación de las diferentes técnicas utilizadas en ambas categorías.

Los dispositivos portátiles o *wearables* están diseñados para colocarse en zonas del sujeto cercanas a la piel, lo que disminuye el ruido e interferencias de la señal. Esto supone una ventaja en comparación a otras técnicas como el uso de micrófonos o radares [13]. Los *wearables* son una forma cómoda de monitorear el síndrome de apnea obstructiva del sueño en casa, lo que permite un cribado más rápido y un seguimiento a largo plazo mejorado.

Los estudios sobre métodos de diagnóstico de la AOS más comunes están basados en el electrocardiograma (ECG) y la fotopletismografía (PPG) [14]. Recientemente se ha visto que con el ECG se puede obtener un cribaje notablemente fiable [15].

El electrocardiograma (ECG), es una prueba no invasiva que registra a través de electrodos colocados en la piel la polarización y despolarización de las células cardíacas. Requiere un análisis detallado y conocimientos especializados en electrofisiología cardíaca para su interpretación debido a la complejidad de los patrones de señal y la variabilidad entre pacientes.

La fotopletismografía se caracteriza con la señal PPG y mide cambios en el volumen sanguíneo a través de cambios en el nivel de absorción o reflexión de luz en la superficie de la piel, lo que posibilita estimar la arritmia sinusal respiratoria (RSA), una variación cíclica en el intervalo de los latidos del corazón de acuerdo con la respiración [16].

Con la fotopletismografía se pueden obtener parámetros similares al ECG, así que, el reto consiste en encontrar el método más cómodo y fiable para los pacientes con sospecha de este síndrome. El ECG, a pesar de haber obtenido muy buenos resultados, sigue siendo un método incómodo a largo plazo por la cantidad de electrodos colocados y limitación de la movilidad. Por otro lado, la fotopletismografía en el dedo también ha demostrado ser un método robusto, pero sigue siendo algo incómodo como método nocturno.

El método de fotopletismografía a través de *wearables* de muñeca está siendo un método cada vez más popular entre los científicos, ya que, es un dispositivo que puede medir más actividades, es cómodo, su batería permite registrar largos periodos, tanto diurnos como nocturnos y puede ser un gran candidato a largo plazo para los pacientes. El inconveniente es que, a diferencia de su colocación en el dedo, en la muñeca encontramos más pelo, y solo es posible una configuración en reflexión (puesto que la luz no atraviesa la muñeca)... lo que incrementa el ruido de la señal.

Introducción.

1.3 Fotopletismografía

Para este trabajo, nos centraremos en el estudio de la onda PPG para la obtención indirecta de la señal respiratoria, dado el bajo coste de los sensores utilizados y su comodidad.

La onda fotopletismográfica, conocida como onda PPG por sus siglas en inglés, se describió por primera vez por Alrick Hertzmann en 1937 [20].

Un dispositivo típico de fotopletismografía (PPG) consiste en una fuente de luz y un fotodetector para realizar una evaluación no invasiva de los cambios de volumen sanguíneo en la microcirculación de una parte del cuerpo accesible, por ejemplo, la yema del dedo, como he mencionado anteriormente, la diana es obtener una validez aceptable en la muñeca, en vez del dedo. La forma de onda PPG proporciona información sobre la frecuencia cardíaca, midiendo la cantidad de luz absorbida o reflejada por el flujo sanguíneo pulsátil dentro de los vasos.

Los principios físicos de esta señal están basados en la ley de Beer-Lambert (1) que determina que la intensidad de la luz que viaja a través de un medio (I) disminuirá exponencialmente en función del coeficiente de absorción (ϵ), la longitud del recorrido óptico (l) y la concentración del medio (c), respecto a la intensidad de la luz inicialmente transmitida (I_0). La parte exponencial de la fórmula es conocida como absorbancia (2).

$$I = I_0 e^{-A} \quad (1)$$

$$A = -\epsilon lc \quad (2)$$

De manera simple, a medida que el corazón se contrae, el rápido aumento del volumen de flujo sanguíneo en las arterias, venas y capilares atenúa la fuente de luz del dispositivo de medición de PPG, lo que le permite detectar los cambios en el volumen de flujo sanguíneo durante el ciclo cardíaco. La forma de la onda consta de tres eventos principales: pico sistólico, hendidura dicrótica y pico diastólico. Los picos sistólico y diastólico indican la detección de la contracción y relajación ventricular transmitida en el sitio de medición, mientras que la muesca dicrótica es causada por el cierre de la válvula aórtica, lo que indica el final de la fase sistólica y el comienzo de la fase diastólica [21].

La *Figura 2* explica de manera ilustrativa que la forma de onda de la PPG posee componentes pulsátiles (AC) y no pulsátiles (DC). El componente AC proporciona información sobre cambios volumétricos en los vasos sanguíneos (pulso arterial, cambios rápidos), lo cual corresponde a la frecuencia cardíaca. El componente DC mide la luz absorbida por el tejido, las venas y la sangre en el sitio de medición, lo que informa sobre la capacidad de volumen en los vasos sanguíneos, como cambios en la capacidad venosa debido a la respiración (cambios lentos).

Introducción.




Figura 2. Esquema teórico onda PPG. [4]

La aplicación típica de la onda PPG es la pulsioximetría, muy útil en los hospitales para medir la saturación de oxígeno en sangre. Esta técnica necesita una fuente de luz que emite a través de la piel y un detector que recibe esa luz después de haberse propagado. La luz y la fuente de luz, como se observa en la *Figura 3*, pueden ser transmisivas o reflectivas, dependiendo de cómo se coloquen, será transmisiva si, el LED y el fotodetector están colocados en lados opuestos de la piel, como es el caso del pulsioxímetro que se coloca en la punta del dedo. En el caso de las reflectivas, la luz y la fuente de luz se encuentran en el mismo lado de la piel, que es el caso de los *wearables* de muñeca.

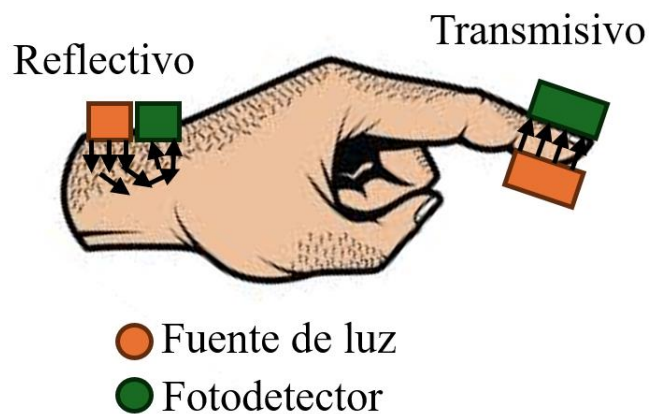


Figura 3. Esquema de los tipos de reproducción de onda PPG.

Introducción.

La luz tiene distintas longitudes de onda, las más interesantes son la luz verde (510-560 nm), la luz roja (600-750 nm) y el infrarrojo (850-1000 nm), dependiendo de la aplicación. La luz roja y el infrarrojo se utilizan principalmente para medir la saturación de oxígeno en sangre (SpO₂), ya que, la absorción de luz de estas longitudes de onda tiene un contraste importante entre la sangre oxigenada y la desoxigenada. Por otro lado, la luz verde se utiliza para medir el pulso o flujo sanguíneo, y ha obtenido mejores resultados en capas más finas, ya que, se obtienen variaciones de amplitud mucho mayores que con el resto, lo que da más información sobre el ciclo cardíaco. En este caso, se extraerán los datos del canal de luz verde para obtener información sobre la pulsatilidad y al ser un *wearable*, se trata de la técnica reflectiva. La *Figura 4* representa la profundidad de cada longitud de onda, la verde llega hasta los capilares y por ello es interesante para la pulsatilidad, mientras que el infrarrojo y la luz roja, llegan hasta la capa de piel donde se encuentran las venas.




Figura 4. Profundidad de la piel que atraviesa cada longitud de onda.

1.4 Algoritmos PWV, PAV y PRV

Hasta ahora, en la memoria, sólo se ha especificado la relación entre la onda PPG y la frecuencia cardíaca, por tanto, a continuación, se detallará la relación con la respiración. Cada método o algoritmo está basado en un parámetro específico: anchura, amplitud y frecuencia y a partir de ahora se hablará de ellos por sus siglas: PWV, PAV y PRV respectivamente.

En la *Tabla 2*, se explican los diferentes parámetros morfológicos de la señal PPG analizados con los algoritmos.

Método	Variabilidad Parámetro	Descripción fisiológica
Pulse Width Variability, PWV	Anchura	Durante la espiración, hay una inervación del sistema nervioso simpático que a su vez es modulada por el parasimpático. La flexibilidad de los vasos sanguíneos afecta a la velocidad de propagación de la onda de pulso, y, por tanto, a su anchura.
Pulse Amplitude Variability, PAV	Amplitud	Durante la inspiración, el retorno venoso al corazón aumenta debido a la disminución de la presión intratorácica, lo que conduce a un aumento en el volumen sanguíneo en los tejidos, es decir, hay un incremento significativo en la presión negativa en el tórax durante la inspiración y esto atrae tanto aire como sangre hacia el pecho. Esto afecta a todos los parámetros morfológicos de la PPG y, por tanto, a su amplitud.
Pulse Rate Variability, PRV	Frecuencia	Durante la inspiración, la actividad parasimpática puede aumentar, lo que puede ralentizar la frecuencia cardíaca. Parámetro muy relacionado con la HRV (Heart Rate Variability), que refleja la capacidad del sistema nervioso autónomo para responder a los cambios en el entorno y en las demandas fisiológicas.

Tabla 2. Descripción de algoritmos basados en la variabilidad de la anchura, amplitud y frecuencia de la onda de pulso para la obtención de la derivación respiratoria.

En la *Figura 5*, se señala un esquema gráfico de la información de la señal que abarca cada algoritmo y de los puntos fiduciales de cada algoritmo:

- n_m : punto que se encuentra en la mitad de la amplitud del pulso
- n_A : amplitud máxima
- n_B : punto en el mínimo del pulso, *basal*
- n_O : punto al inicio del pulso, *onset*
- n_E : punto al final del pulso, *end*




Figura 5. Representación de onda PPG y de parámetros relevantes de los algoritmos PAV, PRV y PWV [22].

Introducción.

1.5 Algoritmo basado en la picudez

Este algoritmo fue diseñado para la adquisición de la frecuencia respiratoria a través de la PPG obtenida mediante la cámara de un teléfono móvil. Combina las 3 derivaciones respiratorias resultantes de los otros algoritmos (PAV, PWV y PRV) y mide su picudez, es decir, cambios muy pronunciados y abruptos [23].

Las señales que medimos son estocásticas, ya que, dependen de muchos factores aleatorios como el movimiento, la luz, el ruido etc. El código del *Anexo 5.3* implementa la estimación de la densidad espectral de potencia (*Power Spectral Density*, PSD) utilizando el periodograma de Welch para las señales respiratorias resultantes de cada algoritmo con el fin de determinar la frecuencia respiratoria dominante.

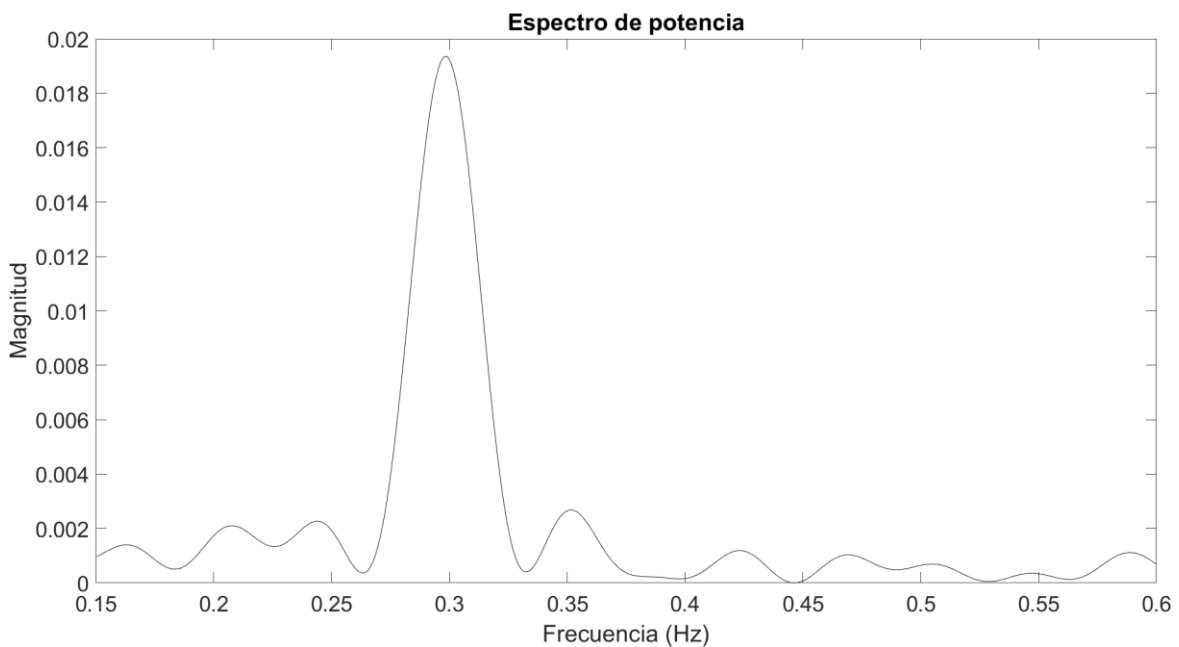


Figura 6. Espectro de potencia para calcular la frecuencia dominante.

El periodograma de Welch es una modificación del periodograma clásico que reduce la varianza de la estimación de la densidad espectral de potencia al promediar periodogramas de segmentos solapados de la señal. La longitud de las ventanas para este estudio es el mismo que para las cámaras y es de 12 segundos.

Lo ideal, en una señal respiratoria registrado durante un ejercicio de respiración a frecuencia constante, es que en el espectro de potencia aparezca un único pico muy pronunciado en dicha frecuencia controlada, como se muestra en la *Figura 6*. Basándose en este principio, el algoritmo trata de cuantificar la picudez de los espectros para después hacer un promediado dependiente de esta picudez.

Introducción.

1.6 Objetivos del TFG

1.6.1 Objetivo general

El objetivo de este trabajo es analizar, mediante procesamiento de señales, cuatro algoritmos diferentes con el mismo fin: estimar señales respiratorias a través de las ondas PPG registradas por un *wearable* diseñado por el Instituto de Investigación Biomédica de la Universidad Tecnológica de Kaunas (Kaunas, Lituania).

Las señales PPG, como se ha explicado anteriormente, están relacionadas con la frecuencia cardíaca y con estos algoritmos se puede obtener la derivación respiratoria de forma indirecta, todo ello, a través del entorno MATLAB y con ayuda de Excel para el cálculo de los errores relativo y absoluto, y para el cálculo de las métricas estadísticas de los resultados. Las bases de datos son de 10 sujetos, haciendo ejercicios de respiración controlada a frecuencia constante, respirando a cinco diferentes frecuencias (0.1, 0.2, 0.3, 0.5 Hz).

En primer lugar, se almacenan las señales de referencia en archivos de MATLAB. Después se ajustan los parámetros de los 3 algoritmos por separado (PAV, PWV, PRV), y una vez obtenidos los valores óptimos, se obtienen y almacenan las derivaciones respiratorias. Para el cuarto algoritmo, se combinan y se mide la picudez de estas, obteniendo otra derivación respiratoria. El proceso de las rutinas de trabajo y el cálculo estadístico será detallado más adelante.

1.6.2 Objetivos secundarios

Con este trabajo pretendo desarrollar mi conocimiento sobre el procesamiento de señales y su relación biológica con la respiración, ampliar conocimientos sobre el síndrome de la Apnea Obstructiva del sueño y sus actuales problemas económicos y de diagnóstico, y el aprendizaje de más herramientas de programación en el entorno de MATLAB, además de profundizar mis habilidades con Excel.

1.7 Estructura de la memoria

Este trabajo es colaboración con el grupo BSICoS (*Biomedical Signal Interpretation and Computational Simulation*) de la Universidad de Zaragoza siguiendo la línea de investigación de la monitorización a largo plazo a través de *wearables*.

Esta memoria contiene 3 capítulos, conteniendo la información y resultados obtenidos del relativo estudio, organizados de la siguiente manera:

Introducción.

- **Capítulo 1:**

Introducción sobre la importancia de la monitorización de la respiración, respectivas aplicaciones y su relación con el diagnóstico de la Apnea Obstruktiva del Sueño (AOS), incluyendo su descripción, actuales problemas sobre el diagnóstico, prevalencia y costes económicos. Por otro lado, se aporta información sobre estudios actuales para la solución de su diagnóstico y las líneas de investigación con el uso de *wearables* o dispositivos portátiles. Finalmente, se definen el concepto de fotopleitismografía y los tres algoritmos de obtención indirecta de las señales respiratorias y se enumeran los objetivos del TFG.

- **Capítulo 2:**

Explicación del trabajo práctico llevado a cabo en MATLAB y Excel. Descripción de las pruebas, contenido de las bases de datos, rutinas de trabajo para la validación de los algoritmos por separado y algoritmos juntos, y para su análisis para frecuencias mayores o iguales a 0.085 Hz y 0.15 Hz.

- **Capítulo 3:**

En este apartado se analizan los resultados estadísticos de los algoritmos aplicados a las señales PPG de dispositivos *wearables*, destacando métricas como la cobertura, y la mediana y el primer y tercer cuartil del error relativo de la estimación. Se discute la dificultad de mediciones directas debido al ruido y los artefactos o interferencias, y se propone la mejora de algoritmos y la implementación de detectores de artefactos específicos para señales PPG respiratorias. Se enfatiza la importancia de mediciones más largas para aumentar la precisión de los datos y se considera el potencial de los *wearables* en el monitoreo del síndrome de apnea obstructiva del sueño.

Finalmente, esta memoria también contiene una serie de Anexos que detallan, los errores obtenidos mediante las rutinas de trabajo y los códigos implementados.

Rutinas de trabajo.

2 Rutinas con los algoritmos

En este capítulo se describe con detalle el trabajo realizado de procesado de señales y los pasos para calcular los errores absoluto y relativo de cada sujeto y etapa (0.1, 0.2, 0.3, 0.4, 0.5 Hz). Los resultados de este capítulo se encuentran en los *Anexos 5.4-5.7*.

2.1 Bases de datos

El departamento de investigación biomédica BSICoS adquirió dos conjuntos de datos de 10 sujetos sin patologías específicas. Durante el experimento, los participantes permanecieron sentados y se les solicitó que respiraran durante 3 minutos a diferentes frecuencias respiratorias (0.1, 0.2, 0.3, 0.4, 0.5 Hz), siguiendo la pauta de un metrónomo virtual. A las diferentes frecuencias respiratorias se les denomina etapas para simplificar.

Este metrónomo emitía dos sonidos distintos para guiar el final de la inspiración y la espiración. Además de llevar puesto el dispositivo *wearable*, los sujetos también utilizaron bandas pletismográficas *Inductotrace* para registrar directamente su frecuencia respiratoria de referencia.

El *Inductotrace* es un pletismógrafo inductivo que se usa para medir los movimientos de la respiración. Como se puede ver en la *Figura 7*, consiste en dos bandas elásticas con cables aislados (*Inductobands*) que se colocan alrededor de la caja torácica y el abdomen, y se conectan a un módulo oscilador y una unidad de calibración. Este dispositivo mide los cambios de volumen en la caja torácica y el abdomen a través de cambios en la autoinductancia de las *Inductobands*.

La medición simultánea con el *Inductotrace* y el dispositivo *wearable* está destinada a validar los algoritmos. Esto nos permite determinar con precisión la frecuencia respiratoria de referencia de los sujetos en ese momento.



Figura 7. *Inductotrace*.

Durante el periodo de las prácticas, realizadas con anterioridad, hice la base de datos de las señales PPG con luz verde registradas por el *wearable*, recortando las etapas,

Rutinas de trabajo.

separándolo por sujetos, y guardándolo en un archivo de MATLAB para mayor accesibilidad. En este trabajo lo he hecho también para las señales de referencia medidas con el *Inductotrace*.

El sujeto 8 fue descartado, ya que, desde mi trabajo de prácticas se concluyó que no hizo correctamente la prueba de medición con el *wearable*. En algunas señales nos guiábamos por el acelerómetro que tenían instalado los sujetos para ver cambios muy bruscos, que indicaban un cambio de etapa, y en el sujeto 8 no se detectaron cambios significativos en el acelerómetro para guiarnos. Por otro lado, del sujeto 1 no se han encontrado las señales de referencia respiratoria, si no, unas señales que ya estaban calibradas, así que también se descarta para esta comparación. Así pues, en total quedan 8 sujetos para analizar.

2.2 Pulsera inteligente

El *wearable* utilizado para el estudio fue diseñado por un grupo de investigadores del Instituto de Ingeniería Biomédica de la Universidad Tecnológica de Lituania en 2019 y se muestra en la *Figura 8*. Su principal objetivo era monitorear la fibrilación auricular, un tipo común de arritmia cardíaca, a través de la fotopletismografía para el monitoreo continuo y la electrocardiografía (ECG) para la adquisición de una señal de control [24].



Figura 8. *Wearable* diseñado por KTU.

Aunque las pulseras inteligentes son aparatos de moda populares para monitorizar la frecuencia cardíaca y la actividad física, generalmente no son lo suficientemente sofisticados como para proporcionar información precisa sobre posibles problemas de salud del usuario, es por ello, que se están investigando métodos específicos para este tipo de aplicaciones.

2.3 Frecuencias de referencia

Para obtener las frecuencias dominantes de referencia, en primer lugar, se selecciona a mano el principio y fin de cada etapa (0.1, 0.2, 0.3, 0.4, 0.5 Hz) de la señal recogida con *Inductotrace*, almacenada en un archivo de MATLAB (.mat). La tabla con estos datos se encuentra en el *Anexo 5.1*. En la *Figura 9*, se observa la señal respiratoria recogida por el *Inductotrace* sin recortar. Si se observa la señal desde el final, las etapas

Rutinas de trabajo.

se pueden reconocer fácilmente, ya que, al final de la señal se observa una frecuencia mayor, lo que corresponde a la quinta etapa donde el sujeto se encuentra respirando a 0.5 Hz.

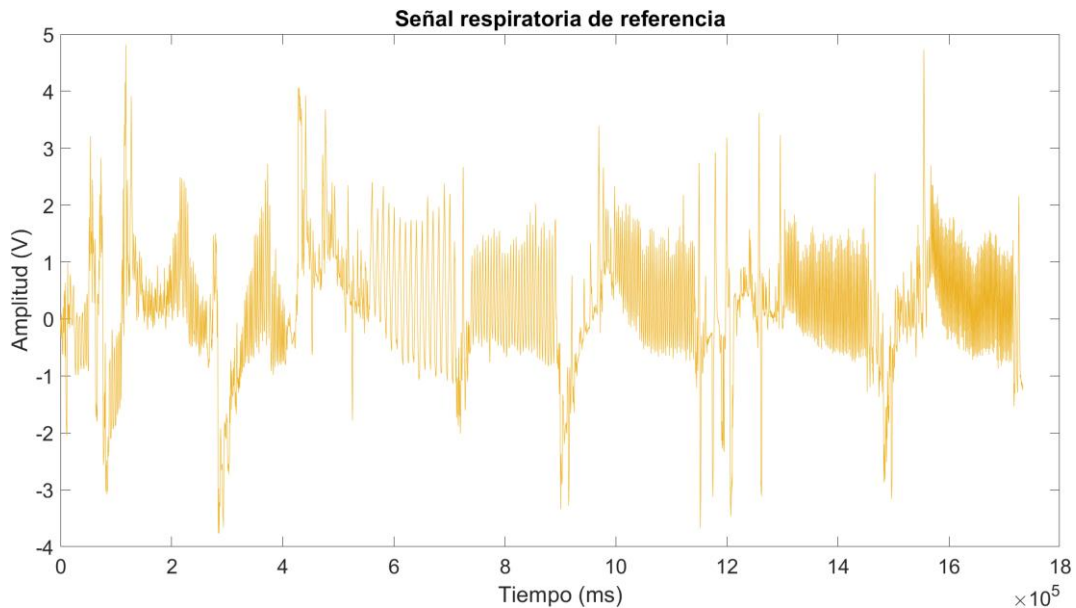


Figura 9. Señal respiratoria medida con *Inductotrace* sin recortar.

Tal y como indica el código del *Anexo 5.2*, se seleccionan las partes apuntadas de la señal, y se almacenan en la variable 'etapas'. Una vez se han almacenado las bases de datos, se utiliza el código del *Anexo 5.3* para calcular la frecuencia dominante de cada etapa y sujeto recortando la señal un minuto y medio desde el centro para evitar errores relacionados con coger el final y principio de la etapa a mano. La *Figura 10*, representa la primera etapa del sujeto 2 recortada un minuto y medio.

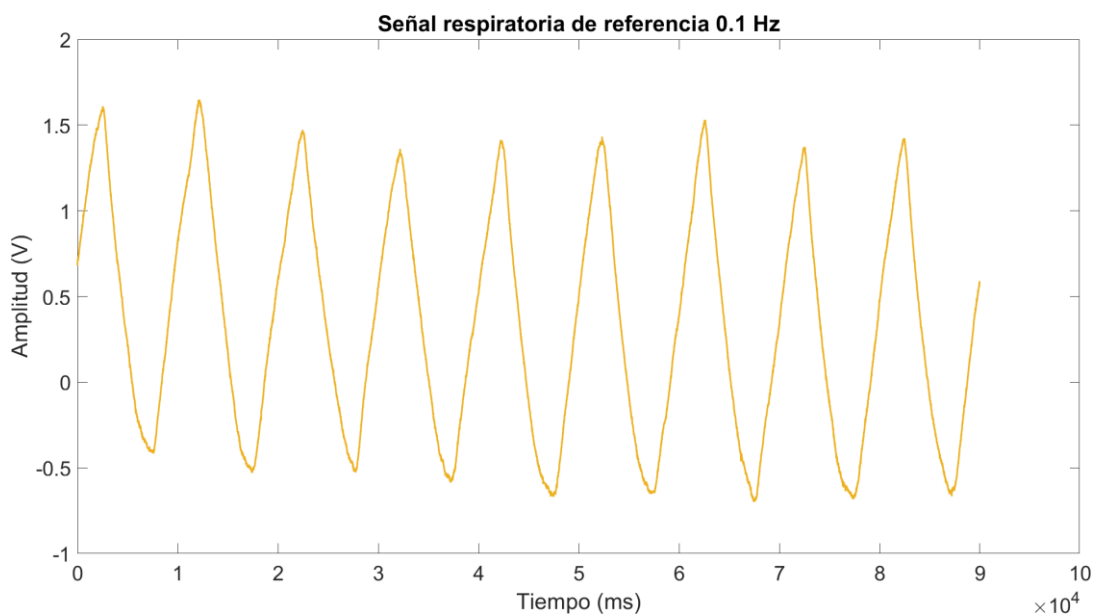


Figura 10. Señal respiratoria medida con *Inductotrace* recortada en la primera etapa.

Esta frecuencia dominante, calculada con la FFT (*Fast Fourier Transform*), se apunta en Excel para compararla con los resultados de las siguientes dos rutinas y calcular

Rutinas de trabajo.

los errores relativo y absoluto. Es obvio que el método es tan preciso que están redondeadas y aparentemente son exactamente 0.1, 0.2, 0.3, 0.4 y 0.5 Hz.

2.4 Descripción de la rutina 1

Se denomina rutina 1 al conjunto de rutinas realizadas de procesado de las señales para el análisis de los tres algoritmos por separado. La rutina 1 se resume en el esquema de la *Figura 11*, y en los siguientes subapartados se irá desgranando la información de cada punto de la rutina de trabajo.

En primer lugar, punto 1 de la *Figura 11*, se preprocesa la señal cruda o *raw*, a través de los filtros Butterworth paso-bajo y paso-alto y el detector de picos. A continuación, *Figura 11* punto 2, se procesan las señales con los algoritmos PAV, PWV y PRV, tanto para frecuencias mayores a 0.085 Hz como frecuencias mayores a 0.15 Hz y se recortan 2 minutos para eliminar la componente continua. Con esto se obtienen las derivaciones respiratorias y se guardan en archivos de MATLAB (.mat). Por último, *Figura 10*, punto 3 se realiza la FFT (*Fast Fourier Transform*) y se calcula la frecuencia donde está su máximo, lo que corresponde a la frecuencia dominante de la señal respiratoria. Esta frecuencia se compara con la de referencia (*Figura 11*, punto 4) y se calculan en Excel los errores absoluto y relativo.

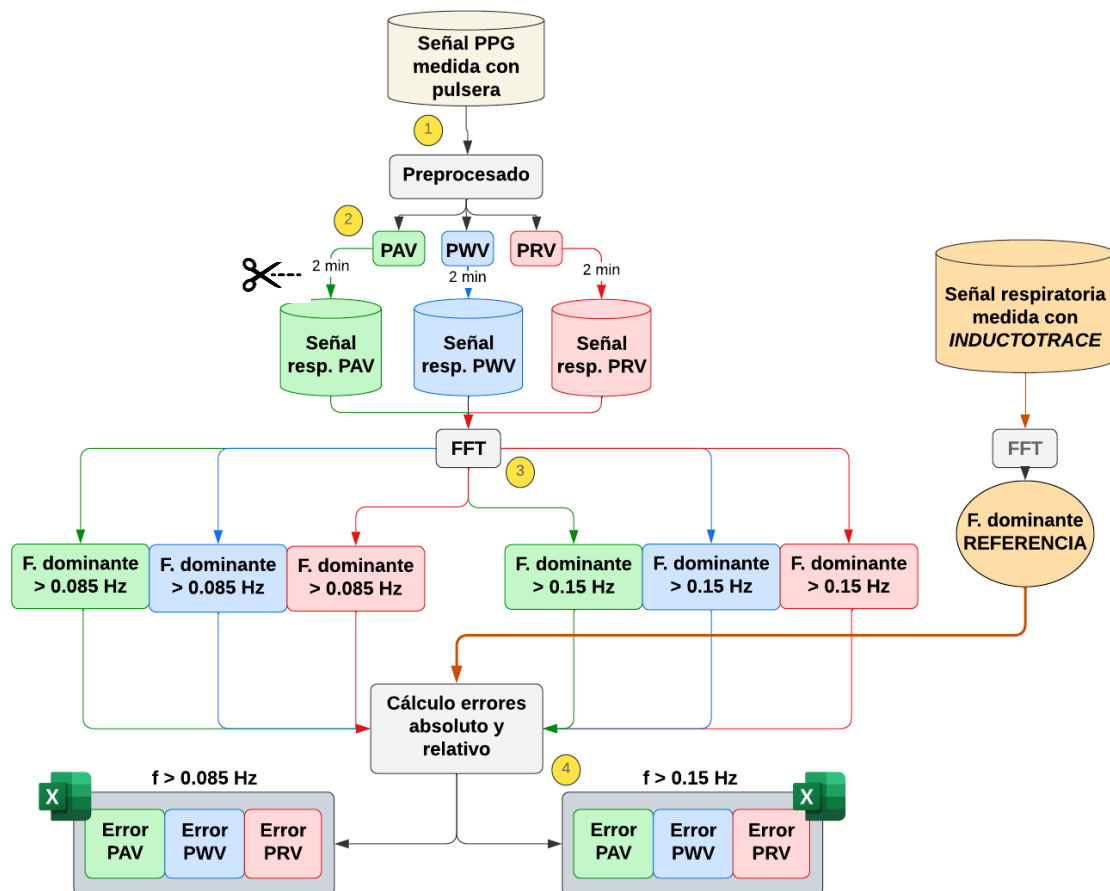


Figura 11. Esquema de la rutina 1 para un sujeto y una etapa.

Rutinas de trabajo.

A continuación, se explicará en detalle cada punto clave de la rutina 1 con el fin de ampliar la información relevante de cada parte. Esta rutina se aplica a cada etapa de cada sujeto, obteniendo como resultado la frecuencia dominante y los errores relativo y absoluto. En los *Anexos 5.4* y *5.5*, se encuentran las tablas de los errores de cada sujeto y etapa tanto para frecuencias mayores a 0.085 Hz como para frecuencias mayores a 0.15 Hz.

2.4.1 Preprocesamiento de la señal

La señal recogida por el *wearable* es de naturaleza ruidosa y no recuerda a la señal PPG. En la *Figura 12*, se muestra la señal tal cual se obtiene o *raw* recogida por el *wearable*. Los datos de la señal PPG medida con la pulsera de muñeca se preprocesan con filtros *Butterworth* y un algoritmo de detección de pulsos para reducir el ruido y obtener una mejor aproximación de los algoritmos descritos. En los siguientes subapartados se detallan estos procesos.




Figura 12. Representación gráfica de la señal *raw* recogida por el *wearable*.

La representación de la señal PPG después del preprocesamiento completo se muestra en la *Figura 13*, y se aprecia una evidente mejora en la calidad y apariencia de la señal PPG, lo que resalta la efectividad del proceso de preprocesamiento y detección de picos implementado. En los siguientes subapartados se explican los pasos intermedios.




Figura 13. Ejemplo de señal PPG recogida por el *wearable* y después del preprocesado.

2.4.1.1 Filtros Butterworth

En este trabajo se aplican dos filtros Butterworth de tercer orden, primero un paso-alto que elimina frecuencias por debajo de 0.03 Hz y un paso-bajo que elimina frecuencias por encima de 35 Hz. En el *Código 1*, se representa su implementación en MATLAB, con la función *butter* se construye el filtro de *Butterworth* y con *filtfilt* se aplica el filtro a la señal.

```
% Filtro Butterworth paso-alto
[bb, aa] = butter(3, 0.03*2/fsppg, 'high');
preproc = filtfilt(bb, aa, signal);

% Filtro Butterworth paso-bajo
[bb, aa] = butter(3, 35*2/fsppg, 'low');
preproc = filtfilt(bb, aa, preproc);
```

Código 1. Filtros *Butterworth* en MATLAB.

Los filtros se utilizan en el ámbito de las comunicaciones para dejar pasar o atenuar de manera selectiva ciertas frecuencias específicas de las señales. En el procesamiento de señales, comúnmente se combinan y se utilizan para mejorar la calidad y eliminar el ruido de estas. En la *Figura 14*, se representan los distintos tipos de filtros ideales y en este caso, dejarían pasar las frecuencias que se encuentran en la ventana negra.

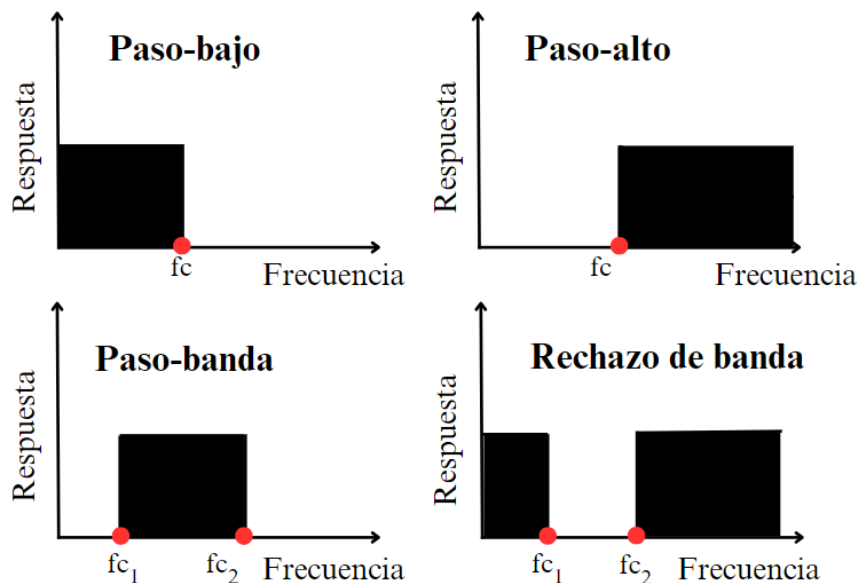


Figura 14. Representación gráfica de los filtros ideales.

El filtro *Butterworth*, también conocido como filtro máximamente plano, minimiza el rizado en la banda de paso. En la *Figura 15*, se describe un filtro paso-bajo Chebyshev con rizado, es decir, con un rizado en la banda de paso del filtro tal como se puede ver en su función de transferencia (relación entre la entrada y la salida del sistema). El filtro Butterworth, por el contrario, no tiene esa variación oscilatoria.

Rutinas de trabajo.

Además, puede ser de distintos grados u órdenes, lo que implica una pendiente menor o mayor en la atenuación en la banda de transición, es decir, entre la banda de paso y la banda de atenuación.

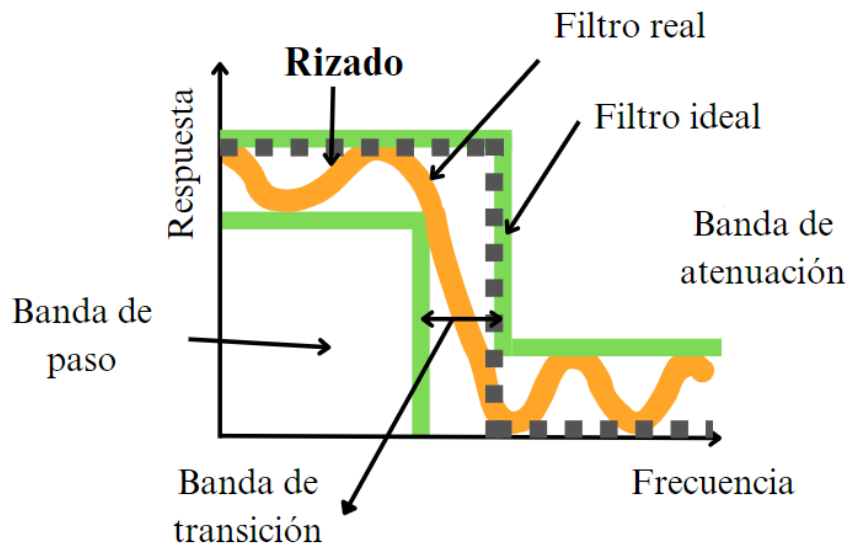


Figura 15. Respuesta de un filtro paso bajo Chebyshev con rizado y definición de los parámetros más importantes.

2.4.1.2 Algoritmo de detección de pulsos

Después del filtrado Butterworth se aplica un algoritmo de detección de pulsos (función denominada `PPG_delineator_LPDF` en el *Anexo 5.8*). Este algoritmo fue diseñado por el Dr. Jesús Lázaro y sus compañeros del grupo de investigación BSICoS en 2015 y está basado en un filtro diferenciador paso-bajo (LPDF) para realzar las pendientes de subida de la PPG.

En el algoritmo, se preprocesa de nuevo la señal, con un filtro diferenciador paso-bajo para resaltar los cambios rápidos o pendientes pronunciadas que están asociadas con los picos, o sea, los latidos cardíacos.

Los picos en la señal PPG corresponden a los picos sistólicos (máximos) y diastólicos (mínimos) del ciclo cardíaco. Con esto se consigue que los pulsos sean más fáciles de detectar en la derivada que en la señal original.

Posteriormente, el algoritmo calcula y ajusta dinámicamente un umbral basado en la señal filtrada, adaptándose en tiempo real a las variaciones en la amplitud de la señal para mejorar la precisión de la detección de picos. Esta capacidad de ajuste dinámico mejora la precisión del algoritmo frente a distintas condiciones.

Rutinas de trabajo.

2.4.2 Procesado de las señales mediante los algoritmos

Una vez preprocesadas las señales PPG tal como se ha explicado en el apartado anterior, se procesan estas señales con cada uno de los algoritmos PAV, PWV y PRV, explicados previamente en la *Tabla 2*, para obtener la derivación respiratoria de manera indirecta.

Cada uno de estos algoritmos utiliza diferentes técnicas y parámetros para procesar la señal PPG, reflejando la complejidad y variedad de enfoques posibles para la derivación respiratoria. La *Figura 16*, proporciona una comparación visual de los resultados de la estimación de la frecuencia respiratoria utilizando los tres algoritmos por separado, PAV, PWV y PRV.

En el *Anexo 5.9*, donde se encuentra el código completo de la rutina 1, están las funciones *generate_PAV*, *generate_PRV* y *generate_PWV* que son las que devuelven las señales respiratorias con cada algoritmo. El interior de las funciones no se muestra, ya que, no han sido compartidos todavía por el grupo de investigación y no es el objetivo de este trabajo.

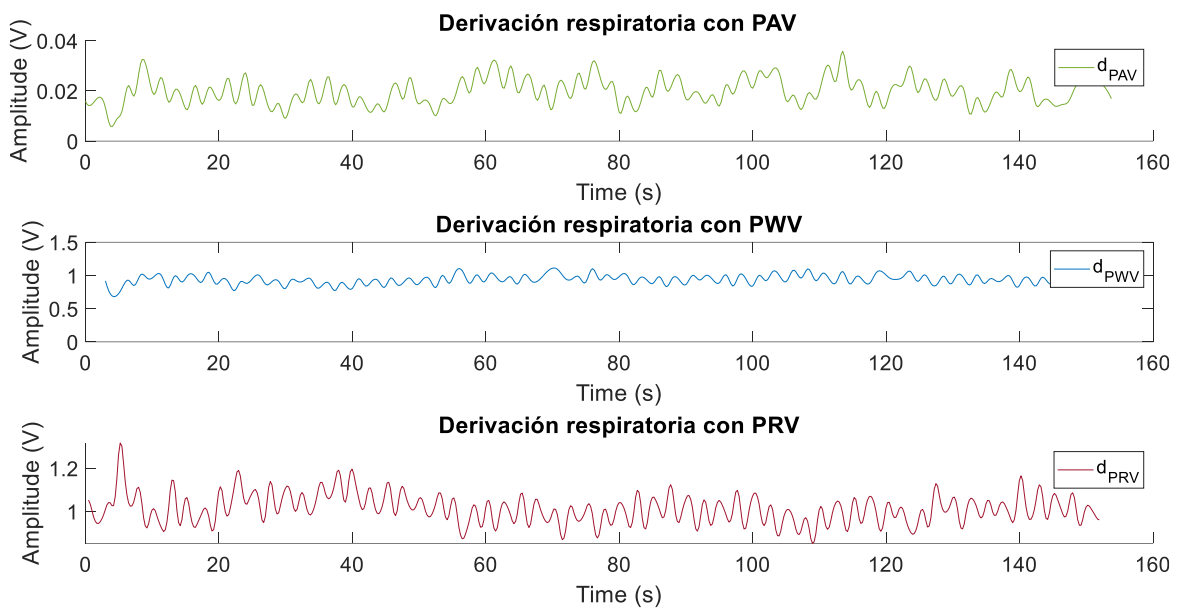


Figura 16. Gráficas de las derivaciones respiratorias obtenidas indirectamente con cada algoritmo.

A medida que se realiza la rutina 1, las señales respiratorias obtenidas, se recortan 2 minutos por el centro y se guardan en un archivo de MATLAB (.mat) para el procesado con el algoritmo basado en la picudez, ya que, combina los otros tres algoritmos y así son más accesibles.

El recorte de las señales se debe a los efectos de borde de la interpolación por *splines*, que extrapola en los bordes, generando el efecto indeseado que aparece en algunas señales y que se muestra en la *Figura 17*, concretamente es la derivación respiratoria obtenida a través de PAV del sujeto 3 en la segunda etapa.

Rutinas de trabajo.

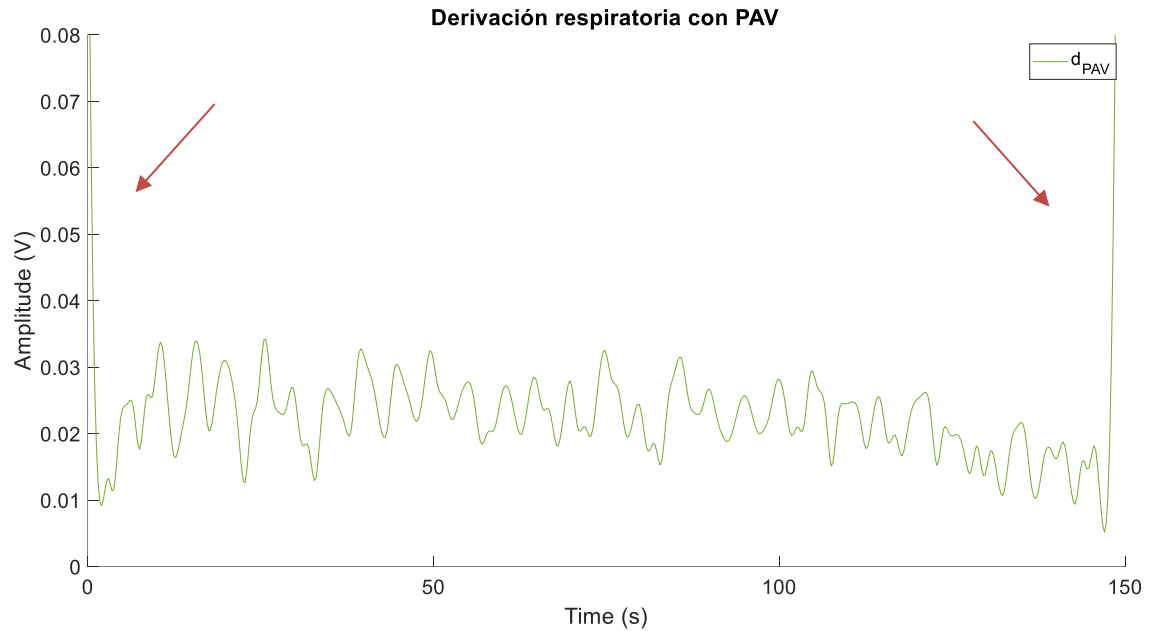


Figura 17. Componente continua.

En el *Código 2*, 'sig' es la señal respiratoria y 'n' el número de puntos que se conservarán para cada lado, es decir, si en total son 120 segundos, 'n' será 60.

```
function [signal] = recorte_120(sig, n)
    centro = round(length(sig)/2);
    izquierda = centro - n;
    derecha = centro + n;
    sig = sig(round(izquierda):round(derecha));
    sig(end) = [];
    signal = sig;
end
```

Código 2. Recorte de las señales 2 min por el centro.

En el *Código 3*, se muestra el proceso de almacenamiento en MATLAB. Los datos se guardan en celdas y cada iteración, es decir, cada etapa, se guarda en una columna de la celda. La variable Resp_S09, o sea, señal respiratoria del sujeto 9, tendrá un subapartado para cada algoritmo (PAV, PWV, PRV) y, en el interior de cada uno, una celda con 5 columnas donde cada una es una etapa (0.1, 0.2, 0.3, 0.4, 0.5 Hz).

```
% Inicialización de las variables
Resp_S09.PRV = cell(1,5);
Resp_S09.PAV = cell(1,5);
Resp_S09.PWV = cell(1,5);

% Guardar datos en celdas
Resp_S09.PRV{1,i} = d_prv'; % Guardar datos en celdas
Resp_S09.PAV{1,i} = d_pav'; % Guardar datos en celdas
Resp_S09.PRV{1,i} = d_pwv'; % Guardar datos en celdas

% Guardar la variable en el directorio
save('Resp_S09', "Resp_S09");
```

Código 3. Almacenamiento de las señales respiratorias.

Rutinas de trabajo.

2.4.3 FFT (*Fast Fourier Transform*)

La estimación de la frecuencia dominante a la que está respirando el sujeto se calcula mediante la FFT (*Fast Fourier Transform*), ya que, es una manera simple de obtener este resultado en MATLAB. Se trata de una herramienta matemática para convertir una señal en el dominio del tiempo al dominio de la frecuencia. En la *Figura 18*, se representa, como ejemplo, el resultado de hacer la FFT a la derivación respiratoria PAV del sujeto 3 respirando a 0.4 Hz.




Figura 18. Representación de la FFT.

En el *Código 4*, se muestra cómo se calcula la FFT en MATLAB. Se inicia generando un vector de frecuencias f , que abarca desde 0 Hz hasta 4 Hz con 4096 puntos. Cabe destacar que esta resolución o número de puntos de la FFT se ha escogido por comparación, ya que, con una resolución de 1024 no era suficiente.

Se utiliza un filtro Butterworth paso-banda de tercer orden y se diseña con la función *butter*. Las frecuencias de corte del filtro se establecen en 0.085 y 1, multiplicadas por 2/4 para normalizarlas y siguiendo la convención del criterio de Nyquist.

El criterio de Nyquist, también conocido como teorema de muestreo de Nyquist-Shannon, es un principio fundamental en el procesamiento de señales digitales que establece que la frecuencia de muestreo de una señal debe ser al menos el doble de la máxima frecuencia contenida en la señal original para poder reconstruirla perfectamente a partir de las muestras.

Posteriormente, el filtro se aplica a la señal respiratoria previamente recortada, mediante la función *filtfilt* y finalmente, se elimina cualquier tendencia lineal de la señal filtrada con *detrend*, y se calcula su transformada de Fourier (FFT) con una resolución de 4096 puntos, extrayendo la magnitud del espectro de frecuencias.

```
f=4*(0:4095)/4096;  
[bb,aa] = butter(3, [0.085,1]*2/4, 'bandpass');  
x = filtfilt(bb,aa, d_prv);  
aux = abs(fft(detrend(x), 4096));
```

Código 4. Cálculo de la FFT.

A continuación, mediante MATLAB se ha extraído la frecuencia máxima del pico máximo de la FFT, es decir, la frecuencia dominante, o sea, a la que está respirando el sujeto. Siguiendo el *Código 5*, primero, se encuentran los índices de las frecuencias f que están entre 0.085 y 2 con `find(f>0.085 & f<2)`. Luego, se seleccionan las frecuencias

Rutinas de trabajo.

correspondientes `f2` y los valores de magnitud espectral `aux2` en esos índices. A continuación, se determina el valor máximo de `aux2` y su índice asociado con `[maximo, max_i] = max(aux2)`. La frecuencia correspondiente a este valor máximo es la frecuencia dominante y se obtiene con `f2(max_i)` y se almacena en `f_dominante`.

```
indices = find(f>0.085 & f<2);  
f2 = f(indices);  
aux2 = aux(indices);  
[maximo, max_i] = max(aux2);  
f_dominante = f2(max_i);
```

Código 5. Selección de la frecuencia máxima de la FFT.

Una vez obtenidas las frecuencias dominantes para cada sujeto y etapa, se han apuntado en Excel y se han calculado los errores absoluto y relativo comparándolas con la frecuencia de referencia. Se han asumido como válidos los errores relativos menores o iguales al 10% y están en las tablas de los *Anexos 5.4* y *5.5*, y el código completo de la rutina 1 se encuentra en el *Anexo 5.9*.

2.4.4 Ondas de Mayer

Sigmund Mayer en 1876 encontró que existen oscilaciones más lentas de la presión arterial no relacionadas con la respiración y son conocidas como ondas de Mayer o LF (*low frequency*) y se encuentran entre 0.04 Hz y 0.15 Hz. Están relacionadas con la modulación simpática del sistema nervioso autónomo que actúa sobre los vasos sanguíneos a través de la información emitida por los barorreceptores [25].

Los barorreceptores son terminaciones nerviosas sensibles a la distensión o estiramiento de los vasos sanguíneos y son los encargados de regular la actividad nerviosa que regula la presión arterial (PA) e influyen en la dinámica cardiovascular a través de mecanismos de retroalimentación negativa para mantener estable la presión arterial [26].

Se cree que las ondas de Mayer afectan a los algoritmos, ya que, el objetivo es medir la frecuencia respiratoria a través de la PPG que está estrechamente relacionada con la presión arterial. En la *Figura 19*, se plantea un ejemplo donde el espectro de frecuencias (resultado de la FFT) muestra un primer máximo en 0.1 Hz y un máximo secundario correspondiente a la frecuencia respiratoria del sujeto. Concretamente, se ilustra la etapa 5 del sujeto 2, por tanto, sí hay una segunda frecuencia dominante que es correcta pero la componente de 0.1 Hz es más dominante y los algoritmos se confunden.

Normalmente, los humanos realizan entre 12 y 20 respiraciones por minuto, lo que equivale a un rango de frecuencias respiratorias de 0.2 a 0.33 Hz, por lo tanto, bajo condiciones normales, los algoritmos no deberían fallar al analizar estos datos, ya que, omitiríamos frecuencias de 0.1 Hz y estaría solucionado. Sin embargo, la respiración varía significativamente entre individuos debido a factores como el estilo de vida, la tensión arterial, síndromes o enfermedades respiratorias, entre otros. Por esta razón, aunque la frecuencia respiratoria normal oscila entre 0.2 y 0.33 Hz, no se pueden filtrar las frecuencias iguales o inferiores a 0.1 Hz.

Rutinas de trabajo.




Figura 19. Fenómeno de dominancia de la frecuencia de la modulación simpática.

En este trabajo, se separan los dos estudios para medir, entre otras cosas, cómo afecta este fenómeno a los algoritmos. Los errores se calculan de dos maneras distintas: filtrando paso-alto a partir de 0.085 Hz y a partir de 0.15 Hz, por separado. Esto se debe a que la frecuencia de 0.1 Hz, generada por la modulación simpática del sistema nervioso, puede confundir a los algoritmos. Sin embargo, es un problema externo al uso del *wearable* y a los algoritmos desarrollados, ya que esta frecuencia es intrínseca al funcionamiento del sistema nervioso autónomo.

2.5 Descripción de la rutina 2

La rutina 2 se encarga del procesamiento de todas las señales mediante el algoritmo basado en la picudez, explicado en el apartado 1.5. En la *Figura 20*, se encuentra un esquema de la rutina 2 para un sujeto y una etapa, en la realidad, se realiza un bucle para todas las etapas de cada sujeto. El código de la rutina 2 completa se encuentra en el *Anexo 5.10*.

Las señales de entrada son las señales respiratorias obtenidas y almacenadas en archivos de MATLAB (.mat) con la rutina 1, lo que simplifica su manipulación. Se realiza un análisis separado para frecuencias superiores a 0.085 y 0.15, aprovechando que las bases de datos se guardaron por separado en la rutina anterior y para ver si mejoran los resultados de este algoritmo si filtramos a 0.15 Hz, evitando así las ondas de Mayer.

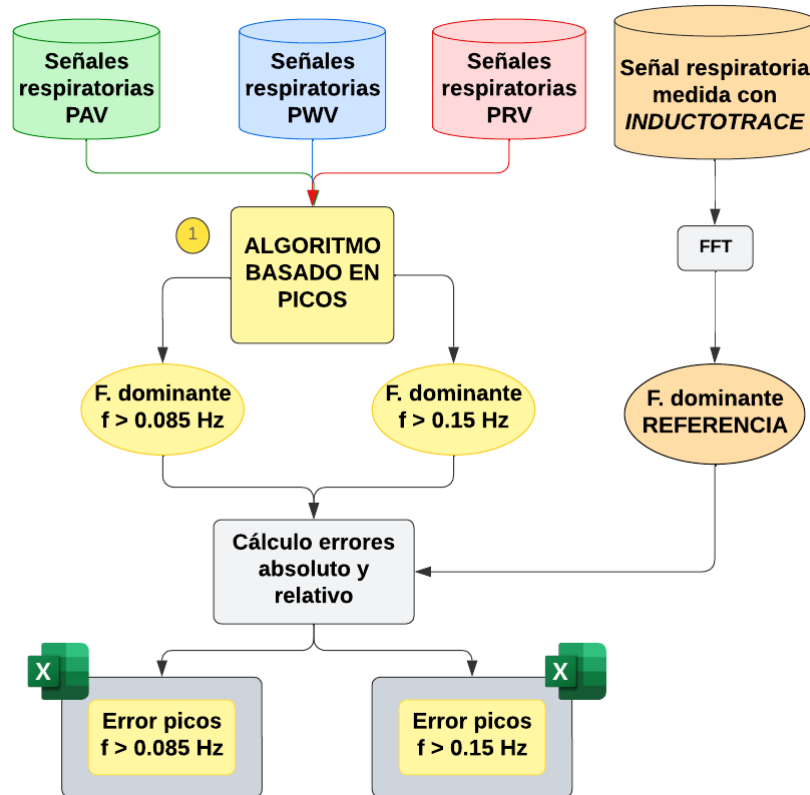


Figura 20. Esquema de la rutina 2 para un sujeto y una etapa.

Se tratan las señales respiratorias obtenidas con cada algoritmo y se procesan con el algoritmo basado en la picudez (*Figura 19*, punto 1). Una vez se obtiene la frecuencia dominante a través del espectro de potencia de los periodogramas de Welch y la selección de las señales respiratorias más picudas, se compara con la frecuencia de referencia y se calcula el error relativo y absoluto en Excel. Las tablas con estos resultados se encuentran en los *Anexos 5.6* y *5.7*.

En cada iteración se grafica el espectro de densidad espectral de potencia, resultado de los periodogramas de Welch, obteniendo un gráfico con la frecuencia dominante. En este caso se trata del sujeto nueve en la etapa 3 y filtrando a 0.15 Hz para evitar las ondas de Mayer y, como se puede observar, la frecuencia dominante corresponde.

3 Resultados

3.1 Estadística

En este apartado se muestran en la *Tabla 3*, los resultados estadísticos obtenidos y se dividen para frecuencias mayores a 0.085 y, por otro lado, para frecuencias mayores a 0.15 Hz. Cabe destacar que se admiten como estimaciones precisas aquellas cuyo error relativo es menor o igual al 10%, y las métricas utilizadas son:

1. **Mediana del error relativo** para cada algoritmo (PAV, PRV, PWV, PICOS) y cada etapa (0.1, 0.2, 0.3, 0.4, 0.5 Hz). Este valor proporciona una medida central de los errores relativos, indicando el valor medio de la distribución de errores.
2. **Cobertura**, es decir, número total de muestras con error relativo menor al 10% con respecto del total. Se cuenta el número de muestras que tienen errores relativos menores o iguales al 10% y se expresa como una fracción respecto al total de muestras para cada algoritmo y etapa y, por otro lado, para el total de muestras de todos los sujetos y etapas en cada algoritmo. Esta métrica indica la proporción de casos en los que los errores son considerados aceptables.
3. **Primer cuartil (Q1) y Tercer cuartil (Q3) del error relativo**, calculados por etapas y algoritmos. El primer cuartil representa el valor por debajo del cual se encuentra el 75% de los datos. Estos valores proporcionan información sobre la dispersión y la variabilidad de los errores relativos.

En base a los resultados presentados en la *Tabla 3*, se puede afirmar que el algoritmo PAV muestra un desempeño ligeramente superior en comparación con los otros algoritmos evaluados, logrando una precisión de aproximadamente el 50%. Este aspecto será analizado con mayor detalle en el capítulo de discusión, donde se evaluará la cobertura de los *wearables*.

Al filtrar la frecuencia correspondiente a las ondas de Mayer (0.1 Hz), se observa que los algoritmos tienden a cometer menos errores, mejorando su precisión. Esta frecuencia es inherente a la fiabilidad de los algoritmos debido a su origen en el sistema nervioso autónomo. Por otro lado, en la primera etapa, los algoritmos muestran un buen rendimiento, ya que, además de la frecuencia respiratoria, se incluye la componente de 0.1 Hz propia de las ondas de Mayer, por lo que, en el espectro la frecuencia de 0.1 Hz presentará todavía más dominancia que si no existieran las ondas de Mayer. Otros estudios sobre la obtención de diferentes parámetros a través de la PPG también han sido afectados por este fenómeno. [27]

El análisis de los cuartiles revela que, cuando los algoritmos presentan un desempeño deficiente, los valores de los errores relativos se incrementan considerablemente, lo que indica una variabilidad significativa en esos casos. Por lo tanto, los errores extremos no son tan relevantes para evaluar el rendimiento general del algoritmo, simplemente indican que no ha funcionado correctamente.

El algoritmo de picos, diseñado inicialmente para el análisis de la señal PPG a través de cámaras de smartphones, se esperaba que mejorara el rendimiento al compararlo con los algoritmos individuales. Sin embargo, los resultados en la *Tabla 3* muestran que

Resultados y conclusión.

no ha habido una mejora significativa. La idea original era utilizar el mejor de los tres algoritmos por separado y potencialmente mejorarlo. Concluimos que el algoritmo diseñado para smartphones no se adapta directamente a los *wearables* y requiere ajustes o rediseño para optimizar su rendimiento en este nuevo contexto.

Consideraremos como válida la cobertura de los experimentos filtrados a 0.085 Hz, ya que, como hemos comentado, la frecuencia respiratoria varía mucho dependiendo de factores externos, por tanto, el *wearable* diseñado por la Universidad de Lituania, da como resultado para este estudio una cobertura media del 45%.

		f > 0.085 Hz				f > 0.15 Hz				
		Etapas	PAV	PRV	PWV	PICOS	PAV	PRV	PWV	PICOS
COBERTURA	0.1	4/8	3/8	6/8	4/8	-	-	-	-	-
	0.2	4/8	6/8	3/8	4/8	5/8	6/8	4/8	7/8	
	0.3	3/8	2/8	3/8	3/8	4/8	4/8	4/8	5/8	
	0.4	4/8	4/8	3/8	4/8	5/8	4/8	4/8	4/8	
	0.5	4/8	1/8	2/8	2/8	4/8	3/8	2/8	4/8	
COBERTURA TOTAL		19/40	17/40	18/40	18/40	18/32	17/32	14/32	20/32	
PRIMER CUARTIL (Q1)	0.1	4.60	1.40	0.60	1.17	-	-	-	-	
	0.2	1.35	2.36	5.02	1.73	0.77	0.62	3.94	1.29	
	0.3	0.95	32.34	4.42	1.12	1.03	1.05	2.15	0.36	
	0.4	0.93	1.53	0.47	0.93	0.93	0.93	0.47	0.93	
	0.5	0.83	35.44	11.66	7.42	0.68	0.98	26.47	0.54	
TERCER CUARTIL (Q3)	0.1	124.6 3	55.75	16.68	24.02	-	-	-	-	
	0.2	42.05	5.34	39.81	28.10	54.78	24.74	55.29	4.91	
	0.3	45.72	58.58	60.12	58.01	30.72	44.53	19.36	14.96	
	0.4	27.32	50.02	66.74	67.90	27.37	18.61	27.13	46.35	
	0.5	45.85	75.19	76.26	82.81	41.84	44.62	61.09	55.76	
MEDIANA ERROR REL (%)	0.1	10.75	12.80	1.95	2.34	-	-	-	-	
	0.2	20.65	4.55	17.35	13.82	2.70	4.05	14.55	3.08	
	0.3	34.18	45.43	34.07	48.73	14.48	3.33	9.18	1.63	
	0.4	5.86	10.15	19.31	14.31	5.86	5.98	14.91	14.31	
	0.5	10.06	64.16	10.15	65.43	10.35	20.61	47.66	27.25	

Tabla 3. Tabla de las métricas estadísticas.

3.2 Discusión

En el contexto de los dispositivos *wearables*, a menudo no se mide directamente, sino que se aplica un detector de artefactos o interferencias debido a la naturaleza ruidosa de las mediciones. Esta necesidad de renunciar a la medición directa se debe a que las señales captadas por los *wearables* están frecuentemente contaminadas por ruido e interferencias, lo que dificulta obtener datos precisos y fiables en tiempo real.

Resultados y conclusión.

La cobertura es una medida importante para evaluar la calidad y fiabilidad de los datos obtenidos y del sistema de medición utilizado. En este trabajo el dispositivo *wearable* para 8 sujetos ha resultado tener una cobertura media del 45% para muestras de 2 minutos de longitud. En otros estudios han obtenido una cobertura del 14.76% durante condiciones controladas de laboratorio [28].

Este enfoque de utilizar detectores de señales permite que los algoritmos analicen sólo señales de calidad y que no sean susceptibles a los factores ruidosos a los que está expuesta la tecnología actual de los *wearables*. De esta manera, como es una herramienta viable para el monitoreo continuo se podrían analizar grandes volúmenes de datos e ir aprendiendo de forma inteligente a través de ellos. La clave está en el procesamiento y análisis de los datos recopilados, que pueden ser filtrados y limpiados para extraer información relevante y precisa, compensando así las limitaciones de cobertura y precisión.

En el ámbito del síndrome de la apnea obstructiva del sueño (AOS), los dispositivos *wearables* presentan tanto oportunidades como desafíos. Durante el sueño, los *wearables* podrían ser particularmente útiles debido a la relativa estabilidad del usuario, lo que reduce el ruido y los artefactos en las mediciones. En un estudio donde las grabaciones con *wearables* eran durante la noche con condiciones de movimiento controlado y restringido, la cobertura fue del 76,34% [29].

Este resultado podría sugerir que los *wearables* podrían ser de gran ayuda para estudios del sueño o, por otro lado, que éstos necesitan de más datos para ofrecer resultados de calidad y fiables.

Duraciones más largas de las mediciones podrían aumentar la precisión de los datos recogidos, ya que, una de las ventajas de los *wearables* es que permiten también una monitorización continua de parámetros como la frecuencia cardíaca, la saturación de oxígeno y los patrones de respiración, que son cruciales para la detección y seguimiento de la AOS, ya que, como se ha comentado anteriormente, esta enfermedad se diagnostica con una prueba del sueño, ya sea en casa o en la unidad del sueño del hospital, por lo que no se estudia durante largos periodos de tiempo.

3.3 Conclusión

La detección y tratamiento temprano de la apnea obstructiva del sueño (AOS) es crucial para prevenir complicaciones. La polisomnografía (PSG) es el método estándar de diagnóstico, pero es costoso, invasivo y requiere pasar una noche en un laboratorio del sueño, lo que genera largas listas de espera debido a la alta prevalencia del síndrome.

Los *wearables*, como relojes inteligentes y pulseras de actividad, ofrecen una alternativa atractiva para la detección y monitoreo de la AOS. Estos dispositivos pueden registrar datos como la frecuencia cardíaca, actividad física y patrones de sueño, que son útiles para identificar y evaluar la AOS. Son cómodos, prácticos, de bajo coste, socialmente aceptados y tienen larga duración de batería, permitiendo una gran recolección de datos. Numerosos investigadores han obtenido resultados positivos con estos dispositivos. Por ejemplo, un estudio en Turquía comparó datos de la PSG de 115

Resultados y conclusión.

sujetos con los de un *smartwatch* y encontró que los dispositivos portátiles fueron efectivos en la detección de AOS severa [30]. Sin embargo, los *wearables* presentan inconvenientes en cuanto a precisión debido a factores como la luz y el movimiento.

Teniendo en cuenta que las señales analizadas solo tenían una duración de dos minutos y que el estudio ha sido realizado en 8 sujetos, no se puede concluir de forma definitiva que el método experimentado y los algoritmos usados sean válidos. Sin embargo, alcanzar una cobertura media del 45%, como se ha visto en el apartado de discusión, no cabe duda de que es una línea de investigación prometedora.

Hay áreas de mejora, como en el tratamiento de la frecuencia debida a las ondas de Mayer y la aplicación de selectores de señales para elegir las de mayor calidad. Sin embargo, a medida que la tecnología continúa avanzando los *wearables* pueden ser útiles para el screening inicial de AOS, especialmente en pacientes de alto riesgo, y para el monitoreo continuo de pacientes diagnosticados para evaluar y ajustar tratamientos. Se necesitan más investigaciones para evaluar la precisión y la efectividad de los *wearables* en diversas poblaciones de pacientes y para desarrollar algoritmos de análisis de datos más robustos.

Por otro lado, comentar que los objetivos a nivel personal planteado al inicio de este trabajo se han cumplido con éxito, analizando y desarrollando mis habilidades en Excel y MATLAB, así como ampliando mis conocimientos sobre la fotopletismografía, el Síndrome de Apnea Obstructiva del Sueño y las aplicaciones de los *wearables*.

3.4 Líneas futuras de trabajo

Para mejorar la precisión y robustez de la estimación de la frecuencia respiratoria a través de señales PPG obtenidas mediante el *wearable*, se proponen las siguientes líneas de trabajo futuras.

Primero, es esencial mejorar el algoritmo de fusión. Se esperaban unos resultados mucho mejores al aplicar el algoritmo de picudez, por lo que tal vez, se debería ajustar específicamente para los *wearables* o pensar en un algoritmo alternativo.

También se propone calcular el promediado con un peso en función de la picudez de las señales respiratorias en lugar de hacer el promedio entre las dos más picudas. Al ponderar los espectros según su relevancia, se logrará un promedio ponderado que refleje mejor la contribución de cada señal. Esto podría evitar una decisión tajante de inclusión o exclusión, proporcionando una estimación más precisa y adaptativa.

En segundo lugar, utilizar señales más largas puede ser beneficioso. Extender la duración de las señales analizadas mejorará la resolución espectral y la robustez de las estimaciones, ya que, en este trabajo son de 2 minutos. Las señales más largas proporcionan más datos, ayudando a suavizar las variaciones aleatorias y mejorando la fiabilidad de los resultados.

Resultados y conclusión.

Finalmente, es crucial desarrollar detectores de artefactos específicos para señales PPG respiratorias, ya que, como se ve en los resultados cuando funciona mal se dispara el error relativo sin una causa justificada.

Estos detectores permitirán identificar y excluir automáticamente segmentos de señal contaminados por ruido, movimiento u otros factores externos. Por tanto, sería interesante implementar un algoritmo automático que evalúe la calidad de la señal y la elija para el estudio o directamente la descarte.

4 Referencias

- [1] Z. Cao, R. Zhu, and R. Y. Que, “A wireless portable system with microsensors for monitoring respiratory diseases,” *IEEE Trans Biomed Eng*, vol. 59, no. 12 PART2, pp. 3110–3116, 2012, doi: 10.1109/TBME.2012.2211354.
- [2] J. F. Fie and C. M. Helms, “Respiratory Rate Predicts Cardiopulmonary Arrest for Internal Medicine Inpatients,” 1993.
- [3] X. Yang *et al.*, “Textile fiber optic microbend sensor used for heartbeat and respiration monitoring,” *IEEE Sens J*, vol. 15, no. 2, pp. 757–761, Feb. 2015, doi: 10.1109/JSEN.2014.2353640.
- [4] A. Nicolò, C. Massaroni, E. Schena, and M. Sacchetti, “The importance of respiratory rate monitoring: From healthcare to sport and exercise,” *Sensors (Switzerland)*, vol. 20, no. 21. MDPI AG, pp. 1–45, Nov. 01, 2020. doi: 10.3390/s20216396.
- [5] I. Homma and Y. Masaoka, “Breathing rhythms and emotions,” *Experimental Physiology*, vol. 93, no. 9. Blackwell Publishing Ltd, pp. 1011–1021, 2008. doi: 10.1113/expphysiol.2008.042424.
- [6] Y. Masaoka and I. Homma, “The effect of anticipatory anxiety on breathing and metabolism in humans,” 2001. [Online]. Available: www.elsevier.com/locate/resphysiol
- [7] U. C. Gatti, S. Schneider, and G. C. Migliaccio, “Physiological condition monitoring of construction workers,” *Autom Constr*, vol. 44, pp. 227–233, 2014, doi: 10.1016/j.autcon.2014.04.013.
- [8] C. Varon, A. Caicedo, D. Testelmans, B. Buyse, and S. Van Huffel, “A Novel Algorithm for the Automatic Detection of Sleep Apnea from Single-Lead ECG,” *IEEE Trans Biomed Eng*, vol. 62, no. 9, pp. 2269–2278, Sep. 2015, doi: 10.1109/TBME.2015.2422378.
- [9] N. González Mangado, C. J. Egea-Santaolalla, E. Chiner Vives, and O. Mediano, “Sleep Obstructive Apnea,” *Open Respiratory Archives*, vol. 2, no. 2. Elsevier Espana S.L.U, pp. 46–66, Apr. 01, 2020. doi: 10.1016/j.opresp.2020.03.008.
- [10] Carmen Delia Aranda, “Canarias duerme mal y la unidad del sueño no da abasto,” <https://www.canarias7.es/sociedad/salud/dormimos-unidad-sueno-20221113202702-nt.html>.
- [11] J. Oto, “El acceso a la unidad del sueño aún cuenta con un año de demora,” <https://www.elperiodicodearagon.com/aragon/2017/02/26/acceso-unidad-sueno-cuenta-ano-46953732.html>.
- [12] O. Mediano *et al.*, “Upcoming Scenarios for the Comprehensive Management of Obstructive Sleep Apnea: An Overview of the Spanish Sleep Network,” *Arch Bronconeumol*, vol. 56, no. 1, pp. 35–41, Jan. 2020, doi: 10.1016/j.arbres.2019.05.017.
- [13] E. Vanegas, R. Igual, and I. Plaza, “Sensing systems for respiration monitoring: A technical systematic review,” *Sensors (Switzerland)*, vol. 20, no. 18. MDPI AG, pp. 1–84, 2020. doi: 10.3390/s20185446.
- [14] C. Massaroni, A. Nicolò, D. Lo Presti, M. Sacchetti, S. Silvestri, and E. Schena, “Contact-based methods for measuring respiratory rate,” *Sensors (Switzerland)*, vol. 19, no. 4. MDPI AG, Feb. 02, 2019. doi: 10.3390/s19040908.
- [15] H. Yoon and S. H. Choi, “Technologies for sleep monitoring at home: wearables and nearables,” *Biomedical Engineering Letters*, vol. 13, no. 3. Springer Verlag, pp. 313–327, Aug. 01, 2023. doi: 10.1007/s13534-023-00305-8.

- [16] F. Mendonça, S. S. Mostafa, A. G. Ravelo-García, F. Morgado-Dias, and T. Penzel, “A Review of Obstructive Sleep Apnea Detection Approaches,” *IEEE Journal of Biomedical and Health Informatics*, vol. 23, no. 2. Institute of Electrical and Electronics Engineers Inc., pp. 825–837, Mar. 01, 2019. doi: 10.1109/JBHI.2018.2823265.
- [17] M. Olsen, E. Mignot, P. J. Jennum, and H. B. Dissing Sorensen, “Robust, ECG-based detection of sleep-disordered breathing in large population-based cohorts,” *Sleep*, vol. 43, no. 5, May 2020, doi: 10.1093/sleep/zsz276.
- [18] H. Yoon and S. H. Choi, “Technologies for sleep monitoring at home: wearables and nearables,” *Biomedical Engineering Letters*, vol. 13, no. 3. Springer Verlag, pp. 313–327, Aug. 01, 2023. doi: 10.1007/s13534-023-00305-8.
- [19] A. A. Alian and K. H. Shelley, “Photoplethysmography,” *Best Practice and Research: Clinical Anaesthesiology*, vol. 28, no. 4. Bailliere Tindall Ltd, pp. 395–406, 2014. doi: 10.1016/j.bpa.2014.08.006.
- [20] H. W. Loh *et al.*, “Application of photoplethysmography signals for healthcare systems: An in-depth review,” *Computer Methods and Programs in Biomedicine*, vol. 216. Elsevier Ireland Ltd, Apr. 01, 2022. doi: 10.1016/j.cmpb.2022.106677.
- [21] J. Park, H. S. Seok, S. S. Kim, and H. Shin, “Photoplethysmogram Analysis and Applications: An Integrative Review,” *Frontiers in Physiology*, vol. 12. Frontiers Media S.A., Mar. 01, 2022. doi: 10.3389/fphys.2021.808451.
- [22] J. Lázaro, R. Bailón, P. Laguna, Y. Nam, K. Chon, and E. Gil, “Respiratory Rate Influence in the Resulting Magnitude of Pulse Photoplethysmogram Derived Respiration Signals,” *Comput Cardiol (2010)*, vol. 41, pp. 289–292, 2014.
- [23] J. Lázaro, Y. Nam, E. Gil, P. Laguna, and K. H. Chon, “Respiratory rate derived from smartphone-camera-acquired pulse photoplethysmographic signals,” *Physiol Meas*, vol. 36, no. 11, pp. 2317–2333, Oct. 2015, doi: 10.1088/0967-3334/36/11/2317.
- [24] KTU Biomedical Engineering Institute, “Smart wrist-worn device developed by Lithuanian researchers can alert about dangerous health conditions,” <https://feec.ktu.edu/news/smart-wrist-worn-device-developed-by-lithuanian-researchers-can-alert-about-dangerous-health-conditions/>.
- [25] B. Estañol, M. Porrás-Betancourt, M. Ángel Padilla-Leyva, and H. Sentfies-Madrid, “Breve historia del relejo barorreceptor: de Claude Bernard a Arthur C. Guyton. Ilustrada con algunos experimentos clásicos,” 2011. [Online]. Available: www.elsevier.com.mx
- [26] A. Robles-Cabrera, A. Michel-Chávez, R. C. Callejas-Rojas, C. Malamud-Kessler, G. Delgado, and B. Estañol-Vidal, “The cardiovagal, cardiosympathetic and vasosympathetic arterial baroreflexes and the neural control of short-term blood pressure,” *Rev Neurol*, vol. 59, no. 11, pp. 508–516, 2014, doi: 10.33588/rn.5911.2014314.
- [27] W. Karlen, S. Raman, J. M. Ansermino, and G. A. Dumont, “Multiparameter respiratory rate estimation from the photoplethysmogram,” *IEEE Trans Biomed Eng*, vol. 60, no. 7, pp. 1946–1953, 2013, doi: 10.1109/TBME.2013.2246160.
- [28] S. K. Bashar *et al.*, “Atrial Fibrillation Detection from Wrist Photoplethysmography Signals Using Smartwatches,” *Sci Rep*, vol. 9, no. 1, Dec. 2019, doi: 10.1038/s41598-019-49092-2.
- [29] A. Tarniceriu *et al.*, *The Accuracy of Atrial Fibrillation Detection from Wrist Photoplethysmography. A Study on Post-Operative Patients*. 2018. doi: 10.0/Linux-x86_64.
- [30] P. Cinar Bilge *et al.*, “Scanning of obstructive sleep apnea syndrome using smartwatch: A comparison of smartwatch and polysomnography,” *Journal of Clinical Neuroscience*, vol. 119, pp. 212–219, Jan. 2024, doi: 10.1016/j.jocn.2023.12.009.

5 Anexos

5.1 Etapas referencia

En esta tabla se muestran los milisegundos apuntados que corresponden al inicio y al final de cada etapa y sujeto.

S	ETAPA 1	ETAPA 2	ETAPA 3	ETAPA 4	ETAPA 5
S02	396761:572577	572577:746753	746753:937168	937168:1112550	1352840:1503500
S03	551860:720673	732313:896595	986545:1147970	1299430:1460660	1557510:1718850
S04	963345:1147540	1197200:1369590	1436400:1597570	1631460:1800130	1821010:1989280
S05	438713:602018	621209:787841	829521:988849	1001450:1164310	1195840:1354540
S06	599243:797289	806368:1013490	102995:1231400	1254380:1454980	1487330:1685370
S07	584489:796153	820273:1016030	1069390:1258640	1297790:1491590	1545780:1742120
S08	550057:720289	727364:898865	967465:1144790	1211600:1376570	1422450:1589400
S09	600753:796433	846658:1043560	1098510:1290640	1313960:1500380	1526770:1713180
S10	608321:799265	826225:1021980	1062860:1257500	1296620:1484230	1574150:1770490

5.2 Código del recorte de las etapas de referencia para un sujeto

```
%% Cortes de las señales por etapas
tiledlayout(6,1)

figure(1)
ax1 = nexttile;
x1 = data(:,1);
plot(x1)
title('Volts')
ax2 = nexttile;
x2 = data(:,2);
plot(x2)
title('Volts')
ax3 = nexttile;
x3 = data(:,3);
plot(x3)
title('Volts')
ax4 = nexttile;
x4 = data(:,4);
plot(x4)
title('Pulse')
ax5 = nexttile;
x5 = data(:,5);
plot(x5)
title('Rate, BPM')
ax6 = nexttile;
x6 = data(:,6);
plot(x6)
title('Status')
```

```

linkaxes([ax1 ax2 ax3 ax4 ax5 ax6], 'x');

s1 = data(551860:720673,3);
s2 = data(732313:896595,3);
s3 = data(986545:1147970,3);
s4 = data(1299430:1460660,3);
s5 = data(1557510:1718850,3);

etapas = {s1, s2, s3, s4, s5};

save('sujeto3.mat', 'etapas', '-append');

```

5.3 Código frecuencia dominante de la referencia para un sujeto

```

clear; close all;

for i = 1:5
    et = etapas{1,i};
    centro = round(length(et)/2);
    izquierda = centro - 45000;
    derecha = centro + 45000;
    sig = et(izquierda:derecha);

    % Calcular la FFT
    N = length(sig);
    fs = 1000; % Frecuencia de muestreo (ejemplo)
    aux = abs(fft(sig));
    f = (0:N-1) * (fs/N); % Vector de frecuencias

    f_resp = i * 0.1;
    % Encontrar la frecuencia dominante dentro del rango deseado
    f_indices = f > 0.085;
    [~, max_i] = max(aux(f_indices));
    s = f(f_indices);
    s = s(max_i);

    % Mostrar resultados
    fprintf('Etapas{1,%d}:\n', i);
    fprintf('Frecuencia dominante: %.10f\n', s);
    fprintf('Error absoluto: %.10f\n', abs(s - f_resp));
    fprintf('Error relativo (%): %.10f\n\n', (abs(s -
f_resp)/f_resp)*100);

    % Gráfico de la señal normal y su FFT
    figure;
    subplot(2, 1, 1);
    plot(sig);
    title(sprintf('Señal Normal - Etapa %d', i));
    xlabel('Tiempo (s)');
    ylabel('Amplitud (V)');

    subplot(2, 1, 2);
    plot(f, aux);
    title(sprintf('FFT - Etapa %d', i));
    xlabel('Frecuencia (Hz)');
    ylabel('Módulo');
    xlim([0, fs/2]);

    % Ajustar el tamaño de la figura para mejorar la visualización

```

```

set(gcf, 'Position', [100, 100, 800, 600]);
end

```

5.4 Errores rutina 1, $f > 0.085$ Hz

La siguiente tabla muestra los errores relativo y absoluto de cada etapa (0.1, 0.2, 0.3, 0.4, 0.5) mediante los algoritmos PAV, PRV y PWV, filtrando a partir de 0.085 Hz. A continuación, se explicará el significado de cada parámetro de la tabla y esta explicación sirve para las demás tablas también.

- REF se refiere a la frecuencia dominante de referencia en Hz medida por el *Inductotrace*.
- S es la abreviatura de Sujeto.
- FD es la frecuencia dominante resultante de la FFT y en Hz.
- ABS es el error absoluto en Hz, que es la diferencia entre la frecuencia de referencia y la frecuencia dominante obtenida con los diferentes algoritmos.
- REL es el error relativo en porcentaje.

WEARABLE (2 min) > 0.085 Hz											
REF	S	ERROR PAV			ERROR PRV			ERROR PWV			
		FD (Hz)	ABS (Hz)	REL (%)	FD (Hz)	ABS (Hz)	REL (%)	FD (Hz)	ABS (Hz)	REL (%)	
0.1	S02	0.09	0.01	5.30	0.10	0.00	1.40	0.10	0.00	0.60	
	S03	0.10	0.00	1.40	0.10	0.00	0.40	0.10	0.00	0.60	
	S04	0.09	0.01	14.10	0.11	0.01	12.30	0.10	0.00	0.60	
	S05	0.10	0.00	2.50	0.09	0.09	93.80	0.11	0.01	7.40	
	S06	0.48	0.38	376.61	0.11	0.01	13.30	0.10	0.00	3.30	
	S07	0.29	0.19	194.90	0.19	0.09	89.50	0.16	0.06	58.20	
	S09	0.11	0.01	7.40	0.10	0.00	1.40	0.10	0.00	0.60	
	S10	0.20	0.10	101.20	0.14	0.04	44.50	0.14	0.04	44.50	
	0.2	S02	0.12	0.08	40.90	0.19	0.01	4.80	0.19	0.01	6.25
		S03	0.20	0.00	1.35	0.19	0.01	2.85	0.20	0.00	1.35
S04		0.29	0.09	45.50	0.20	0.00	0.90	0.13	0.07	37.00	
S05		0.20	0.00	0.10	0.14	0.14	72.25	0.14	0.06	27.75	
S06		0.19	0.01	3.30	0.19	0.01	4.80	0.10	0.10	48.25	
S07		0.38	0.18	91.90	0.19	0.01	4.30	0.42	0.22	112.40	
S09		0.20	0.00	1.35	0.20	0.00	0.40	0.20	0.00	0.90	
S10		0.12	0.08	38.00	0.21	0.01	6.95	0.21	0.01	6.95	
0.3		S02	0.30	0.00	0.70	0.11	0.19	62.23	0.11	0.19	62.57
		S03	0.30	0.00	0.70	0.30	0.00	0.27	0.30	0.00	0.40
	S04	0.09	0.21	71.37	0.17	0.13	43.03	0.24	0.06	21.53	
	S05	0.20	0.10	33.93	0.13	0.13	44.27	0.12	0.18	59.30	
	S06	0.30	0.00	1.03	0.65	0.35	115.17	0.11	0.19	62.90	
	S07	0.40	0.10	34.43	0.13	0.17	57.37	0.30	0.00	0.90	
	S09	0.17	0.13	43.03	0.30	0.00	0.07	0.28	0.02	5.60	

	S10	0.14	0.16	53.77	0.16	0.14	46.60	0.16	0.14	46.60
	S02	0.40	0.00	0.35	0.41	0.01	1.58	0.40	0.00	0.58
	S03	0.40	0.00	0.15	0.40	0.00	0.35	0.40	0.00	0.15
	S04	0.38	0.02	6.25	0.36	0.04	10.40	0.34	0.06	15.27
0.4	S05	0.42	0.02	5.48	0.17	0.17	42.48	0.09	0.31	77.30
	S06	0.40	0.00	1.12	0.39	0.01	1.37	0.40	0.00	0.10
	S07	0.23	0.17	42.15	0.11	0.29	72.65	0.15	0.25	63.62
	S09	0.31	0.09	22.37	0.36	0.04	9.90	0.31	0.09	23.35
	S10	0.17	0.23	58.25	0.10	0.30	76.07	0.10	0.30	76.07
	S02	0.11	0.39	77.92	0.13	0.37	74.22	0.13	0.37	74.60
	S03	0.26	0.24	47.46	0.45	0.05	10.54	0.45	0.05	9.76
	S04	0.50	0.00	0.98	0.28	0.22	43.74	0.44	0.06	12.30
0.5	S05	0.49	0.01	2.34	0.27	0.27	54.88	0.20	0.30	59.38
	S06	0.50	0.00	0.00	0.50	0.00	0.98	0.49	0.01	1.96
	S07	0.41	0.09	17.78	0.13	0.37	73.44	0.09	0.41	81.24
	S09	0.50	0.00	0.40	0.11	0.39	78.12	0.17	0.33	66.22
	S10	0.27	0.23	45.32	0.09	0.41	81.24	0.09	0.41	81.24

5.5 Errores rutina 1, $f > 0.15$ Hz

<i>WEARABLE (2 min) > 0.15 Hz</i>										
REF	S	ERROR PAV			ERROR PRV			ERROR PWV		
		EX (Hz)	ABS (Hz)	REL (%)	EX (Hz)	ABS (Hz)	REL (%)	EX (Hz)	ABS (Hz)	REL (%)
	S02	0.21	0.01	2.55	0.19	0.01	4.80	0.19	0.01	6.75
	S03	0.20	0.00	0.90	0.20	0.00	1.85	0.20	0.00	1.35
	S04	0.29	0.09	45.00	0.20	0.00	0.10	0.27	0.07	36.25
0.2	S05	0.20	0.00	0.10	0.20	0.14	72.25	0.44	0.24	119.25
	S06	0.19	0.01	2.85	0.52	0.32	160.75	0.19	0.01	4.80
	S07	0.38	0.18	91.90	0.19	0.01	3.30	0.42	0.22	112.40
	S09	0.20	0.00	0.40	0.20	0.00	0.10	0.20	0.00	0.40
	S10	0.37	0.17	84.10	0.22	0.02	8.90	0.16	0.04	22.35
	S02	0.30	0.00	1.03	0.74	0.44	146.74	0.52	0.22	71.87
	S03	0.30	0.00	0.70	0.30	0.00	0.07	0.30	0.00	0.40
	S04	0.47	0.17	58.20	0.29	0.01	3.33	0.26	0.04	12.77
0.3	S05	0.23	0.07	23.17	0.20	0.13	44.27	0.26	0.04	12.77
	S06	0.30	0.00	1.03	0.30	0.00	0.70	0.29	0.01	2.67
	S07	0.40	0.10	34.77	0.36	0.06	21.10	0.30	0.00	0.60
	S09	0.21	0.09	29.37	0.30	0.00	0.40	0.28	0.02	5.60
	S10	0.32	0.02	5.80	0.16	0.14	45.30	0.18	0.12	39.13
	S02	0.40	0.00	0.35	0.41	0.01	1.80	0.40	0.00	0.58
	S03	0.40	0.00	0.15	0.40	0.00	0.35	0.40	0.00	0.15
0.4	S04	0.38	0.02	6.25	0.36	0.04	10.65	0.24	0.16	41.15
	S05	0.42	0.02	5.48	0.17	0.17	42.48	0.32	0.08	19.92
	S06	0.40	0.00	1.12	0.40	0.00	1.12	0.40	0.00	0.10

	S07	0.23	0.17	42.37	0.40	0.00	0.83	0.36	0.04	9.90
	S09	0.31	0.09	22.37	0.36	0.04	10.15	0.31	0.09	23.35
	S10	0.23	0.17	43.12	0.18	0.22	54.82	0.25	0.15	38.47
0.5	S02	0.51	0.01	2.92	0.27	0.23	46.68	0.29	0.21	41.02
	S03	0.26	0.24	47.46	0.45	0.05	10.36	0.45	0.05	9.76
	S04	0.50	0.00	0.78	0.28	0.22	43.94	0.34	0.16	32.04
	S05	0.30	0.20	40.62	0.27	0.27	54.88	0.20	0.30	59.38
	S06	0.50	0.00	0.00	0.50	0.00	0.98	0.49	0.01	1.76
	S07	0.41	0.09	17.78	0.35	0.15	30.86	0.16	0.34	68.74
	S09	0.50	0.00	0.40	0.50	0.00	0.40	0.17	0.33	66.22
	S10	0.27	0.23	45.50	0.50	0.00	0.78	0.23	0.27	54.30

5.6 Errores rutina 2, $f > 0.085$ Hz

REF	S	ERROR PICOS $f > 0.085$ Hz			
		FD (Hz)	ABS (Hz)	REL (%)	
0.1	S02	0.10	0.00	0.59	
	S03	0.10	0.00	0.59	
	S04	0.11	0.01	12.31	
	S05	0.10	0.00	1.37	
	S06	0.12	0.02	17.19	
	S07	0.19	0.09	90.43	
	S09	0.10	0.00	2.34	
	S10	0.14	0.04	44.53	
	0.2	S02	0.13	0.07	36.52
		S03	0.20	0.00	1.85
S04		0.20	0.00	1.37	
S05		0.15	0.05	25.29	
S06		0.19	0.01	4.30	
S07		0.12	0.08	39.45	
S09		0.20	0.00	0.10	
S10		0.15	0.05	23.34	
0.3		S02	0.12	0.18	58.98
		S03	0.30	0.00	0.26
	S04	0.14	0.16	52.47	
	S05	0.09	0.21	71.35	
	S06	0.30	0.00	1.37	
	S07	0.13	0.17	57.68	
	S09	0.30	0.00	0.39	
	S10	0.17	0.13	44.99	
	0.4	S02	0.40	0.00	0.34
		S03	0.40	0.00	0.34
S04		0.38	0.02	6.00	
S05		0.09	0.31	78.52	

	S06	0.40	0.00	1.12
	S07	0.14	0.26	64.84
	S09	0.31	0.09	22.61
	S10	0.09	0.31	77.05
0.5	S02	0.09	0.41	82.81
	S03	0.45	0.05	9.57
	S04	0.09	0.41	82.81
	S05	0.12	0.38	76.37
	S06	0.50	0.00	0.98
	S07	0.09	0.41	82.81
	S09	0.50	0.00	0.39
	S10	0.23	0.27	54.49

5.7 Errores rutina 2, $f > 0.15$ Hz

REF	S	ERROR PICOS $f > 0.085$ Hz			
		FD (Hz)	ABS (Hz)	REL (%)	
0.2	S02	0.19	0.01	5.27	
	S03	0.20	0.00	1.85	
	S04	0.20	0.00	1.37	
	S05	0.20	0.00	1.08	
	S06	0.19	0.01	4.78	
	S07	0.19	0.01	4.30	
	S09	0.20	0.00	0.10	
	S10	0.15	0.05	23.34	
	0.3	S02	0.30	0.00	0.06
		S03	0.30	0.00	0.26
S04		0.24	0.06	21.55	
S05		0.26	0.04	12.76	
S06		0.30	0.00	1.37	
S07		0.31	0.01	1.89	
S09		0.30	0.00	0.39	
S10		0.17	0.13	44.34	
0.4		S02	0.40	0.00	0.34
		S03	0.40	0.00	0.34
	S04	0.38	0.02	6.00	
	S05	0.17	0.23	58.25	
	S06	0.40	0.00	1.12	
	S07	0.23	0.17	42.63	
	S09	0.31	0.09	22.61	
	S10	0.17	0.23	57.52	
	0.5	S02	0.28	0.22	44.92
		S03	0.45	0.05	9.57
S04		0.50	0.00	0.58	

S05	0.20	0.30	59.57
S06	0.50	0.00	0.39
S07	0.15	0.35	69.92
S09	0.50	0.00	0.39
S10	0.23	0.27	54.49

5.8 Código del preprocesado

```

% Parámetros
load("PPG_G_wrist\S02_G_wrist_data.mat")
stage = 'stage5';
sig = 'sig5';
signal = S02_G_wrist_data.(stage).(sig); % Señal PPG wearable
ppgart = []; % Artefactos de la PPG
fsppg = 100; % Frecuencia de muestreo
lpd_fp = 4.8; % Frecuencia de paso del LPDF
lpd_fc = 5; % Frecuencia de corte del LPDF
lpd_order = 3*100; % Orden del filtro
alpha = 0.5; % Coeficiente para actualizar el umbral
refract = 270e-3; % Periodo de refractario (s)
taoRR = 1; % Fracción del intervalo RR para el umbral
fsi_nM = 100; % Frecuencia de muestreo para buscar el punto nM
w_nB = 150e-3; % Longitud de la ventana después de un pico (s)
plotflag = false; % Indicador para graficar resultados

% Filtro Butterworth paso-alto
[bb, aa] = butter(3, 0.03*2/fsppg, 'high');
preproc = filtfilt(bb, aa, signal);

% Filtro Butterworth paso-bajo
[bb, aa] = butter(3, 35*2/fsppg, 'low');
preproc = filtfilt(bb, aa, preproc);

% Detección de pulsos
[nA, nB, nM, sig_filt, peaks_filt, thres] = PPG_delineator_LPDP
(preproc, fsppg, ppgart, lpd_fp, lpd_fc, lpd_order, alpha, refract,
taoRR, w_nB, fsi_nM, plotflag)

```

5.9 Código completo de la rutina 1 para un sujeto

```

clear all; close all;

%% PRV
% Inicialización de variables
frec = zeros(1, 5);
Resp_S09.PRV = cell(1,5);

% Bucle para las distintas etapas
for i = 1:5
    stage = sprintf('stage%d', i);
    sig = sprintf('sig%d', i);
    load("PPG_G_wrist\S09_G_wrist_data.mat"); % CAMBIAR
    signal = S09_G_wrist_data.(stage).(sig); % CAMBIAR

```

```

%% Preprocesado:

% Filtro Butterworth paso-alto
[bb, aa] = butter(3, 0.03*2/100, 'high');
preproc = filtfilt(bb, aa, signal);

% Filtro Butterworth paso-bajo
[bb, aa] = butter(3, 35*2/100, 'low');
preproc = filtfilt(bb, aa, preproc);

%% PPG delineation:
lpd_fp = 4.8;
lpd_fc = 5;
lpd_order = 3*100;
alpha = 0.5;
refract = 270e-3;
taoRR = 1;
w_nB = 150e-3;
fsi_nM = 100;
plotflag = false;
t = 0:1/fsi_nM:(length(signal)-1)/fsi_nM;

[nA, nB, nM, sig_filt, peaks_filt, thres] =
PPG_delineator_LPDPF(preproc, 100, [], lpd_fp, lpd_fc, lpd_order,
alpha, refract, taoRR, w_nB, fsi_nM, plotflag);

ppgart = [];
n_M = nM(~isnan(nM));
evenly_flag = 1;
evenly_fs = 4;
evenly_Tini = n_M(1,1);
evenly_Tend = n_M(1, length(n_M));

%% Generación de PRV:
[ d_prv, d_prv_t, du_prv ] = generate_PRV( ppgart, n_M,
evenly_flag, evenly_fs, evenly_Tini, evenly_Tend );

%% Gráficas:

figure(1);
ax(1) = subplot(3,1,1); hold on;
plot(t, preproc, 'b');
nM = plot(n_M(~isnan(n_M)),
preproc(1+round(n_M(~isnan(n_M))*100)), '+');
legend('x_{PPG}(n)', 'n_M');
title('Señal PPG filtrada');

d_prv = recorte_120(d_prv, 60);
d_prv_t = recorte_120(d_prv_t, 60);
Resp_S09.PRV{1,i} = d_prv'; %GUARDAMOS LOS DATOS

subplot(3,1,2);
hold on;
ax = plot(d_prv_t, d_prv, 'b');
plot(du_prv.t, du_prv.sig, 'm*');
title('Derivación respiratòria PRV');
legend('d {PRV}');
xlabel('Tiempo (s)');
ylabel('Amplitud (s)');

%% FFT y frecuencia dominante

```

```

subplot(3,1,3);
f=4*(0:4095)/4096;
[bb,aa] = butter(3, [0.085,1]*2/4, 'bandpass');
x = filtfilt(bb,aa, d_prv);
aux = abs(fft(detrend(x), 4096));
plot(f, aux);
title('FFT');
xlabel('Frecuencia (Hz) ');
ylabel('Modulo');

indices = find(f>0.085 & f<2);
f2 = f(indices);
aux2 = aux(indices);
[maximo, max_i] = max(aux2);
s = f2(max_i);
frec(i) = s;
end
frec = frec';
display('PRV');
display(frec);

%% PWV
frec = zeros(1, 5); % Vector de 1 fila y 5 columnas
Resp_S09.PWV = cell(1,5);

for i = 1:5
    stage = sprintf('stage%d', i);
    sig = sprintf('sig%d', i);
    load("PPG_G_wrist\S09_G_wrist_data.mat"); % CAMBIAR
    signal = S09_G_wrist_data.(stage).(sig); % CAMBIAR10

    [bb, aa] = butter(3, 0.03*2/100, 'high');
    preproc = filtfilt(bb, aa, signal);

    [bb, aa] = butter(3, 35*2/100, 'low');
    preproc = filtfilt(bb, aa, preproc);

    %% PPG delineation:
    lpd_fp = 4.8;
    lpd_fc = 5;
    lpd_order = 3*100;
    alpha = 0.5;
    refract = 270e-3;
    taoRR = 1;
    w_nB = 150e-3;
    fsi_nM = 100;
    plotflag = false;
    t = 0:1/fsi_nM:(length(signal)-1)/fsi_nM;

    [nA, nB, nM, sig_filt, peaks_filt, thres] =
    PPG_delineator_LPDPF(preproc, 100, [], lpd_fp, lpd_fc, lpd_order,
    alpha, refract, taoRR, w_nB, fsi_nM, plotflag);

    %% Parameters:
    fsdr = 4; %Sampling frequency for the PWV signal
    N = 25; %Number of samples for computing MAD
    C = 3; %Number of STDs to consider a a sample as non-outlier by
MAD

    %% Onset (nO) and end (nE) detection:

```

```

n_A = nA;
tm = incidences(n_A,n_A(1, length(n_A)), 0);
j = 1;
l = min(length(n_A), length(tm));

while j <= l
    if n_A(j) ~= tm(j)
        n_A(j) = [];
        l = l - 1;
    else
        j = j + 1;
    end
end

sigpoint = generar_DR_anchura_PPG_v2_jaime(preproc, [], n_A, 4,
100);
du_pwv.sig = sigpoint(5,:)-sigpoint(4,:);
du_pwv.t = sigpoint(1,:);

%% MAD:
[du_pwv_no_ouliers.sig, du_pwv_no_ouliers.t] =
outlier_correction_mad(du_pwv.sig, du_pwv.t, N, C, 2, false);

%% Spline interpolation:
d_pwv.t = 0:1/4:du_pwv_no_ouliers.t(end);
d_pwv.t = d_pwv.t(d_pwv.t>=du_pwv_no_ouliers.t(1));
d_pwv.sig = spline(du_pwv_no_ouliers.t, du_pwv_no_ouliers.sig,
d_pwv.t);

d_pwv.sig = recorte_120(d_pwv.sig, 60);
d_pwv.t = recorte_120(d_pwv.t, 60);

Resp_S09.PWV{1,i} = d_pwv.sig'; %GUARDAMOS LOS DATOS

%% Figure:
t = 0:1/100:(length(preproc)-1)/100;

figure(2);
ax(1) = subplot(3,1,1); hold on;
plot(t, preproc, 'b');
nA = plot(n_A(~isnan(n_A)),
preproc(1+round(n_A(~isnan(n_A))*100)), 'r*');
nO = plot(sigpoint(4,~isnan(sigpoint(4,:))),
preproc(1+round(sigpoint(4,~isnan(sigpoint(4,:))*100)), 'r^');
nE = plot(sigpoint(5,~isnan(sigpoint(5,:))),
preproc(1+round(sigpoint(5,~isnan(sigpoint(5,:))*100)), 'rv');
legend('x_{PPG}(n)', 'n_A', 'n_O', 'n_E');
title('PPG Signal Filtered');

ax(2) = subplot(3,1,2); hold on;
plot(d_pwv.t, d_pwv.sig, 'b');
% plot(du_pwv.t, du_pwv.sig, 'm*');
% plot(du_pwv_no_ouliers.t, du_pwv_no_ouliers.sig, 'r*');
legend('d_{PWV}');
linkaxes(ax, 'x');

%% FFT, Eabs, Erel

% subplot(3,1,3)
f=4*(0:4095)/4096; % Por debajo de 1 mHz no se puede distinguir

```

```

[bb,aa] = butter(3, [0.085,1]*2/4, 'bandpass');
x = filtfilt(bb,aa,d_pwv.sig);
aux = abs(fft(detrend(x), 4096));
% plot(f, aux);
title('FFT');
xlabel('Frecuencia (Hz) ');
ylabel('Modulo');

indices = find(f>0.085 & f<2);

f2 = f(indices);
aux2 = aux(indices);

[maximo, max_i] = max(aux2);

s = f2(max_i);

frec(i) = s;
end

frec = frec';
display('PWV')
display(frec)

%% PAV
frec = zeros(1, 5); % Vector de 1 fila y 5 columnas
Resp_S09.PAV = cell(1,5);

for i = 1:5
    stage = sprintf('stage%d', i);
    sig = sprintf('sig%d', i);
    load('PPG_G_wrist\S09_G_wrist_data.mat')
    signal = S09_G_wrist_data.(stage).(sig);

    [d_pav, d_pav_t, du_pav, n_A, n_B, nM, sig_filt, peaks_filt,
    thres, ppg, t, sigpoint] = PAV_simplificado(signal);

    d_pav = recorte_120(d_pav, 60);
    d_pav_t = recorte_120(d_pav_t, 60);
    Resp_S09.PAV{1,i} = d_pav';

    figure(3);
    % Primer subplot: Señal PPG filtrada
    subplot(3,1,1);
    hold on;
    plot(t, ppg, 'b');
    fs = 100;
    max_amplitude = plot(n_A, ppg(1+round(n_A(~isnan(n_A))*fs)),
    'r*');
    nB = plot(n_B, sigpoint(2,:), 'r^');
    title('PPG Filtered Signal');
    legend('ppg signal', 'max amplitude','nB');
    xlabel('Tiempo (s)');

    % Segundo subplot: PPG Derived Respiration Signal
    subplot(3,1,2);
    hold on;
    plot(d_pav_t, d_pav, 'b');
    plot(du_pav.t, du_pav.sig, 'm*');

```

```

title('PPG Derived Respiration Signal');
legend('d_{PAV}');
xlabel('Tiempo (s)');
ylabel('Amplitud (V)');;

% Tercer subplot: FFT
subplot(3,1,3);
f = 4 * (0:4095) / 4096;
[bb, aa] = butter(3, [0.085,1]*2/4, 'bandpass');
x = filtfilt(bb, aa, d_pav);
aux = abs(fft(detrend(x), 4096));
plot(f, aux);
title('FFT');
xlabel('Frecuencia (Hz) ');
ylabel('Modulo');

% Ajustar espaciado entre subplots
spacing = 0.05;
position = [0.1, 0.1, 0.8, 0.27]; % [left, bottom, width, height]
set(gca, 'Position', position + [0, -2*spacing, 0, 0]);
set(gca, 'Position', position + [0, -spacing, 0, 0]);

indices = find(f>0.085 & f<2);
f2 = f(indices);
aux2 = aux(indices);

[maximo, max_i] = max(aux2);

s = f2(max_i);

frec(i) = s;
f2 = f(indices);
aux2 = aux(indices);

frec(i) = s;
end

frec = frec';
display('PAV');
display(frec);

save('Resp_S09', "Resp_S09");

```

5.10 Código completo de la rutina 2 para un sujeto

```

clear all; close all;
% Set parameters
fs = 4; % Frecuencia de muestreo de la señal respiratoria
f_lims = [0.15 0.6];
Tm = 12;
peakness_thr_A = 35;
peakness_thr_B = 5;
delta = 0.1;
Nfft=2^12;

load('Resp_S09_2.mat');
signal = Resp_S09_2_2; % Señal respiratoria f > 0.15

```

```

frec = 1:5;
for i=1:5
    signals = cell(1,3);
    signals{1,1} = signal.PAV{1,i}; % {1, etapa}
    signals{1,2} = signal.PRV{1,i}; % {1, etapa}
    signals{1,3} = signal.PWV{1,i}; % {1, etapa}

    [ Orig, Aver, used, peakness, Chi_A, Chi_B ] =
    peakness_welch_one_spectrum( signals, fs, f_lims, Tm, Nfft,
    peakness_thr_A, peakness_thr_B, delta );
    figure(i)
    plot(Aver.f, Aver.S)
    [pico_max, idx] = max(Aver.S);
    f_dominante = Aver.f(idx);
    frec(1,i) = f_dominante;
end
frec= frec';

```