



**ESPE**  
UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

**“Análisis de desempeño de dispositivos wearables comerciales para la estimación de los niveles de estrés causado por estímulos audiovisuales en sujetos sanos”**

Núñez Almeida, Nicolás Esteban

Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica, Automatización y Control

Trabajo de titulación, previo a la obtención del título de Ingeniero en Electrónica,  
Automatización y Control

Ing. Arcentales Viteri, Andrés Ricardo, PhD

30 de julio del 2021



## Document Information

<b>Analyzed document</b>	Tesis_Final_NNunez_Urkund.pdf (D110920200)
<b>Submitted</b>	8/2/2021 1:36:00 AM
<b>Submitted by</b>	Guaman Novillo Ana Veronica
<b>Submitter email</b>	avero.guaman@gmail.com
<b>Similarity</b>	2%
<b>Analysis address</b>	avguaman.espe@analysis.orkund.com

## Sources included in the report

<b>W</b>	URL: <a href="https://repositorio.espe.edu.ec/bitstream/21000/11836/1/T-ESPE-053245.pdf">https://repositorio.espe.edu.ec/bitstream/21000/11836/1/T-ESPE-053245.pdf</a> Fetched: 11/16/2019 7:57:09 AM		1
<b>W</b>	URL: <a href="https://repositorio.espe.edu.ec/bitstream/21000/15069/1/T-ESPE-040295.pdf">https://repositorio.espe.edu.ec/bitstream/21000/15069/1/T-ESPE-040295.pdf</a> Fetched: 12/10/2019 7:34:57 AM		2
<b>SA</b>	<b>Universidad de las Fuerzas Armadas ESPE / Urkund_Tesis_Saa_Dario.docx</b> Document Urkund_Tesis_Saa_Dario.docx (D36006183) Submitted by: ararcentales@espe.edu.ec Receiver: ararcentales.espe@analysis.orkund.com		1
<b>SA</b>	<b>Universidad de las Fuerzas Armadas ESPE / Tesis Final JSArias.pdf</b> Document Tesis Final JSArias.pdf (D45482047) Submitted by: ararcentales@espe.edu.ec Receiver: ararcentales.espe@analysis.orkund.com		1
<b>SA</b>	<b>Universidad de las Fuerzas Armadas ESPE / Tesis_Betancourt Yopez.pdf</b> Document Tesis_Betancourt Yopez.pdf (D40882038) Submitted by: ararcentales@espe.edu.ec Receiver: ararcentales.espe@analysis.orkund.com		1





DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES  
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y CONTROL

### CERTIFICACIÓN

Certifico que el trabajo de titulación, **“Análisis de desempeño de dispositivos wearables comerciales para la estimación de los niveles de estrés causado por estímulos audiovisuales en sujetos sanos”** fue realizado por el señor **Núñez Almeida, Nicolás Esteban** el cual ha sido revisado y analizado en su totalidad por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 30 de julio de 2021



.....

**Ing. Arcentales Viteri, Andrés Ricardo PhD**

C.C. 1712480746



DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES  
CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y CONTROL

### RESPONSABILIDAD DE AUTORÍA

Yo, **Núñez Almeida, Nicolás Esteban**, con cédula de ciudadanía n°100396000-0, declaro que el contenido, ideas y criterios del trabajo de titulación: **"Análisis de desempeño de dispositivos wearables comerciales para la estimación de los niveles de estrés causado por estímulos audiovisuales en sujetos sanos"** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 30 de julio de 2021

**Núñez Almeida, Nicolás Esteban**

C.C.: 100396000-0



**DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES**  
**CARRERA DE INGENIERÍA EN ELECTRÓNICA, AUTOMATIZACIÓN Y CONTROL**

**AUTORIZACIÓN DE PUBLICACIÓN**

Yo **Núñez Almeida, Nicolás Esteban**, con cédula de ciudadanía n° 100396000-0, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **“Análisis de desempeño de dispositivos wearables comerciales para la estimación de los niveles de estrés causado por estímulos audiovisuales en sujetos sanos”** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 30 de julio de 2021

**Núñez Almeida, Nicolás Esteban**

C.C.: 100396000-0

**Dedicatoria**

Este trabajo está dedicado a mis padres y hermanas, que siempre me han apoyado y creído en mí, y sobre todo a mis abuelitos que sé que están conmigo protegiéndome y alentándome en cada paso que doy.

Familia, siempre están en mi corazón y la persona que soy y lo que he logrado y lograré siempre será gracias a ustedes, por ustedes y para ustedes.

## **Agradecimientos**

Agradezco a mis papis y hermanas, por haberme apoyado siempre con muchas sonrisas, abrazos y sobre todo paciencia, que sé que la necesitaron.

Agradezco a mis amigos que me acompañan desde el colegio, gracias por estar en las buenas, en las malas y en las peores.

Agradezco a mis amigos que me trajo esta etapa universitaria, gracias por su compañía, por las amanecidas para terminar los eternos proyectos, y sobre todo por las largas charlas y las risas.

Por último, agradezco a mi director de tesis, Dr. Andrés Arcentales, por su tiempo, dedicación y paciencia para lograr culminar este proyecto exitosamente

## Índice de Contenidos

Resultado de Análisis Urkund .....	2
Certificación .....	3
Responsabilidad de Autoría .....	4
Autorización de publicación.....	5
Dedicatoria.....	6
Agradecimientos .....	7
Índice de Tablas .....	11
Índice de Figuras .....	13
Resumen .....	16
Abstract.....	17
Capítulo I.....	18
Introducción.....	18
Antecedentes .....	18
Justificación e Importancia .....	20
Alcance del proyecto.....	21
Objetivos .....	23
Objetivo general.....	23
Objetivos específicos.....	23
Capítulo II.....	25
Estado Del Arte .....	25
Introducción .....	25
Respuesta fisiológica frente a estímulos audiovisuales.....	25
Cambios en el sistema cardiorrespiratorio .....	26
Otros cambios fisiológicos de interés .....	28
Sistemas multimodales para el análisis de emociones .....	31
Métodos de inducción de emociones.....	35
Dispositivos wearables para el registro de señales fisiológicas.....	37
Dispositivos estándar para adquisición de señales fisiológicas .....	38
Dispositivos wearables y sus aplicaciones .....	45
Dispositivos wearables en estudios de emociones.....	47
Capítulo III.....	52
Plataforma Multisensado Para La Adquisición De Señales Fisiológicas.....	52

Introducción .....	52
Plataforma MySignals .....	53
Sensores externos .....	57
Módulo de flujo respiratorio (FLW).....	57
Módulo de fotopletimografía (PPG) .....	60
Módulo para electrooculografía (EOG) .....	62
Módulo de respuesta galvánica de la piel (GSR) .....	64
Plataforma implementada para la adquisición de bioseñales .....	66
Dispositivos Wearable.....	68
Dispositivos Polar .....	68
Garmin VivoSmart 4 .....	77
Software de integración.....	79
Programa para la adquisición de señales.....	79
Interfaz gráfica para la adquisición de señales .....	81
Capítulo IV.....	87
Adquisición Y Procesamiento De Las Señales .....	87
Introducción .....	87
Estructura y registro de las señales.....	87
Procesamiento digital de las señales fisiológicas.....	89
Procesamiento de la señal ECG .....	90
Procesamiento de la señal PPG .....	92
Procesamiento de la señal FLW .....	95
Procesamiento de la señal EOG .....	97
Procesamiento de la señal GSR.....	99
Procesamiento de la señal de Temperatura .....	100
Capítulo V.....	102
Análisis De Resultados .....	102
Introducción .....	102
Análisis comparativo de dispositivos .....	102
Polar H10-ECG .....	102
Polar OH1-PPG .....	108
VivoSmart- BPMs.....	112
Algoritmo de clasificación supervisada .....	113

Modelo de clasificación I.....	115
Modelo de clasificación II.....	117
Capítulo VI.....	121
Conclusiones Y Recomendaciones.....	121
Plataforma multisensado .....	121
Generación de la base de datos y procesamiento de las señales.....	123
Estimación de los niveles de estrés.....	125
Desempeño de los dispositivos wearables .....	128
Referencias.....	134

## Índice de Tablas

Tabla 1. <i>Principales métodos de inducción de emociones</i> .....	35
Tabla 2. <i>Comparación de los tipos de electrodos</i> .....	39
Tabla 3. <i>Especificaciones técnicas, dispositivo Polar H10</i> .....	69
Tabla 4. <i>Servicio PMD para la comunicación BLE con los dispositivos Polar</i> .....	72
Tabla 5. <i>Valores a escribir en el PMD CP</i> .....	72
Tabla 6. <i>Características temporales y frecuenciales señal ECG</i> .....	92
Tabla 7. <i>Características temporales y frecuenciales señal PPG</i> .....	95
Tabla 8. <i>Características temporales y frecuenciales señal FLW</i> .....	97
Tabla 9. <i>Características temporales y frecuenciales señal EOG</i> .....	99
Tabla 10. <i>Características temporales y frecuenciales señal GSR</i> .....	100
Tabla 11. <i>Índices de similitud temporal / frecuencial PolarH10 - ECG</i> .....	106
Tabla 12. <i>Índices de similitud temporal / frecuencial tacograma extraído del PolarH10 - ECG</i> ..	107
Tabla 13. <i>Índices de similitud temporal / frecuencial Polar OH1 - PPG</i> .....	109
Tabla 14. <i>Índices de similitud temporal / frecuencial SST extraído del PolarOH1 - PPG</i> .....	110
Tabla 15. <i>Comparativa BPMs estimados en una Ventana 30 s, VivoSmart – Plataforma Multisensado</i> .....	112
Tabla 16. <i>Comparativa BPMs estimados entre intervalos R-R sucesivos, VivoSmart – Plataforma Multisensado</i> .....	113
Tabla 17. <i>Clasificadores Basal-Estrés, todas las características</i> .....	116
Tabla 18. <i>Clasificadores Relajado-Estrés, todas las características</i> .....	116
Tabla 19. <i>Selección de característica Basal-Estrés</i> .....	117
Tabla 20. <i>Selección de características Relajado-Estrés</i> .....	118
Tabla 21. <i>Características más relevantes seleccionadas por estímulo</i> .....	118

Tabla 22. *Clasificadores Basal-Estrés generados con características seleccionadas* ..... 119

Tabla 23. *Clasificadores Relajado-Estrés con características seleccionadas* ..... 120

## Índice de Figuras

Figura 1 <i>Clasificación de los dispositivos wearables</i> .....	37
Figura 2. <i>Dispositivo Holter</i> .....	38
Figura 3. <i>Camiseta CardioSense</i> .....	41
Figura 4. <i>Ejemplos de wearables con medición PPG</i> .....	43
Figura 5. <i>Electroencefalograma convencional vs banda EEG comercial</i> .....	44
Figura 6. <i>Detección de estrés mental mediante wearables</i> .....	48
Figura 7. <i>Esquema de conexión para el registro de señales</i> .....	53
Figura 8. <i>Modelos de la plataforma MySignals</i> .....	54
Figura 9. <i>Hardware, plataforma MySignalsHW</i> .....	54
Figura 10 <i>Diagrama esquemático de la plataforma MySignalsHW</i> .....	55
Figura 11. <i>Diagrama de bloques sensores de la plataforma MySignalsHW.</i> .....	56
Figura 12. <i>Diagrama de bloques del módulo FLW</i> .....	57
Figura 13. <i>Circuito implementado para el módulo FLW</i> .....	60
Figura 14. <i>Diagrama de bloques del módulo PPG</i> .....	60
Figura 15. <i>Circuito implementado para el módulo PPG</i> .....	62
Figura 16. <i>Diagrama de bloques del módulo EOG</i> .....	62
Figura 17. <i>Posición de los electrodos para EOG</i> .....	63
Figura 18. <i>Circuito implementado para el módulo EOG</i> .....	64
Figura 19. <i>Diagrama de bloques del módulo GSR externo</i> .....	65
Figura 20. <i>Circuito de acondicionamiento del módulo de GSR externo</i> .....	66
Figura 21. <i>Plataforma multisensado completa</i> .....	67
Figura 22. <i>Circuito de alimentación implementado</i> .....	67
Figura 23. <i>Partes del dispositivo Polar H10.</i> .....	68

Figura 24. <i>Dispositivo Polar OH1</i> .....	69
Figura 25. <i>Perfil, Servicio y Característica en una comunicación BLE.</i> .....	70
Figura 26. <i>Diagrama de flujo para la adquisición continua de los dispositivos Polar.</i> .....	72
Figura 27. <i>Paquete enviado por dispositivos Polar</i> .....	73
Figura 28. <i>Señal ECG obtenida del dispositivo Polar H10</i> .....	74
Figura 29. <i>Subdivisión paquete enviado por dispositivos Polar OH1</i> .....	75
Figura 30. <i>Señal PPG original obtenida del dispositivo Polar OH1</i> .....	75
Figura 31. <i>Señal PPG sin procesar y filtrada del dispositivo Polar OH1</i> .....	76
Figura 32. <i>Señal ECG y PPG obtenidas de los dispositivos Polar</i> .....	77
Figura 33. <i>Dispositivo Garmin VivoSmart4</i> .....	78
Figura 34. <i>Diagrama de flujo programa Arduino Nano</i> .....	80
Figura 35. <i>Interfaz de usuario</i> .....	82
Figura 36. <i>Ventana principal de la interfaz</i> .....	83
Figura 37. <i>Ventana secundaria de la interfaz</i> .....	83
Figura 38. <i>Visualización señales PolarH10</i> .....	84
Figura 39. <i>Visualización señales de plataforma multisensado</i> .....	85
Figura 40. <i>Mensajes emergentes de la interfaz</i> .....	86
Figura 41. <i>Procedimiento para el registro de señales fisiológicas</i> .....	88
Figura 42. <i>Organización de la base de datos</i> .....	89
Figura 43. <i>Tramos temporales para la extracción de características</i> .....	90
Figura 44. <i>Diagrama de bloques del procesamiento de la señal ECG</i> .....	90
Figura 45. <i>Señal ECG original y preprocesada, MySignals</i> .....	91
Figura 46. <i>Señal ECG original y preprocesada, Polar H10</i> .....	91
Figura 47. <i>Diagrama de bloques del procesamiento de la señal PPG</i> .....	93

Figura 48. Señal PPG original y preprocesada, NewSensor.....	94
Figura 49. Señal PPG original y preprocesada, PolarOH1 .....	94
Figura 50. Diagrama de bloques del procesamiento de la señal FLW .....	95
Figura 51. Señal FLW original y preprocesada, NewSensor .....	96
Figura 52. Diagrama de bloques del procesamiento de la señal EOG .....	97
Figura 53. Señal EOGV original y preprocesada, NewSensor.....	98
Figura 54. Señal GSR original y preprocesada, NewSensor.....	99
Figura 55. Señal original y preprocesada de temperatura corporal, MySignals.....	101
Figura 56. Diagrama de bloques, análisis comparativo ECG MySignals – ECG PolarH10.....	103
Figura 57. Escala de correlación sugerida para los coeficientes $\rho$ , RCC y MSC.....	105
Figura 58. Comparación temporal / frecuencial PolarH10 - ECG .....	105
Figura 59. Comparación temporal / frecuencial tacograma extraído del PolarH10 - ECG .....	107
Figura 60. Comparación temporal / frecuencial PolarOH1 - PPG .....	109
Figura 61. Comparación temporal / frecuencial de la señal SST extraída del PolarOH1 – PPG...	110
Figura 62. Efecto del movimiento en la señal PPG del PolarOH1.....	111

## Resumen

Todos estamos constantemente expuestos a estímulos que generan variados niveles de estrés sin ser conscientes que, a corto o mediano plazo, este puede causar deterioro en la salud física y mental, haciendo esencial un monitoreo continuo de los niveles de ansiedad. En este aspecto, los wearables resultan una opción interesante para investigaciones ambulatorias, sin embargo, su uso ha sido relegado a ámbitos cotidianos, debido a los escasos estudios que validen la calidad de las señales obtenidas. Por tanto, el presente proyecto busca analizar el desempeño de tres wearables comerciales (la banda PolarH10, la pulsera PolarOH1 y el reloj inteligente Garmin VivoSmart4) para la estimación de estrés causado por estímulos audiovisuales en sujetos sanos, y determinar su aplicabilidad en este campo.

Dentro de la investigación, se detalla el hardware y software utilizado para el registro de señales fisiológicas de interés, el procesamiento digital aplicado a las señales registradas, y el diseño de clasificadores basados en algoritmos supervisados para la estimación de los niveles de estrés.

Entre los resultados de la investigación se tiene que el dispositivo PolarH10 es aplicable para estudios de estrés al lograrse un clasificador con una exactitud del 81.3% para la estimación de Relajado-Estrés y una correlación temporal y frecuencial fuerte del tacograma extraído ( $\rho=0,889$ ,  $MSC=0,889$ ). En cuanto al PolarOH1, se observa una fuerte correlación temporal ( $\rho=0,892$ ) pero un desempeño regular para la generación de clasificadores ( $Acc<70\%$ ) debido a la distorsión de la señal original por artefactos de movimiento. Por último, el VivoSmart4 no es recomendable para ámbitos investigativos al no proporcionar información significativa para el diseño de sistemas propios para la estimación de estrés

### **PALABRAS CLAVE:**

- **WEARABLES**
- **ESTÍMULOS AUDIOVISUALES**
- **ESTRÉS**

## **Abstract**

We are all constantly exposed to stimuli that generate various levels of stress without being aware that, in the short or medium term, this can cause deterioration in physical and mental health, making continuous monitoring of anxiety levels essential. In this aspect, wearables are an interesting option for ambulatory research, however, their use has been relegated to everyday environments, due to the few studies that validate the quality of the signals obtained. Therefore, the present project seeks to analyze the performance of three commercial wearables (the PolarH10 band, the PolarOH1 bracelet and the Garmin VivoSmart4 smartwatch) for the estimation of stress caused by audiovisual stimuli in healthy subjects, and to determine their applicability in this field.

Within the research, the hardware and software used for the recording of physiological signals of interest, the digital processing applied to the recorded signals, and the design of classifiers based on supervised algorithms for the estimation of stress levels are detailed.

Among the results of the research is that the PolarH10 device is applicable for stress studies by achieving a classifier with an accuracy of 81.3% for Relax-Stress stimulation and a strong temporal and frequency correlation of the extracted tachogram ( $\rho=0.889$ ,  $MSC=0.889$ ). As for PolarOH1, a strong temporal correlation is observed ( $\rho=0.892$ ) but a regular performance for classifier generation ( $Acc<70\%$ ) due to the distortion of the original signal by motion artifacts. Finally, the VivoSmart4 is not recommended for research settings as it does not provide significant information for the design of proprietary systems for stress estimation.

### **PALABRAS CLAVE:**

- **WEARABLES**
- **AUDIOVISUAL STIMULI**
- **STRESS**

## Capítulo I

### Introducción

#### Antecedentes

Los wearables, son aquellos dispositivos electrónicos que se llevan “puestos”, y como explica (Torrado, 2018) y (Billinghurst & Starner, 1999), pueden tomar diversas formas como prendas de ropa, accesorios y dispositivos inteligentes acoplados a las extremidades, tronco o cabeza de la persona. La tecnología wearable, presenta como característica principal, su capacidad para adquirir señales fisiológicas y transmitirlos inalámbricamente, permitiéndole al usuario acceder a dicha información en tiempo real (Seneviratne et al., 2017) (Luque Ordóñez, 2016).

En los últimos años se ha generado una masificación de wearables de muñeca, sobre todo, porque permiten al usuario medir una serie de aspectos fisiológicos como el ritmo cardíaco, saturación de oxígeno, número de pasos, calorías quemadas, etc. Este boom ha llevado a emplear los wearables tanto en aplicaciones cotidianas, como en aplicación enfocadas en deportistas de alto rendimiento. Sin embargo, para uso médico, siguen sin ser el estándar preferente de los investigadores, debido principalmente a la carencia de estudios y certificaciones que los validen.

Dentro de las investigaciones realizadas, hay dos principales categorías a distinguir: investigaciones enfocadas en validar los dispositivos para un uso cotidiano, e investigaciones enfocadas en aplicación médicas, entrando dentro de este campo sobre todos, aquellos estudios centrados en la respuesta fisiológica del estrés en sujetos sanos.

Para validaciones de uso cotidiano, estudios como los realizados por (Pardamean et al., 2019), (Wang et al., 2017) y (Parak & Korhonen, 2014), proponen analizar el desempeño de múltiples wearables principalmente mediante la correlación estadística temporal de las señales adquiridas respecto a un electrocardiograma (ECG) seleccionado como dispositivo patrón. De estas

investigaciones, se concluyó principalmente que el desempeño de los dispositivos disminuye con el incremento de la actividad cardiorrespiratoria relacionada con el ejercicio. Sin embargo, los índices de correlación encontrados son inconclusos variando entre el 76.29% y el 99%, siendo este último, alcanzado por el dispositivo Polar H7 (Polar, s. f.-a).

En cuanto a trabajos enfocadas en ámbitos clínicos, investigaciones como la de (Al-Kaisey et al., 2020), no recomiendan el uso de dispositivos de muñeca como reemplazo de los monitores Holter para el control de la frecuencia cardíaca en pacientes con fibrilación auricular. A pesar de ello, para monitorización del sueño (Parak et al., 2015), de sujetos en condiciones de descanso (Giles et al., 2016) y respiración controlada (Plews et al., 2017), el uso de wearables ha demostrado ser factible.

Enfocándose ahora en estudios clínicos centrados en el uso de wearables para análisis de la respuesta fisiológica del estrés en sujetos sanos, se debe destacar entre las escasas investigaciones realizadas hasta la fecha, el trabajo desarrollado por (Ollander et al., 2017). Dentro de esta investigación, se realizó una comparación de las señales adquiridas por el dispositivo de muñeca Empatica E4 (Empatica, s. f.) respecto a sensores estacionarios tradicionales, mientras sujetos sanos realizaban actividades consideradas como estresantes cognitivamente. Concluyéndose, al igual que en los trabajos de (Menghini et al., 2019), (Hernando et al., 2017) y (Hernando et al., 2018), que a pesar de que las señales obtenidas por los wearables presentaban considerables pérdidas de intervalos entre latidos, se puede lograr un buen índice de discriminación de estrés al aplicarse un análisis de sus componentes espectrales.

Basándose en estas investigaciones, el presente proyecto busca analizar el desempeño de wearables comerciales para la estimación de los niveles de estrés causado por estímulos audiovisuales en sujetos sanos, y finalmente determinar la aplicabilidad de ellos en este campo poco estudiado.

## **Justificación e Importancia**

Todos estamos constantemente expuestos a estímulos que generan variados niveles de estrés (Berrío García & Mazo Zea, 2011), sin ser conscientes que, a corto o mediano plazo, este puede causar deterioro en la salud física y mental (McEwen & Sapolsky, 2006). Por estos motivos, como explica (Jadoun et al., 2012), es fundamental mantener los niveles de ansiedad controlados. Dentro de esta problemática, se han desarrollado una serie de metodologías enfocadas en reducir los niveles de ansiedad. Entre los métodos más prometedores, se tiene el emplear estímulos auditivos y audiovisuales, demostrándose que tanto sujetos sanos como sujetos en espera de procedimientos médicos, reducen sus niveles de ansiedad, sustituyéndose el uso de sedantes o medicamentos (Bradt et al., 2013) (Koelsch & Jancke, 2015).

Para analizar el verdadero impacto de los diferentes estímulos auditivos y audiovisuales, se han desarrollado una serie de investigaciones, empleando sobre todo electrocardiógrafos para la adquisición de señales fisiológicas. Sin embargo, esta metodología se torna inviable fuera del ambiente de laboratorio, al no permitir un seguimiento en situaciones cotidianas e incluso dentro del propio ambiente de experimentación, es intrusiva y poco amigable para el sujeto de prueba.

Actualmente, la tecnología wearable, está alcanzando su era dorada (Pardamean et al., 2019), empleando desde fotopletismografía (PPG), para detectar la variabilidad del flujo sanguíneo en función de la absorción de luz (Angulo Fuato, 2010), hasta electrocardiografía (ECG), para medir la actividad eléctrica cardíaca. Los wearables como explica (Ollander et al., 2017) presentan la gran ventaja de proveer un monitoreo continuo del usuario, siendo una opción interesante para investigaciones en situaciones reales. A pesar de ello, su uso ha sido limitado principalmente a aplicaciones cotidianas o incluso para dar seguimiento a deportistas de alto rendimiento, siendo relegado de investigaciones y análisis fisiológicos, debido principalmente a los escasos estudios que validen la calidad de las señales obtenidas.

Por este motivo, el presente proyecto busca analizar el desempeño de una serie de wearables comerciales aplicándolos a estudios que relacionen señales fisiológicas con estímulos audiovisuales. Además, el proyecto servirá de soporte para futuras investigaciones enfocados en el análisis de señales fisiológicas y en la aplicación de wearables para ámbitos clínicos.

El presente trabajo de investigación será desarrollado como parte del proyecto de investigación “Integración de Nuevas Tecnologías para el Diseño de Soluciones Cognitivas en Ambientes de Vida Asistida para Adultos Mayores: Evaluación de Áreas de Atención y Memoria, CERPA-XIV-2020-07” financiado por la Corporación Ecuatoriana Para El Desarrollo De La Investigación Y La Academia CEDIA y la Universidad de las Fuerzas Armadas ESPE.

### **Alcance del proyecto**

En el presente proyecto, se propone el análisis de desempeño de dispositivos wearables comerciales para la evaluación de estrés causado por estímulos audiovisuales en sujetos sanos. Para ello, se seleccionarán diferentes wearables presentes en el mercado que permitan la obtención de señales fisiológicas como electrocardiograma y fotopletismografía, se obtendrán las señales crudas de los dispositivos, y se verificará su desempeño aplicando a sujetos sanos a diferentes estímulos audiovisuales para finalmente comparar la respuesta obtenida con dispositivos estándar.

Como primera etapa del proyecto se desarrollará el estado del arte, centrando la búsqueda en los dispositivos y aplicaciones comerciales disponibles, y sobre todo en estudios que validen su desempeño.

A continuación, se realizará la adaptación de los dispositivos de sensado de variables fisiológicas que actuarán como patrones en la detección de estrés y de los dispositivos wearables. Como dispositivo de sensado estándar, se empleará la plataforma multisensado MySignals, por lo que se requiere en primer lugar ponerla en funcionamiento, y posteriormente realizar

adaptaciones de software y hardware para adquirir únicamente las señales de interés para el proyecto. Las señales consideradas serán las descritas en el trabajo de (Betancourt Mediavilla & Yépez Narváez, 2018). En cuanto a los dispositivos wearables, se desarrollará el software necesario para obtener las señales crudas de los dispositivos Polar H10 y Polar OH1, y se obtendrán los datos ya procesados del dispositivo Garmin Vivosmart4. Adicionalmente, se realizarán medidas fisiológicas con aplicaciones comerciales de celular que permitan detectar el nivel de estrés en el usuario.

Posteriormente, se generará una base de datos de señales fisiológicas de sujetos sanos sometidos a estímulos audiovisuales de estrés. Dentro de este punto, se desarrollará una plataforma que permita la sincronización de las señales adquiridas por todos los dispositivos de forma simultánea, se someterá a sujetos de prueba a diferentes estímulos audiovisuales que generen variados niveles de estrés y finalmente, se almacenarán los datos obtenidos para su posterior análisis. Se debe aclarar que, debido a la pandemia que se vive actualmente, las señales fisiológicas serán adquiridas con los familiares cercanos al autor del presente trabajo de investigación y familiares del personal participante del proyecto CERPA-XIV-2020-07. En este último aspecto, si bien la adquisición no será realizada directamente por el autor, los participantes presentan conocimiento de la temática y de la tecnología a emplearse, por lo que se llevará un control del procedimiento a seguir únicamente de forma telemática. Además, el sistema será adaptado enfocándose en la facilidad de uso, y será completamente desinfectado antes de ser entregado a la siguiente persona. Finalmente, el protocolo de pruebas y los estímulos audiovisuales, estarán basados en las investigaciones realizadas por (Raza Raza, 2016) y (Betancourt Mediavilla & Yépez Narváez, 2018). Debido a que se prevé un reducido número de sujetos de prueba, se tomarán varias mediciones a cada uno de ellos, en el transcurso del desarrollo del trabajo de investigación.

La cuarta etapa del proyecto, se centrará en el análisis de las señales fisiológicas de los dispositivos seleccionados como patrones y de los dispositivos wearables comerciales. Aquí, se realizará un análisis a profundidad de las señales fisiológicas obtenidas por todos los dispositivos, extrayéndose finalmente sus principales características temporales y frecuenciales. Adicional a esto, se realizará una comparativa de las señales obtenidas con el dispositivo patrón y los dispositivos comerciales

Finalmente, se realizará la caracterización y clasificación de las señales fisiológicas. Se aplicarán algoritmos supervisados de clasificación para la estimación de los niveles de estrés a partir de las características extraídas de las señales registradas en la base de datos. Al final, se realizará una comparativa de los niveles de estrés obtenidos en los clasificadores implementados respecto a los calculados por el dispositivo Vivosmart 4 y la app de celular.

## **Objetivos**

### ***Objetivo general***

Analizar el desempeño de diferentes dispositivos wearables comerciales orientados al sensado de variables fisiológicas para la estimación de los niveles de estrés causado por estímulos audiovisuales en sujetos sanos.

### ***Objetivos específicos***

- Desarrollar el estado del arte sobre los dispositivos wearables de adquisición de variables fisiológicas para la detección de estrés.
- Adaptar el hardware y software de los dispositivos estándar de sensado de variables fisiológicas para la estimación de los niveles de estrés.
- Adaptar los diferentes dispositivos wearables comerciales para la adquisición de señales biomédicas para la estimación de los niveles de estrés.

- Generar una base de datos de señales fisiológicas de sujetos sanos sometidos a estímulos audiovisuales de estrés en base a las señales obtenidas con equipos estándar de medición y dispositivos wearables.
- Realizar un análisis comparativo entre las señales fisiológicas registradas con los dispositivos estándar y los dispositivos wearables comerciales.
- Caracterizar la respuesta temporal y frecuencial de las señales fisiológicas adquiridas para la estimación de los niveles de estrés a partir de la base de datos generada con sujetos sanos.

## Capítulo II

### Estado Del Arte

#### Introducción

El presente proyecto de investigación, propone analizar el desempeño de una serie de wearables comerciales aplicándolos a estudios que relacionen señales fisiológicas con estímulos audiovisuales, por lo tanto, resulta imperativo en primer lugar la revisión del estado del arte de esta temática.

En este capítulo se realiza una revisión del estado del arte sobre investigaciones que analizan la respuesta fisiológica del cuerpo humano ante factores internos o externos (conocidos como estresores). A su vez, se realiza un análisis de los diferentes métodos de estimulación presentes en la literatura para inducción de emociones. Finalmente, se realiza un estudio de los principales dispositivos wearables utilizados como reemplazo a los sistemas estándar para el registro de señales fisiológicas, siendo nuestro enfoque principal en los dispositivos empleados en el análisis de emociones.

#### Respuesta fisiológica frente a estímulos audiovisuales

Cuando se percibe un estímulo potencialmente amenazante, una cascada de efectos fisiológicos toman lugar, movilizando el cuerpo y principalmente el sistema nervioso para enfrentar o huir de la situación (Giorgos Giannakakis, Grigoriadis, et al., 2019). A este proceso cognitivo y fisiológico se lo conoce como respuesta ante estrés, y permite asegurar una adaptación efectiva al agente causante de dicho estímulo más conocido como estresor (Setz et al., 2010), y permite mantener el balance y regulación de las funciones corporales como temperatura, actividad cardíaca, presión sanguínea, respiración, entre otros.

De forma general, los estresores audiovisuales son primero procesados por el tálamo y posteriormente analizados en profundidad por la amígdala y el córtex prefrontal, generando una

respuesta del sistema nervioso activando tanto regiones del hipotálamo y glándula pituitaria como al Sistema Nervioso Autónomo (SNA). El SNA, como explica (Fernández Megías, 2012), está formado por dos ramas, simpática y parasimpática, que inervan conjuntamente la mayoría de órganos internos, especialmente el sistema cardiovascular, respiratorio y gastrointestinal, y cumplen roles antagónicos en respuesta al tipo de estímulo propiciado. Por un lado, la mayor activación de la rama simpática está asociada a emociones negativas generando respuestas rápidas de ataque, mientras que la mayor activación de la rama parasimpática, se asocia a emociones positivas teniendo un papel relajante y de restauración del organismo.

Todos estos cambios, tienen efecto sobre una serie de sistemas, por tanto, la evaluación integral de medidas cardiovasculares, electrodérmicas, respiratorias, entre otros, proveen información esencial del funcionamiento del organismo ante estímulos (Kreibig, 2010).

### ***Cambios en el sistema cardiorrespiratorio***

Como se explicó anteriormente, en respuesta a un estresor, el SNA activa en mayor medida su rama simpática o parasimpática dependiendo del tipo de emoción generada. Esta desestabilización provoca cambios a nivel cardíaco y a nivel respiratorio como la reducción de la variabilidad de ritmo cardíaco (HRV), incremento de dispersión del complejo QT, cambios en la presión sistólica y diastólica, cambios en el ritmo respiratorio, volumen tidal, variabilidad respiratoria se encontraron como respuesta ante estresores (Rizwan et al., 2019) (Kreibig, 2010)

En este contexto, estudios como el de (Rizwan et al., 2019) emplean la señal cardíaca para el diseño de un sistema de detección de estrés basado en máquinas de vectores de soporte (Support Vector Machine, SVM), siendo usada esta señal debido a su facilidad de adquisición y técnicas validadas para la extracción de características. Otra ventaja de la señal ECG radica en que información del flujo respiratorio puede obtenerse indirectamente mediante la técnica denominada EDR, siglas en inglés para respiración derivada del ECG, siendo esta información de

importancia en estudios de estrés. Para la implementación del sistema, se empleó las señales disponibles en la base de datos sobre estrés generado en conductores en tráfico pesado “drivedb” de Physionet (Goldberger et al., 2000) para el entrenamiento y validación del algoritmo de clasificación supervisada, generándose una serie de modelos variando el número de características y tipo de Kernel del SVM. Al final, se obtuvo una exactitud del 98.6% con una función de Kernel Gaussiano y todas las características extraídas. De esta manera, se observó la importancia de la información respiratoria (extraída en este caso de la señal EDR) en sistemas para la detección de estrés.

Otras investigaciones, como la de (Meijer & Morssink, 2020), realizaron la adquisición de la señal respiratoria y ECG mediante sensores independientes, con el fin de generar clasificadores basados en árboles de decisión con empaquetado. Esta investigación empleó dos bases de datos para el entrenamiento y validación del sistema generado, siendo éstas la descrita por (Varon et al., 2019) y por (Goldberger et al., 2000) respectivamente, obteniéndose finalmente un sistema con una exactitud media del 73% entrenado con características seleccionadas mediante el algoritmo de Mínima Redundancia, Máxima Relevancia (Minimum Redundancy Maximum Relevance, MRMR). Se debe destacar de esta investigación el hecho de que, de las seis características empleadas, cuatro de ellas corresponden a la señal respiratoria, siendo crucial discriminar entre una respuesta ante estrés de una conversación por parte del sujeto.

Por otro lado, existen investigaciones que emplean o bien la señal cardiaca o la señal respiratoria en sus estudios. Para la señal respiratoria, se destaca el trabajo de (Machado Fernández & Anishchenko, 2018), el cual emplea un bioradar para la adquisición de la señal respiratoria, un ejercicio matemático como estímulo de estrés mental y un modelo de perceptrón multicapa como clasificador; obteniéndose una precisión del 94.4%, y destacándose el uso de un dispositivo no invasivo. En cuanto a la señal cardiaca, se tiene como referencia el trabajo de

(Giorgos Giannakakis, Trivizakis, et al., 2019), en el cual se alcanza una exactitud media del 89.8% y máxima del 99.1% mediante arquitecturas de aprendizaje profundo. En este estudio, la estimulación se realizó en una serie de fases, destacándose el uso de videos relajantes o de presión psicológica como estímulos audiovisuales.

### ***Otros cambios fisiológicos de interés***

Aparte de los cambios descritos para el sistema cardiorrespiratorio, existen otras medidas fisiológicas que se pueden considerar para describir o identificar de forma objetiva la respuesta emocional de un sujeto ante un estímulo, como son: medidas por observación, medidas electromiográficas, medidas por electroencefalograma, medidas por neuroimagen y medidas de la actividad electrodérmica (EDA).

Dentro de las medidas por observación, se tienen los cambios en la postura corporal, la voz y la expresión facial, destacándose esta última debido al desarrollo que ha tenido la visión por computador en los últimos años, permitiendo incluso la estimación del ritmo cardíaco en función de los cambios de la tonalidad de la piel. En este campo, se han realizado una serie de investigaciones, enfocadas tanto en la cuantificación de los cambios faciales (G. Giannakakis et al., 2017), como en el reconocimiento de emociones (Busso et al., 2004), reconociéndose lo prometedor de estas técnicas y la factibilidad para desarrollar sistemas en tiempo real que permitan monitorizar de forma continua en aplicaciones clínicas y de investigación. Específicamente en el estudio de (G. Giannakakis et al., 2017), se aplicaron una serie de estresores internos y externos, incluyendo estímulos audiovisuales mientras se grababa la reacción del sujeto de prueba. Los resultados indican que características faciales específicas involuntarias y semi-voluntarias derivadas de la actividad ocular tales como número de parpadeos y apertura de ojos, actividad bucal, movimientos de cabeza y ritmo cardíaco son indicadores objetivos de estrés y ansiedad. En el estudio se obtuvieron diferentes modelos de clasificadores con una exactitud que

varía en promedio entre un 80% y 90% de exactitud dependiendo del estímulo aplicado y del algoritmo seleccionado, K vecinos cercanos KNN, índice generalizado de probabilidad, Naive Bayes, AdaBoost o SVM.

Si bien, las medidas por observación resultan no invasivas y generalmente describen eventos inconscientes, como aclara (Fernández Megías, 2012), estas medidas podrían llegar a ser afectadas por la voluntad del sujeto de prueba, como se observa en la investigación de (Busso et al., 2004), que toma como referencia grabaciones de una actriz para el entrenamiento y validación de su modelo. Este motivo hace deseable buscar otras medidas objetivas como son las medidas electromiográficas enfocadas en las respuestas por sobresalto que generan tensión de músculos específicos, así como parpadeos involuntarios, y cambios en músculos faciales asociados al fruncimiento del ceño (relacionado a emociones de enojo o desaprobación) o la elevación de la comisura de los labios. En el contexto de músculos faciales, en la investigación de (Dimberg, 1990), se aplicaron estímulos visuales y auditivos por separado a diferentes sujetos de prueba, obteniéndose las señales EMG de los músculos cigomático y corrugador, demostrándose al final que la electromiografía facial (fEMG) supone una herramienta sensible a la medición de cambios emocionales. En contraste con las mediciones por observación, la fEMG presenta una mejor resolución espacial y es sensible a microexpresiones, con la clara desventaja que su aplicación requiere elevado conocimiento técnico y anatómico para la adecuada adquisición de las señales. Por ello, otros estudios como el de (Wijsman et al., 2013) emplean señales EMG obtenidas del trapecio superior para generar características temporales y frecuenciales relacionadas al estrés mental. Debido a su enfoque en un ambiente de oficina, los estímulos aplicados incluyeron una prueba de cálculo, resolución de un rompecabezas lógico y prueba de memoria, teniéndose como resultado cambios significativos de amplitud de la señal durante

eventos estresantes y demostrándose la oportunidad de la inclusión de este tipo de medidas en sistemas ambulatorios para monitoreo de estrés

En cuanto a las medidas por electroencefalograma, se analiza los cambios eléctricos cerebrales y regiones con mayor actividad. Estos estudios debido a su complejidad, se enfocan principalmente en el reconocimiento de emociones y no solamente en la respuesta fisiológica general ante estímulos. En este campo, se pueden observar investigaciones como la de (Keelawat et al., 2019), en la cual se pretenden generar modelos de redes convolucionales para reconocer diferentes emociones ante estímulos auditivos. Esta investigación emplea un total de 12 electrodos colocados simétricamente en una gorra de tela para adquirir las señales eléctricas cerebrales y entrenar modelos de clasificación basados en redes convolucionales (CNN) y SVM para la clasificación de cuatro diferentes grupos de emociones. Al final del estudio, se obtuvieron conclusiones comparativas entre los modelos generados, obteniéndose que el uso de CNN tiene un mejor rendimiento que el de un modelo basado en SVM, sobre todo si se emplea “Leave-One Out Cross Validation”, debido probablemente a la capacidad de las CNN de obtener información espacio-temporal y por tanto de generalizarse para un mayor número de participantes.

Por otra parte, para estudio del cerebro, se emplean medidas por neuroimagen como la resonancia magnética nuclear, tomografía por emisión de positrones (PET) y resonancia magnética funcional (fMRI), destacándose que este tipo de estudios son extremadamente complejos e inviables fuera del ambiente clínico y científico. Como ejemplo de este campo, se tiene el trabajo de (Phan et al., 2002), en el cual se realiza un meta-análisis sobre las zonas cerebrales activadas en función del tipo de estímulo aplicado y de la emoción generada mediante la recopilación de un total de 55 exámenes PET y fMRI en sujetos sanos. En este estudio, se dividió el cerebro en 20 regiones no superpuestas y se caracterizó cada región por su capacidad de respuesta a las emociones positiva, negativa, felicidad, miedo, ira tristeza y asco; respecto a los

diferentes métodos de inducción visual, auditivo, recuerdos/imaginación. Entre los resultados encontrados, se tiene que el córtex prefrontal tiene un rol mayor en el procesamiento de emociones, el miedo activa específicamente la región de la amígdala, la inducción por estímulos visuales activa la región del córtex occipital y de la amígdala, entre otros.

Las medidas de la actividad electrodérmica (EDA), también han sido ampliamente adoptadas, pues como explica (Fernández Megías, 2012), la EDA varía proporcionalmente según el nivel de respuesta generado ante un estímulo, siendo tomado por tanto como un indicador objetivo y no manipulable para discriminar el estado emocional del paciente. Este hecho se refleja en la investigación desarrollada por (Setz et al., 2010), en la cual se emplea únicamente las variaciones de la conductancia de la piel (altura de los picos y la tasa de picos instantáneos), al reflejar de forma directa la activación del sistema simpático y por tanto de la reacción ante un estresor. El trabajo de (Setz et al., 2010), se enfocó en la discriminación del estrés de carga cognitiva en un entorno de oficina, empleándose como estímulos de estrés mental la resolución de problemas aritméticos bajo presión y de estrés psicosocial la estimulación de riesgo socio-evaluativo. Durante los experimentos, se usó un dispositivo portátil para monitorear el EDA y obtener seis clasificadores, basados en el Análisis Discriminante Lineal (LDA), SVM con diferentes Kernel y del centroide más cercano, obteniéndose una exactitud máxima del 82,8%.

### ***Sistemas multimodales para el análisis de emociones***

Si bien, en los apartados anteriores se mencionaron investigaciones enfocadas en señales asociadas a un único tipo de bioseñal cardiorrespiratoria, electromiográfica, electroencefalográfica o electrodérmica, se está tornando una práctica frecuente la adquisición simultánea de múltiples sistemas conocido como modos, intentando generar modelos más robustos para la caracterización de la respuesta fisiológica ante estresores (Giorgos Giannakakis, Grigoriadis, et al., 2019). Este enfoque, se torna lógico al entenderse que todos los sistemas se

encuentran estrechamente relacionados entre sí y son gobernados por la actividad del sistema nervioso autónomo.

En este campo, investigaciones como la de (De Santos Sierra et al., 2011), emplean señales bimodales de ritmo cardíaco (HR) y respuesta galvánica de la piel (GSR) para detectar el estrés inducido y generar modelos de lógica difusa alcanzando una exactitud del 99.5%. Como protocolo de estimulación, se empleó la hiperventilación y la preparación de una charla generando cambios fisiológicos y emocionales. Este enfoque adoptado, permite la adaptación del sistema en el tiempo y por tanto mantener el rendimiento del clasificador, además que la simplicidad para obtener las señales propuestas resulta extremadamente aplicable en tiempo real en ámbitos cotidianos.

Otra combinación bimodal de señales, es la expuesta por (Lu et al., 2015) en donde emplean características del movimiento ocular y de la señal EEG para clasificar emociones positivas, negativas y neutras mediante modelos de lógica difusa. Para la generación de estas emociones, se emplearon estímulos audiovisuales (escenas seleccionadas de películas), obteniéndose un modelo con una exactitud del 87.59%. Esta metodología fue adoptada con el fin de generar a futuro interfaces cerebro-computador aplicables al mundo real, gracias al desarrollo de EEG portables como el propuesto por (Chi et al., 2012)

Por su parte, en el trabajo realizado por (Shi et al., 2010), se extraen un total de 26 características relacionadas con bioseñales ECG, ritmo respiratorio, GSR y temperatura corporal, y se entrena y comparan una serie de clasificadores basado en SVM (Support Vector Machine) con una alta precisión y sensibilidad. Cada sujeto en este estudio fue expuesto a un protocolo compuesto de cuatro estresores (representando los desafíos sociales, mentales o físicos generadores de estrés) y seis periodos de descanso. Adicional a las métricas fisiológicas, este estudio incorporó la evaluación ecológica momentánea (EMA) como método para investigar las

experiencias y sobre todo el estado de ánimo del sujeto previo y posterior a cada periodo de estimulación o descanso. Esta métrica, permitió incorporar parámetros específicos de cada usuario para el entrenamiento de los diferentes clasificadores, obteniéndose una precisión y sensibilidad media de 68% y 80% respectivamente.

Otra investigación a destacar en el uso de sistemas multimodales es la realizada por (Arcentales V et al., 2021), en la cual se realiza el análisis multivariante de cinco señales fisiológicas ECG, fotopleitismografía PPG, resistencia galvánica de la piel, flujo respiratorio y electrooculograma, obtenidas mediante un prototipo de plataforma especializada en estudios de estrés. Como parte del protocolo de estimulación, se emplearon cuatro videos de tres minutos y veinte segundos de duración como estímulos audiovisuales de estados de relajación, estrés psicológico y estrés aritmético, y se aplicaron a 50 sujetos sanos en dos sesiones diferentes. Posteriormente se realizó el procesamiento y extracción de características temporales y frecuenciales de cada una de las señales, destacándose la estimación espectral de la interacción cardiorrespiratoria como parámetro adicional. Con base en las características estimadas y los estímulos aplicados, se calcularon múltiples clasificadores multivariados basados en SVM considerando diferentes combinaciones de características. Como resultado de la investigación, para la discriminación basal vs estrés el mejor modelo (con una exactitud del 76%) empleó todas las características, destacándose además el modelo basado solo en la señal de FLW, el cual presenta una exactitud y sensibilidad similar, pero especificidad relativamente baja. Por otro lado, para la discriminación del estrés psicológico del estrés matemático, el clasificador con mejores resultados fue basado únicamente en las características extraídas de la señal GSR, seguido del clasificador basado en todas las características. Si bien estos resultados resaltan el hecho de que el uso de características multivariantes mejora el desempeño de los clasificadores, se torna

evidente la necesidad de aplicar algoritmos de selección de características para mejorar el rendimiento de los modelos generados.

Existe un gran número de investigaciones de sistemas multimodales, variando tanto el tipo de estímulo, población aplicada, señales empleadas, y sistema de clasificación, como se observa en la revisión realizada por (Giorgos Giannakakis, Grigoriadis, et al., 2019). Según este análisis, existen señales fisiológicas consistentes en eficiencia y especificidad para la discriminación de condiciones de estrés, entre las que se encuentran el incremento de ritmo cardiaco y la variación de la respuesta galvánica de la piel, medidas influenciadas exclusivamente por la parte simpática del sistema nervioso autónomo. En cuanto a la actividad cerebral, la medida más consistente es el índice de asimetría alfa del EEG que parece reducirse durante las condiciones de estrés. Otras variaciones destacables asociadas con condiciones de estrés son: aumento de la relación LF / HF, disminución de la desviación estándar de los intervalos RR, el aumento de la presión arterial sistólica y diastólica, el aumento de la frecuencia respiratoria y el aumento de tono de voz. Sin embargo, se debe aclarar que, al tener sistemas interconectados, el análisis univariado puede no incorporar toda la información necesaria, por lo que se torna imprescindible la selección de característica adecuada para el tipo de estrés investigado (psicológico, social, mental). Otro tema sumamente importante de la investigación de (Giorgos Giannakakis, Grigoriadis, et al., 2019) resulta la variabilidad de la respuesta que tiene cada sujeto ante un específico tipo de estresor dependiendo de los parámetros sociales por ejemplo alta o baja presión de grupo, contextuales, alta recompensa versus baja recompensa, y cognitivo-emocionales, por ejemplo, instrucción para participar en la evaluación cognitiva de la situación. Además, se debe considerar adecuadamente el tipo de estresor empleado en función del estrés que se desee generar, siendo tareas de aritmética y el Stroop Color Word Test (SCWT) adecuados para generar estrés mental, entrevistas o presentaciones que impliquen una exposición social

adecuados para generar estrés social y empleando imágenes, videos o recordando situaciones con contenido cargado negativamente para generar estrés psicológico.

### **Métodos de inducción de emociones**

Como explica (Fernández Megías, 2012) la emoción implica un cambio súbito en el organismo, cambio que es producido por un estímulo, sea éste interno o externo. Adicional a este concepto, se definen como premisas clave para diferenciar a una emoción de otros estados afectivos, que: una emoción aparece como respuesta a un estímulo, tiene una duración limitada de tiempo, que genera una experiencia subjetiva consciente que el sujeto puede identificar e informar y, por último, que viene acompañada de cambios fisiológicos.

Hasta la fecha, se han empleado una gran variedad de métodos para inducir emociones en los participantes, sin ninguna clara superioridad uno de otro. Entre algunos de los métodos, se encuentran la manipulación de imaginación, interacción social, estimulación auditiva y estimulación audiovisual, siendo este último empleado en formas de fragmentos de películas o historias, o incluso como juegos interactivos. De forma general en la Tabla 1 se puede observar una comparación de los diferentes métodos de inducción de emociones, con excepción de la estimulación audiovisual, la cual se describe posteriormente.

**Tabla 1.**  
*Principales métodos de inducción de emociones*

Método	Descripción	Ventaja	Desventaja
Método Velten	Lectura de frases autorreferenciales con contenido emocional alegre, triste o neutro	Ampliamente estudiado y utilizado para inducir estados de ánimo depresivos.	El sujeto intuye fácilmente la emoción a inducir y puede informar un grado de emoción mayor al verdadero
Historia de contenido emocional	Relatos sin apoyo audiovisual y no autorreferenciados	Técnica económica y flexible	Depende de la capacidad de imaginación del sujeto
Imágenes	Uso de imágenes con contenido emocional	Sencillo y permite el uso de material de apoyo variado	Dificultad para generar emociones específicas

Método	Descripción	Ventaja	Desventaja
Música	Escuchar fragmentos de piezas musicales	Evoca eficazmente estados positivos y negativos	Dificultad para generar emociones discretas, sobre todo negativas
Sonidos	Uso de sonidos aislados (explosiones, sonidos de bebé, etc.)	Validado por varios estudios	
Recuerdos autobiográficos	Recordar eventos relacionados a la emoción a inducir	Permite inducir emociones concretas	Dificultad de estandarización, reproducción y comparación
Interacciones personales	Se generan situaciones de la vida real para inducir la emoción	Mayor validez ecológica	Difícil obtener datos sin interferir en la emoción provocada y puede ser éticamente cuestionable
Manipulación expresión facial	Activación de músculos faciales implicados en una emoción concreta		Requiere conocer la expresión asociada a la emoción a inducir
Realidad Virtual	Generar entornos virtuales	Sensación de realismo mayor a otros sistemas	Puede ser costoso de diseñar

Nota: Tabla comparativa de los principales métodos de inducción de emociones exceptuando la estimulación audiovisual. Información adaptada de *Inducción de Emociones en Condiciones Experimentales: Un Banco de Estímulos Audiovisuales*, por Fernández Megías, C., 2012, Universidad Autónoma de Barcelona.

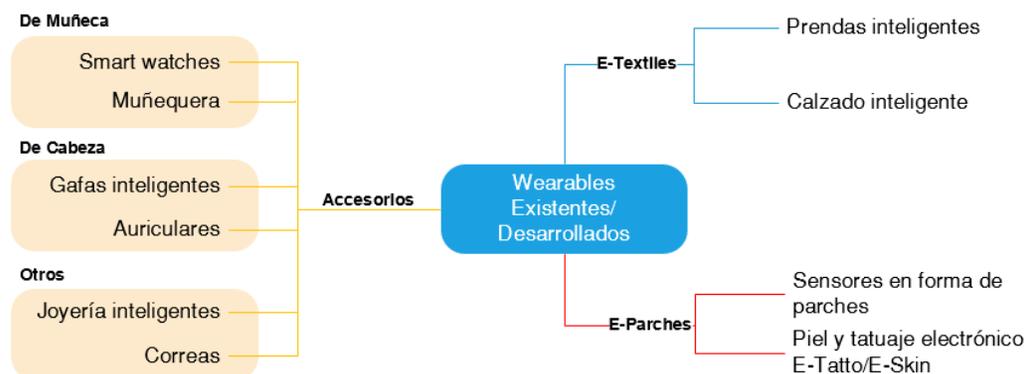
Por otro lado, según los resultados obtenidos por (Gerrards-Hesse et al., 1994), la estimulación audiovisual sería la más efectiva, tanto en la introducción de emociones positivas como negativas, destacándose que se pueden obtener tanto estados emocionales generales, positivo, negativo o neutro, como emociones discretas, ira, miedo, alegría. Este estudio empleó un grupo de métricas y técnicas meta-analíticas, como el peso medio del efecto entre las emociones generadas de los estímulos aplicados, para evaluar directamente la efectividad de cada método. Además, como explica (Fernández Megías, 2012), la estimulación audiovisual en forma de fragmentos de películas tiene una serie de ventajas como: fácil de implementar, genera

cambios subjetivos y fisiológicos, datos ecológicamente más válidos respecto a otros métodos al evocar situaciones reales, buena estandarización y reproducibilidad al no depender de la experiencia personal del usuario, capacidad para inducir emociones discretas, menor autorregulación de las emociones por parte de los participantes, método flexible que puede adaptarse a los objetivos y necesidades de cada investigación y bajo costo de implementación dependiendo únicamente de la adquisición de derechos de autor en caso de ser necesario.

### Dispositivos wearables para el registro de señales fisiológicas

Los wearables (anglicismo referente a los llamados dispositivos o tecnología vestible), como explica (Torrado, 2018) y (Billingham & Starner, 1999) son dispositivos electrónicos que pueden tomar diversas formas como prendas de vestir, accesorios y dispositivos inteligentes acoplados a las extremidades, tronco o cabeza de la persona. Generalmente combinan sensores para adquisición de bioseñales y capacidades de comunicación inalámbrica permitiendo el monitoreo en tiempo real y acceso remoto a la información recolectada (Messmer et al., 2017). En la Figura 1, se observa una clasificación general de los dispositivos wearables desarrollados, dependiendo del tipo y región de ubicación. (Seneviratne et al., 2017)

**Figura 1**  
*Clasificación de los dispositivos wearables*



Nota: Figura adaptada de *A Survey of Wearable Devices and Challenges* por Seneviratne et al., 2017, IEEE Communications Surveys and Tutorials

### ***Dispositivos estándar para adquisición de señales fisiológicas***

Como se mencionó anteriormente, la adquisición de bioseñales es uno de los aspectos clave en el diseño de un dispositivo wearable, generando diversa información sobre el estado de salud del usuario. Por ello, resulta de interés abordar el tema sobre los diferentes instrumentos estándar para adquisición de señales fisiológicas y cómo estos han ido evolucionando o han sido adaptados hacia los diferentes wearables.

En torno al análisis y diagnóstico del sistema cardiovascular, el dispositivo estándar empleado es el electrocardiógrafo, el cual capta, procesa y presenta la actividad eléctrica del corazón denominada como electrocardiograma o ECG, mediante la colocación de electrodos sobre el cuerpo. Este dispositivo generalmente emplea un total de 12 derivaciones o disposición de los electrodos sobre las extremidades y el tórax, las cuales generan información espacio-temporal completa del estado del corazón, permitiendo el diagnóstico de una serie de condiciones anormales. Si bien este dispositivo se emplea para un diagnóstico detallado del sistema cardiaco, por sus características físicas es aplicable sólo para estudios con paciente estáticos, por lo que existen versiones más compactas y con menos derivaciones conocidos como Holter. En la Figura 2, se presenta un holter, mismo que se usa como dispositivo estándar en cuanto a mediciones ambulatorias de señales ECG (Mayo Clinic, s. f.).

**Figura 2.**  
*Dispositivo Holter*



Nota: Ejemplo de dispositivo Holter tomado de *Monitor Holter* por Mayo Clinic, s. f, Mayo Clinic

Por otro lado, en cuanto a los electrodos, el ECG tradicional (y dispositivos Holter) están basados en electrodos húmedos de plata/cloruro de plata (Ag/AgCl) directamente conectados a la piel del paciente mediante un gel electrolítico. Sin embargo, para mediciones a largo plazo, estos sensores son muy poco convenientes al generar irritación y alergia (Searle & Kirkup, 2000). Por ello, se han buscado como alternativas electrodos secos (diseñados a partir de acero inoxidable) o electrodos acoplados capacitivamente, siendo estos últimos caracterizados por no requerir un contacto directo con la piel del usuario. En la Tabla 2, se puede observar una comparativa detallada sobre los tres principales tipos de electrodos.

**Tabla 2.**  
*Comparación de los tipos de electrodos.*

Tipo de electrodo	Electrodos Ag/AgCl	Electrodos secos	Acoplados capacitivamente
Descripción	Usa un gel como electrolito en contacto con la piel	Discos metálicos o plásticos conductivos colocados directamente en la piel. El sudor actúa como electrolito	El electrodo está separado de la piel por un elemento altamente dieléctrico (como la tela)
Principio de operación	Transferencia de carga mediante un camino resistivo entre la piel y el electrodo	Transferencia de carga mediante un camino resistivo entre la piel y el electrodo	Transferencia de carga mediante acoplamiento capacitivo
Ventajas	Buena calidad de señal, cuidados intensivos, no requiere electrónica local	Cómodos, confiables, menor irritación de piel	Buena calidad de señal, sin ruido por artefactos, no irrita la piel
Desventajas	Requiere asistencia experta, cambios frecuentes e irritación de la piel	Monitoreo permanente, baja calidad de señal, alta impedancia piel-electrodo	Requiere electrónica local y blindaje

Nota: Comparación de los electrodos húmedos, secos y acoplados capacitivamente. Tabla adaptada de *Wearable sensors for ECG measurement: a review*, por Ramasamy & Balan, 2018,

A pesar de que los electrodos húmedos ofrecen la menor complejidad y excelente calidad de señal, para estudios ambulatorios no son la mejor opción al generar problemas como irritación de piel, disconformidad, pueden caerse debido a sudoración excesiva o tiempo de uso, entre otros. Para sobrellevar estos inconvenientes, los dispositivos wearables presentan dos alternativas al dispositivo Holter tradicional: bandas pectorales con electrodos secos o prendas de vestir como camisetas con electrodos acoplados capacitivamente, siendo las bandas pectorales las alternativas disponibles en el mercado actual.

Las bandas pectorales, como la diseñada por Polar en sus versiones Polar H9 y Polar H10 (Polar, 2016) o de Garmin con su dispositivo HRM-Pro (Garmin Ltd., s. f.), emplean polímeros conductivos como electrodos secos debido principalmente a su flexibilidad como explica (Ramasamy & Balan, 2018) en su revisión sobre dispositivos wearables para adquisición de ECG. Esta cualidad, permite la adaptación del dispositivo al cuerpo, maximiza la comodidad y evita ser intrusivo en las actividades del usuario.

En cuanto a las prendas inteligentes, existen ya comercialmente disponibles camisetas que presentan incorporado un sensor ECG como la presentada por la empresa alemana Ambiotex (Ambiotex, s. f.). Esta incluye la misma tecnología empleada en una banda pectoral con la diferencia de que los electrodos se encuentran incorporados en la tela de la propia prenda, sin embargo, a diferencia de las bandas presentadas anteriormente, la clara desventaja de esta camiseta radica en que no cuenta con correas que permitan ajustar el sensor al cuerpo y minimizar artefactos de movimiento. Como tecnología alternativa, se tiene la desarrollada por 2M Engineering con su camiseta CardioSense, observada en la Figura 3, la cual emplea electrodos acoplados capacitivamente (2M Engineering, 2018). Esta prenda, a diferencia de otros productos, se encuentra enfocada en el monitoreo constante de pacientes en rehabilitación tras sufrir un ataque cardíaco, por lo que no solo sus medidas son de grado médico y son altamente confiables,

sino que incluyen algoritmos de inteligencia artificial enfocados en la detección en tiempo real de fibrilación atrial.

**Figura 3.**

*Camiseta CardioSense*



Nota: Camiseta inteligente en desarrollo Cardiosense tomada de *CardioSense-Wearable ECG sensor with atrial fibrillation detection*, por 2M Engineering, 2018, 2M Engineering

Además de las prendas inteligentes y la banda pectoral para la adquisición de la señal ECG, se tiene como alternativa el uso de relojes inteligentes como el presentado por Apple desde la versión 4 de su modelo Apple Watch (Apple, 2021). Este dispositivo obtiene la señal cardíaca por un periodo de 30 segundos, y al igual que con la camiseta CardioSense, tiene incorporado algoritmos para la detección de ciertas anomalías cardíacas, sin embargo, presenta la clara desventaja de que no permite el monitoreo continuo de esta señal al requerirse mantener el dedo sobre el electrodo colocado en la corona del reloj. De forma similar, el dispositivo VITAL ECG desarrollado por (Randazzo et al., 2020) empleó una metodología similar al del Apple Watch y no mostró diferencia significativa respecto al ECG convencional MAC2000 en términos de ritmo cardíaco, contenido espectral y variaciones temporales, validándose el enfoque propuesto.

Se debe destacar que, si bien los wearables están optimizados para la comodidad y monitoreo continuo, la principal desventaja radica en que por el momento no existe forma de elegir la derivación para la adquisición del ECG, es decir no se puede modificar la posición de los electrodos limitando sus aplicaciones en función del tipo de estudio deseado. Además, otro

problema a sobrellevar es la reducción de artefactos por movimiento, pues al emplearse electrodos secos o sin contacto, el sistema se torna más propenso a este tipo de perturbación, siendo esencial el incorporar algoritmos embebidos enfocados en minimizar estos defectos.

Como otra alternativa a la medición de parámetros cardíacos, se tiene el uso de sensores basados en fotopleletismografía, siendo esta una técnica óptica que detecta los cambios en el volumen de sangre con cada latido del corazón mediante la medición de la cantidad de luz absorbida o reflejada por el tejido microvascular (Allen, 2007). Se debe aclarar que la señal PPG no reemplaza a la señal ECG, pero se pueden estimar parámetros comunes como el ritmo cardíaco, variabilidad de ritmo cardíaco y estimación del ritmo respiratorio.

Tradicionalmente la señal PPG es adquirida en el dedo o lóbulo de la oreja del paciente, siendo encapsulado el sensor perpendicularmente al emisor, siendo detectados los cambios por variación de luz absorbida. Este enfoque, minimiza problemas relacionados a cambios en la luz ambiental y por movimientos ligeros del paciente, sin embargo, para estudios ambulatorios no suponen una opción viable. Por ello, la tecnología wearable propone tres alternativas a la medición tradicional de fotopleletismografía, siendo estas el uso de relojes inteligentes, de bandas o pulseras de brazo/antebrazo o el uso de auriculares, todos disponibles en el mercado actual.

A diferencia de los dispositivos ECG, existe una mayor aceptación de las pulseras y relojes inteligentes en el mercado, observándose un amplio abanico de opciones a escoger, destacándose por su popularidad la pulsera Rhythm 24 de la marca Scosche (Scosche, 2021), la pulsera OH1 de Polar (Polar, 2019a) y el reloj inteligente VivoActive4 de Garmin (Garmin Ltd., 2019). Estos dispositivos a diferencia de sus contrapartes hospitalarios, emplean tecnología por refracción, como se observa en la Figura 4, por lo que se encuentran más propensos a perturbaciones por luz ambiental y movimiento del usuario (Tamura et al., 2014). Para solucionar estos problemas, dispositivos como los Polar han adoptado una metodología basada en incorporar múltiples

sensores PPG simultáneos, sensores de luz ambiental y acelerómetros, permitiendo compensar fallas por artefactos de movimiento y cambios de luminosidad.

**Figura 4.**

*Ejemplos de wearables con medición PPG*



Nota: Sistema de sensado de la señal PPG para los dispositivos (a) Rhythm 24 y (b) VivoActive4. Imágenes adaptadas de *Scosche Rhythm24 Waterproof Heart Monitor Armband*, por Scosche, 2021, Scosche y de *vivoactive® 4 | Smartwatch with GPS | GARMIN*, por Garmin Ltd., 2019, Garmin Ltd.

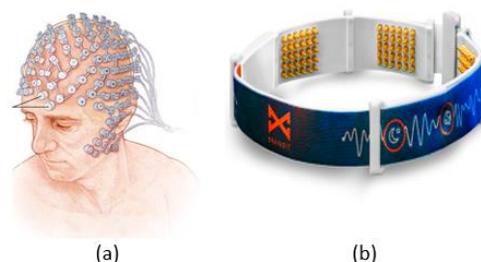
Por otro lado, auriculares como los PowerBuds diseñados por Amazfit (Amazfit, 2020) incorporan la medición de la señal de fotopletismografía en el oído del usuario y la eliminación activa de artefactos de movimiento, permitiendo una medición más precisa y en tiempo real del ritmo cardiaco mientras se escucha música y se realizan una variedad de actividades.

En cuanto a la actividad electrodérmica de la piel (EDA), de forma estándar, esta es adquirida colocando electrodos secos o húmedos en regiones como la palma de la mano, planta del pie, falange de los dedos u hombros del paciente dependiendo del tipo de estudio a realizar (Boucsein et al., 2012), notándose sin embargo que las posiciones mencionadas resultan poco prácticas para estudios ambulatorios. Como alternativa, los dispositivos wearables como la pulsera Empatica E4 (Empatica, 2019) colocan electrodos metálico en el área volar de la muñeca siendo lo menos intrusivo posibles y sobretodo sin limitar la movilidad del paciente

El desarrollo de wearables enfocados en las señales EEG no se ha quedado atrás con la presentación de alternativas como el MindWave Headset diseñado por Neurosky (NeuroSky, 2020). Este dispositivo fue incluso empleado en la investigación de (Müller & Fritz, 2015) para caracterizar la respuesta emocional de desarrolladores de software en situaciones laborales cotidianas. Para estudios clínicos, el electroencefalograma estándar puede tener desde uno hasta 256 canales dependiendo de la resolución y regiones de interés, considerando la complejidad que supone el estudio de la actividad eléctrica cerebral. Este sistema multicanal, generalmente es integrado en una capucha o gorra de tela que permite la correcta fijación y posicionamiento de los electrodos a la cabeza del paciente. Como alternativa, los dispositivos wearables actuales presentan un menor número de electrodos y por tanto menor resolución espacial, y se enfocan en regiones específicas del cerebro, como se observa en la Figura 5. Como ejemplo, el dispositivo de Brainbit (Brainbit, 2016) está diseñado para adquirir las cuatro señales cerebrales principales relacionadas a las regiones de los lóbulos temporales y occipitales, enfocándose en la generación de aplicaciones basadas en EEG como interfaces humano-máquina, análisis de patrones de sueño, entrenamiento y educación mental focalizada, etc.

**Figura 5.**

*Electroencefalograma convencional vs banda EEG comercial*



Nota: Comparativa visual entre un electroencefalograma estándar (a) y la banda desarrollada por Brainbit (b). Imágenes adaptadas de *EEG (electroencephalogram)*, por Mayo Clinic, s.f, Mayo Clinic y de *Wearable EEG Headband*, por Brainbit, 2016, Brainbit.

### ***Dispositivos wearables y sus aplicaciones***

En general, los dispositivos de muñeca, con sus dos subcategorías principales de relojes inteligentes y pulseras, son uno de los principales contribuyentes a la masificación de los wearables debido a que abordan necesidades actuales como: reemplazar al reloj convencional, actuar como una extensión del teléfono inteligente y dar seguimiento y cuantificar las diversas actividades físicas del usuario (Seneviratne et al., 2017). Sin embargo, debido a la miniaturización de la electrónica y su enfoque en ser cómodos y poco intrusivos, los dispositivos wearables cada vez están abriéndose lugar en otros campos como en la medicina deportiva y seguimiento a deportistas desde amateur hasta profesionales, estudios clínicos principalmente del tipo ambulatorio y en la medicina preventiva apoyando el creciente campo de la telemedicina.

Para seguimiento deportivo profesional, hoy en día se tienen una serie de wearables adaptados en función del deporte practicado, permitiendo un entrenamiento más inteligente y consciente por parte de sus usuarios, ejemplos de ello son las medias Sensoria Fitness (Sensoria, 2019) para corredores, que permiten el análisis de la cadencia y técnica para asentar el pie, o la banda Push Pro Band (Push, 2020) enfocada en métricas sobre el desempeño en levantamiento de pesas.

Para validaciones de uso cotidiano, estudios como los realizados por (Pardamean et al., 2019), (Wang et al., 2017) y (Parak & Korhonen, 2014), proponen analizar el desempeño de múltiples wearables principalmente mediante la correlación estadística temporal de las señales adquiridas respecto a un electrocardiógrafo (ECG) seleccionado como dispositivo patrón. De estas investigaciones, se concluye principalmente que el desempeño de los dispositivos disminuye con el incremento de la actividad cardiorrespiratoria relacionada con el ejercicio. Sin embargo, los índices de correlación encontrados son inconclusos variando entre el 76.29% y el 99%, siendo este último, alcanzado por el dispositivo Polar H7 (Polar, s. f.-a).

En cuanto a trabajos enfocadas en ámbitos clínicos, investigaciones como la de (Al-Kaisey et al., 2020), no recomiendan el uso de dispositivos de muñeca como reemplazo de los monitores Holter para el control de la frecuencia cardíaca en pacientes con fibrilación auricular. A pesar de ello, para monitorización del sueño (Parak et al., 2015), de sujetos en condiciones de descanso (Giles et al., 2016) y respiración controlada (Plews et al., 2017), el uso de wearables ha demostrado ser factible.

Estudios como el de (Fletcher et al., 2010), apoyan la idea de que los dispositivos wearables permiten el monitoreo continuo y a largo plazo de señales fisiológicas, aspecto fundamental para el tratamiento y manejo de varias enfermedades crónicas, desórdenes neurológicos y problemas de salud mental. Sin embargo, entre los retos que plantea previa a la adopción masiva de esta tecnología, es la seguridad en la transmisión de información, optimización del consumo de energía, y la reconfiguración del sistema de sensado en función de la aplicación del usuario final. En este último contexto, se ejemplifica el hecho de que, para estudios clínicos, el equipo de trabajo prefiere la adquisición de una gran cantidad de información simultánea en tiempo real, mientras que, para otras aplicaciones, un ciclo de transmisión bajo sería adecuado optimizando el consumo energético del dispositivo.

Otras investigaciones como la de (Messmer et al., 2017) plantea la factibilidad de emplear wearables en estudios clínicos para el desarrollo de fármacos y productos medicinales, reduciendo la necesidad de visitas frecuentes a centros médicos y permitiendo la adquisición objetiva de información física, fisiológica, conductual, etc. en ventanas más extensas de tiempo. No obstante, pese a las claras ventajas que esta tecnología presenta, aún se tienen trabas y preocupaciones en lo que respecta al ámbito regulatorio tanto en la estandarización de procedimientos como en la privacidad y manejo de la información, pero como aclara (Messmer

et al., 2017) estos obstáculos percibidos cada vez disminuyen a medida que la tecnología continúa mejorando.

Debido a su capacidad para recopilar y transmitir información, el uso de wearables está estrechamente relacionado con el avance del Internet de las Cosas y el campo de la salud. El avance en la medicina y por tanto el incremento en el tiempo de vida medio de las personas ha llevado a explorar nuevas tecnologías para mejorar y reducir costos asociados a la medicina preventiva. Los wearables, como explica (Haghi et al., 2017), por su capacidad para monitorizar constantemente diversos indicadores fisiológicos, están siendo integrados con la telemedicina para estructurar el Internet Médico de las Cosas (MIoT). Sin embargo, previa a que esta integración de sistemas sea completa, existen algunos retos a superarse, similares a los planteados por (Fletcher et al., 2010), siendo estos la conectividad simple y segura del dispositivo, consume energético, diseños cómodos y fáciles de colocar, y riesgo reducido de pérdida de información.

### ***Dispositivos wearables en estudios de emociones***

El estrés es un estado psicofisiológico del cuerpo humano que surge en respuesta a un evento desafiante o una condición exigente conocida como estresor. En caso de una exposición prolongada a múltiples estresores, la salud física y mental de una persona puede verse comprometida a mediano y largo plazo generando incluso problemas de salud crónicos. Para prevenir los problemas relacionados con el estrés, es necesario detectarlos en las etapas iniciales, lo que es posible únicamente mediante un seguimiento continuo del estado físico de la persona (Gedam & Paul, 2021). Para ello, una de las alternativas más prometedoras resulta el uso de dispositivos wearables para la recopilación continua y en tiempo real de datos, y posterior generación de modelos basados en técnicas de inteligencia artificial para la detección y caracterización de estrés mental y otros estados afectivos relacionados. En este contexto, se han

realizado una serie de investigaciones variando el tipo de señales adquiridas, recreando diversos ambientes y aplicando variadas técnicas de machine learning, observándose en la Figura 6 un resumen de los principales elementos empleados

**Figura 6.**  
*Detección de estrés mental mediante wearables*



Nota: Se presentan los principales tipos de señales, ambientes recreados y algoritmos de machine learning empleados en estudios para la detección de estrés mental mediante el uso de dispositivos wearables. Información adaptada de *A Review on Mental Stress Detection using Wearable Sensors and Machine Learning Techniques*, por Gedam & Paul, 2021, IEEE Access

Un ejemplo de investigaciones centradas en entornos académicos, fue la desarrollada por (Can et al., 2019). En este estudio, se emplearon el reloj inteligente Samsung Gear S junto a la pulsera Empatica E4 para adquirir señales PPG, GSR, temperatura de la piel y aceleración durante nueve días en 21 participantes de un concurso de programación, con el fin de discriminar estados de relajación, estrés y carga cognitiva relativamente alta. Posterior a la adquisición, se realizó el procesamiento basado principalmente en la remoción de artefactos de movimiento, la extracción de características, y entrenamiento de modelos de clasificación, proceso similar al mencionado

anteriormente respecto a sistemas multimodales. Como resultados de esta investigación, se obtuvo un clasificador de tres niveles con una exactitud del 90.4% con los datos obtenidos por la pulsera Empatica E4, mientras que para el dispositivo Samsung se obtuvo una exactitud del 84.67%, deduciéndose que la exactitud de los modelos generados depende de la calidad de la señal obtenida, siendo superior la de la pulsera Empatica E4 por su enfoque investigativo. En lo que respecta al algoritmo de detección, se compararon seis clasificadores bien conocidos basados en PCA y LDA, PCA y SVM, KNN, regresión logística, random forest y perceptrón multicapa, siendo estos dos últimos los que tuvieron un mejor rendimiento. Como una acotación adicional, se destaca que entrenar clasificadores específicos para cada usuario resulta un acercamiento práctico para incrementar el rendimiento del sistema generado, y de no adoptarse esta metodología, se pueden previamente agrupar a los sujetos en clusters de comportamiento de estrés y entrenar modelos generales para dicho cluster. Esta conclusión fue corroborada por la investigación de (Udovičić et al., 2017), la cual emplea el dispositivo portable Shimmer3 (Shimmer Sensing, 2020) para adquirir señales de GSR y PPG, y entrenar clasificadores basados en SVM y KNN.

La pulsera Empática E4 y su versión anterior (E3), debido a su enfoque investigativo y accesibilidad a las señales no procesadas de los sensores, ha sido empleada en una gran variedad de estudios, como lo explica (Seneviratne et al., 2017). Por ejemplo, en el estudio realizado por (Müller & Fritz, 2015), se demostró la posibilidad de clasificar emociones positivas y negativas usando la Empatica E3, junto a la banda MindWave de Neurosky y el dispositivo Eye Tribe para capturar medidas GSR y PPG, electroencefalográficas y del movimiento ocular respectivamente. Estas medidas fueron seleccionadas debido a que el estudio tenía por objetivo el de verificar y caracterizar la respuesta emocional de desarrolladores de software a lo largo del progreso que tienen en un proyecto. La investigación logró generar clasificadores basados en árboles de

decisión con una exactitud del 71% planteándose la posibilidad de generar a futuro sistemas de recomendación enfocados en mejorar la productividad del desarrollador en función de su estado mental.

Otro estudio a considerar, fue el desarrollado por (Betti et al., 2018) tuvo por objetivo validar la capacidad de un sistema de sensores fisiológicos portátiles, basados en la banda pectoral BioHarness de Zephyr, el dispositivo Shimmer3 y el headset MindWave de Neurosky, para capturar el estrés y evaluar si los cambios detectados en las señales fisiológicas se correlacionan con los cambios en el nivel de cortisol salival, que es un biomarcador de estrés objetivo y confiable. El algoritmo de clasificación SVM, basado en las características más relevantes, obtuvo una exactitud del 86%, y el análisis de correlación mostró que los cambios observados en las características fisiológicas eran consistentes con la tendencia de los niveles de cortisol en la saliva.

Dentro de las investigaciones enfocadas en el uso de wearables para estudios de emociones, se destacan aquellas que desarrollan o emplean plataformas experimentales como es el caso de los trabajos realizados por (Wijsman et al., 2011) y (Plarre et al., 2011). En este campo, al desarrollar sistemas netamente investigativos, se añaden una serie de capacidades como el incremento en el número de sensores, aumento del tiempo de autonomía y mejor integración y comunicación entre sus elementos. En este último punto, se recalca la emergente tecnología BAN, siglas en inglés de Body Area Networks, la cual pretende sobrellevar los problemas de estandarización en la comunicación de los diferentes dispositivos portátiles y generar un único servidor que concentra y envía todos los datos a una aplicación móvil o incluso directamente a la nube. En el trabajo de (Wijsman et al., 2011), se emplea la plataforma desarrollada por (Brown et al., 2009) para la adquisición de señales ECG, EMG, respiración y GSR de sujetos sanos sometidos a un protocolo de estimulación de estrés mental, obteniéndose un clasificador binario con un 80% de exactitud. En cuanto a la investigación de (Plarre et al., 2011), 21 sujetos fueron

expuestos a estresores cognitivos, físicos y sociales, similares a los experimentados en un entorno natural, adquiriéndose señales ECG, GSR, respiración, temperatura ambiental y aceleración, mediante la plataforma experimental Autosense (Autosense Project, s. f.). Obteniéndose una exactitud del 90% con el modelo entrenado, se puede inferir que la tecnología BAN cómoda y de bajo consumo va a permitir la monitorización ambulatoria de emociones en tiempo real en el futuro.

Si bien en su mayoría los estudios encontrados tienen por objetivo la generación de modelos para la detección de estrés, existen otros estudios que intentan comparar objetivamente los wearables de los dispositivos estándar de medición, descritos en el apartado de Dispositivos estándar para adquisición de señales fisiológicas. Bajo este concepto, se destaca el trabajo de (Ollander et al., 2017), en el cual se analiza las características de variabilidad de ritmo cardíaco y respuesta galvánica de la piel adquiridas por la pulsera Empatica E4 respecto a las adquiridas por un electrocardiógrafo estándar y un sensor de EDA al someter a sujetos sanos a estresores sociales. Entre los resultados destacados, se tiene el hecho de que, si bien la señal PPG de la Empatica E4 tiene una pérdida considerable de intervalos entre pulso y pulso especialmente durante el desarrollo de una tarea, se pueden estimar aceptablemente medidas temporales como la media y desviación estándar de la frecuencia cardíaca. En cuanto a la actividad electrodérmica, pese a que las señales adquiridas en diferentes ubicaciones, muñeca vs dedo, no muestran semejanza visual, la GSR tomada con la E4 tiene un mayor poder de discriminación de estrés que la señal medida en el dedo.

### Capítulo III

#### Plataforma Multisensado Para La Adquisición De Señales Fisiológicas

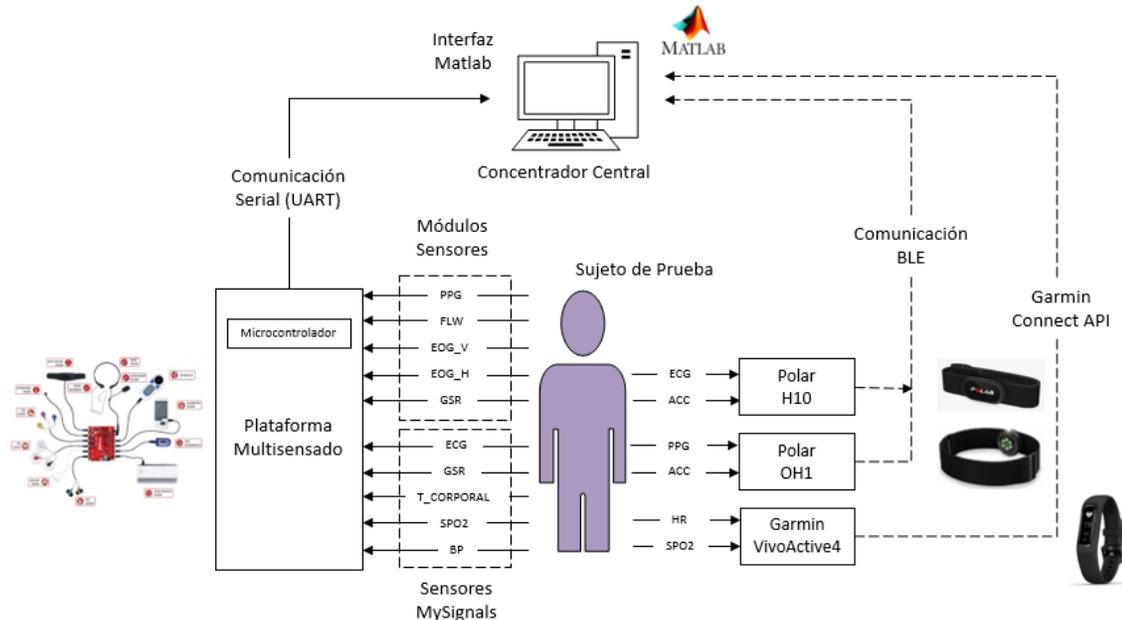
##### Introducción

Una vez investigado el estado del arte en lo que respecta al uso de wearables y dispositivos estándar, se procedió a generar un sistema multisensado que permita el registro simultáneo de ciertas señales fisiológicas de interés para estudios de estrés. En este contexto, en el presente capítulo se describe a detalle el hardware y software del sistema multisensado, empleando a la plataforma MySignalsHW y módulos de fotopletimografía, respuesta galvánica de la piel, flujo respiratorio y electrooculografía como dispositivos estándar y a los Polar OH1, Polar H10 y Garmin VivoSmart4 como dispositivos wearables. El hardware diseñado tuvo por objetivo ser modular, fácil de conectar y de calibración sencilla.

En cuanto al diseño de software, se emplea el programa Matlab 2019b en un computador central para la comunicación y recopilación de información con el hardware mencionado. Este software fue seleccionado al incorporar funciones propias para establecer la comunicación con el controlador de la plataforma MySignals y con los dispositivos wearables, además de que permite generar una interfaz para controlar la adquisición y visualización de señales en tiempo real.

En la Figura 7, se puede observar el diagrama de bloques del sistema propuesto, en el que se describe de forma general las señales adquiridas por la plataforma multisensado y los dispositivos wearables, y el tipo de comunicación empleada hacia el computador central. Se debe aclarar que, el objetivo de emplear diferentes dispositivos y módulos, muchos de ellos con señales redundantes, es tanto para la generación de la base de datos como para realizar una comparativa de desempeño de unos con otros.

**Figura 7.**  
*Esquema de conexión para el registro de señales*



### Plataforma MySignals

MySignals, es una plataforma de desarrollo de la empresa Libelium, enfocada en aplicaciones de e-Health, la cual, en su versión completa, permite medir más de quince diferentes parámetros biométricos como son: ritmo cardíaco, ritmo respiratorio, saturación de oxígeno en sangre, presión sanguínea, electrocardiograma, electromiografía, flujo respiratorio, entre otros (Cooking Hacks, 2017). Esta plataforma presenta dos modelos, observados en la Figura 8, siendo MySignalsSW enfocada en aplicaciones web e IoT, y MySignalsHW enfocada en el área de investigación. Debido a su enfoque, MySignalsHW permite al usuario configurar el software del controlador y adicionar sensores de requerirse, a diferencia de MySignalsSW la cual permite únicamente seleccionar los dispositivos a emplear, con la ventaja de presentar una conexión inherente con la nube.

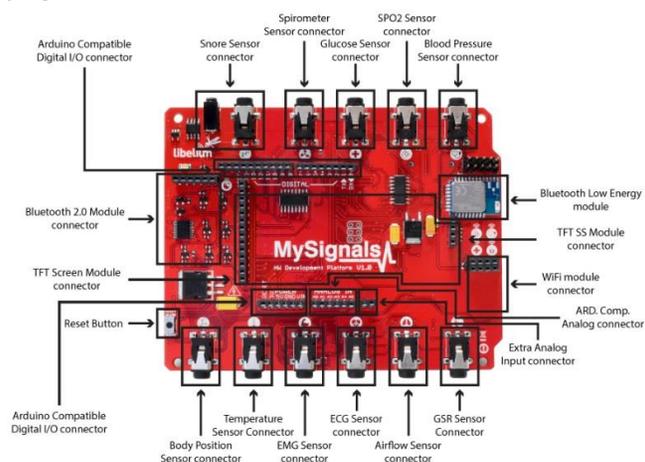
**Figura 8.**  
Modelos de la plataforma MySignals



Nota: Modelos de la plataforma MySignals: MySignalsSW (izquierda) y MySignalsHW (derecha). Tomado de *MySignalsHW v2 - eHealth and Medical IoT Development Platform for Arduino*, por Cooking Hacks, 2017

La plataforma MySignals en su modelo de Hardware, fue la empleada en el presente trabajo de investigación y como se presenta en la Figura 9, tiene 11 conectores para cada uno de los sensores alámbricos disponibles, analógicos o de conexión serial tipo UART, cuenta con pines para adición de módulos externos para comunicación inalámbrica Wi-Fi, Bluetooth y BLE y cuenta con conectores para un display TFT táctil

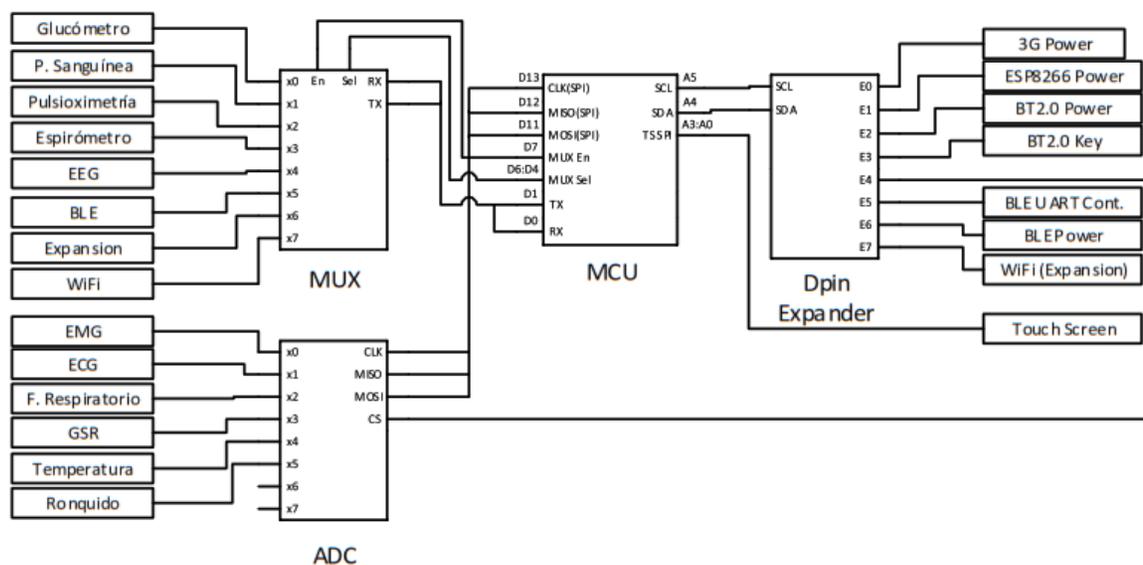
**Figura 9.**  
Hardware, plataforma MySignalsHW



Nota: Imagen de los conectores de la plataforma MySignalsHW y su descripción. Tomado de *MySignalsHW v2 - eHealth and Medical IoT Development Platform for Arduino*, por Cooking Hacks, 2017

Si bien, la plataforma MySignalsHW permite el acceso al Hardware completo y permite la configuración de su controlador, se tiene por desventaja que solo puede realizar la adquisición simultánea de un grupo de sensores dependiendo de la interfaz de conexión empleada (sensores analógicos, sensores seriales tipo UART o sensores inalámbricos BLE). Este hecho se debe a que las diferentes interfaces emplean recursos comunes como se observa en el diagrama de la Figura 10. Este hecho se puede notar en la conexión de los sensores de presión sanguínea y pulsioximetría hacia un multiplexor común que permite la transmisión UART hacia el controlador.

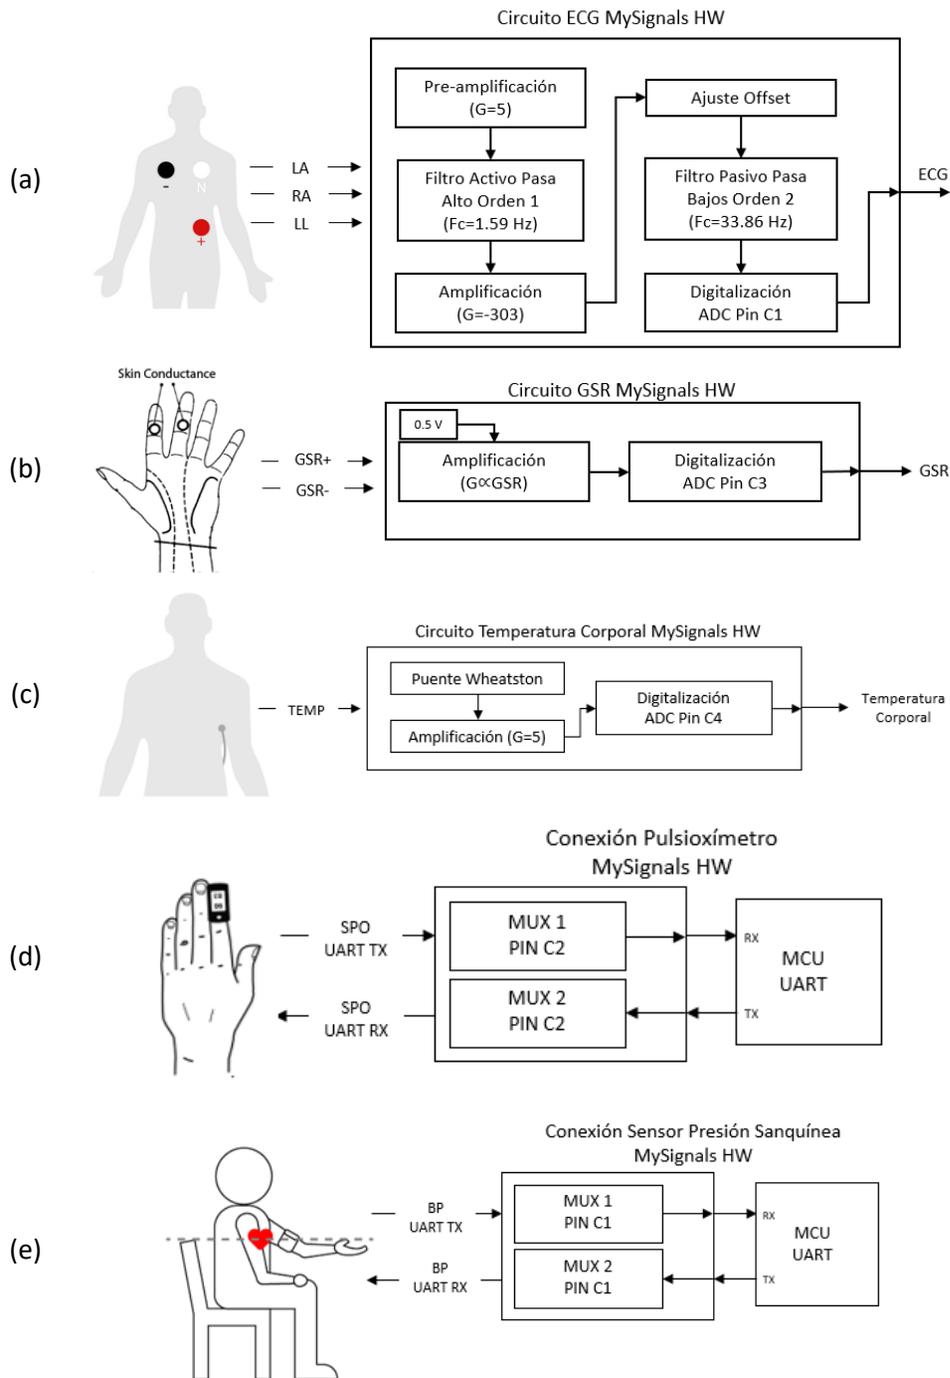
**Figura 10**  
*Diagrama esquemático de la plataforma MySignalsHW*



En la Figura 11, se observa el diagrama de bloques de los circuitos para las señales ECG, GSR, temperatura corporal, pulsioximetría y presión sanguínea implementados en la MySignalsHW, destacándose que los circuitos de acondicionamiento de los sensores analógicos son basados en la plataforma e-Health V2 al ser una versión mejorada de esta (Cooking Hacks, 2012). Se debe destacar, que, si bien el acondicionamiento es similar, la digitalización de las señales difiere, siendo empleado el convertor A/D MCP3208 de 10 bits de resolución que cuenta con una interfaz SPI.

**Figura 11.**

Diagrama de bloques sensores de la plataforma MySignalsHW.



Nota: Diagrama de bloques de los circuitos ECG (a), GSR (b), Temperatura corporal (c), pulsioximetría (d) y presión sanguínea (e) de la plataforma MySignals HW. Adoptado de *e-Health Sensor Platform Schematic*, por Cooking Hacks, 2012

## Sensores externos

Para mejorar las capacidades de la plataforma MySignals y superar limitaciones encontradas en su diseño, se adicionaron módulos externos para la adquisición de señales de flujo respiratorio, fotopleletismografía, electrooculografía y respuesta galvánica de la piel, siendo los tres primeros, FLW, PPG y EOG, diseñados por el investigador y el último, GSR, diseñado por la empresa (Grove, 2014)

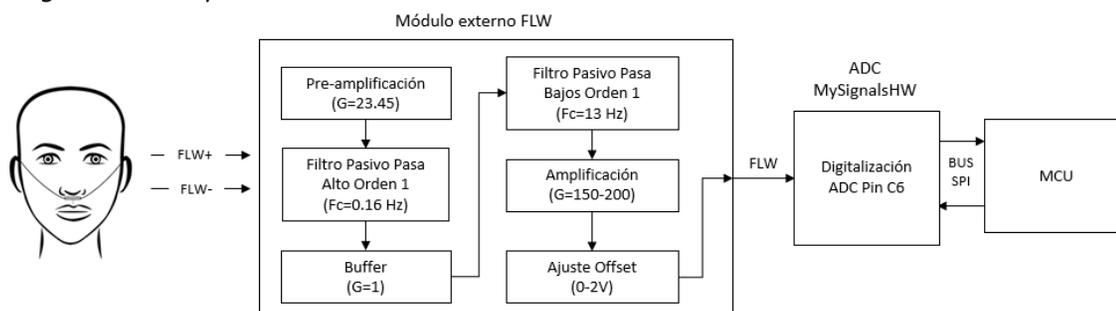
### Módulo de flujo respiratorio (FLW)

Si bien la plataforma MySignals cuenta con un sistema de adquisición de la señal de flujo respiratorio, este presentaba la gran limitante de únicamente adquirir los ciclos positivos de dicha señal. Este hecho hizo imprescindible diseñar un módulo adicional que pueda registrar la señal completa de flujo respiratorio.

Para el diseño del módulo, se emplea como referencia el sistema de acondicionamiento implementado en la propia MySignals, tomado de (Cooking Hacks, 2012), siendo adaptado a las necesidades del proyecto como la integración de una etapa de amplificación y desplazamiento variable, permitiendo la calibración manual en función del paciente con el fin de aprovechar el rango completo del conversor análogo digital propio de la tarjeta de adquisición. En la Figura 12, se puede observar el diagrama de bloques del sistema de acondicionamiento diseñado, en donde se tienen etapas de: pre amplificación, filtrado, amplificación y desplazamiento offset

**Figura 12.**

*Diagrama de bloques del módulo FLW*



Para la adquisición de la señal, se utilizó el mismo sensor de la plataforma MySignals, siendo este un sensor térmico tipo termopar en forma de cánula, el cual permite medir los cambios de temperatura debido a los ciclos de inspiración y expiración bajo las fosas nasales

Para la etapa de preamplificación, se emplea el amplificador de instrumentación AD620 de Analog Devices (Analog Devices, s. f.), siendo adecuado para sistemas de adquisición de bioseñales, los cuales requieren características específicas como una alta precisión, bajo nivel de ruido y bajo consumo. Para la ganancia de esta etapa, se busca mantener valores similares a los presentados por el sistema de la plataforma MySignals ( $G=254.54$ ), por lo que se calculó la resistencia de ganancia  $R_G$  con la fórmula:

$$G = 1 + \frac{49.4k\Omega}{R_G} \rightarrow R_G = \frac{49.4k\Omega}{G - 1} = 194.84\Omega \sim 200\Omega$$

Sin embargo, durante la etapa de pruebas de funcionamiento, se observó una saturación en la señal acondicionada, por lo que se redujo de forma experimental el valor de la resistencia a un valor comercial de  $R_G = 2.2k\Omega$ , obteniéndose una ganancia de 23.45, calculada como:

$$G = 1 + \frac{49.4k\Omega}{2.2k\Omega} = 23.45$$

Para el filtrado analógico de la señal, se emplea un filtro pasivo pasa banda de primer orden basado en un filtro pasa altos (HPF) con una frecuencia de corte de 0.16 Hz, un buffer para acople de impedancias y un filtro pasa bajos (LPF) con una frecuencia de corte de 13Hz. Estos valores fueron obtenidos a partir de los condensadores y resistencias del diseño original de la plataforma MySignals, siendo estos calculados como:

$$f_{c\text{HPF}} = \frac{1}{2\pi \times R_2 \times C_1} = \frac{1}{2\pi \times 100k\Omega \times 10\mu F} = 0.16 \text{ Hz}$$

$$f_{c\text{LPF}} = \frac{1}{2\pi \times R_3 \times C_2} = \frac{1}{2\pi \times 56k\Omega \times 220\eta F} = 12.92 \text{ Hz} \sim 13 \text{ Hz}$$

Una vez filtrada la señal, reduciéndose el ruido de baja y alta frecuencia como el de la red eléctrica, se continuó con la etapa de amplificación y offset variables, destacándose que se emplea un único amplificador para ambas funciones con el fin de minimizar el número de elementos y tamaño del hardware. El circuito empleado, presenta una serie de ecuaciones simples, basadas en la configuración de amplificador no inversor, que permiten el cálculo de la ganancia y voltaje de desplazamiento, siendo estas:

$$G = 1 + \frac{R_f}{R_i}$$

$$V_{Offset} = V_{ref} \frac{R_2}{R_1} * G$$

En donde, G corresponde a la ganancia del circuito y  $V_{ref}$  es el voltaje encontrado a la salida del potenciómetro de offset

Si se considera una ganancia variable aproximada entre 150 y 200, y seleccionando un valor de  $R_i = 1k\Omega$ ,  $R_f$  fue seleccionada como una resistencia de  $150k\Omega$  en serie con un potenciómetro de precisión de  $50k\Omega$ , calculados a raíz de:

$$\frac{R_f}{R_i} = G - 1 ; \text{ Con } R_i = 1k\Omega$$

$$R_{f \min} = 149k\Omega \sim 150k\Omega \quad R_{f \max} = 199k\Omega \sim 200k\Omega$$

En cuanto al voltaje de desplazamiento se busca un valor comprendido entre 0 y 2V, calculándose los valores de resistencias para el valor máximo como:

$$R_i \gg R_2$$

$$1k\Omega \gg 100$$

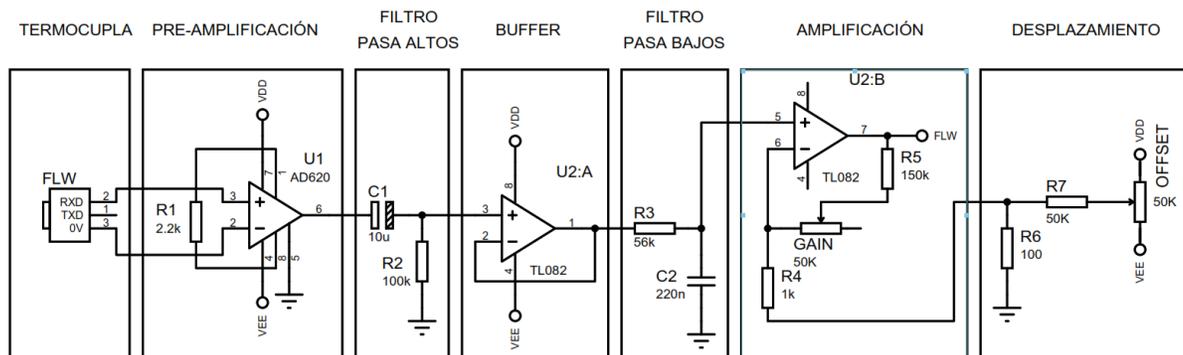
$$V_{Offset} = V_{ref} \frac{R_2}{R_1} * G \rightarrow R_1 = V_{ref} * \frac{R_2}{V_{Offset}} * G_{max}$$

$$R_1 = 5 * \frac{100}{2} * 200 = 50k\Omega$$

Finalmente, en la Figura 13 se puede observar el circuito completo implementado para la adquisición de la señal de flujo respiratorio y sus diferentes etapas descritas anteriormente.

**Figura 13.**

*Circuito implementado para el módulo FLW*

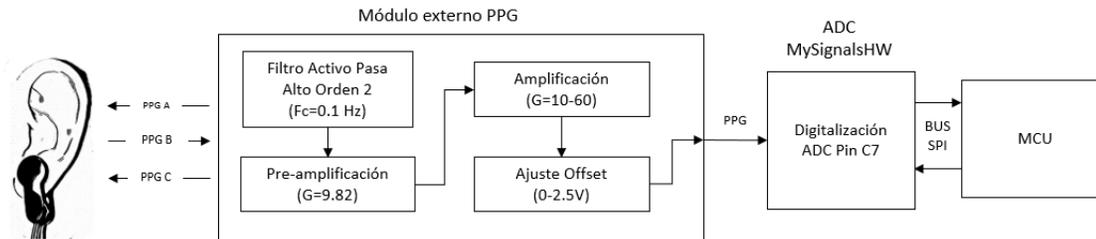


### **Módulo de fotopletismografía (PPG)**

La plataforma MySignals, presenta un módulo de pulsioximetría, basado en la señal fotopletismográfica, que entrega valores instantáneos de ritmo cardiaco y saturación de oxígeno, sin embargo, con estas métricas no se logra establecer una comparación objetiva con el dispositivo Polar OH1. Por este motivo, se implementó un módulo adicional para la adquisición de la señal no procesada de fotopletismografía, siendo presentadas sus etapas en la Figura 14.

**Figura 14.**

*Diagrama de bloques del módulo PPG*



El sensor empleado corresponde al clip de oreja HRM-2511B de Kyto, que como explica (Cruz Varela, 2021), se encuentra compuesto por un emisor de luz infrarroja y un fototransistor permitiendo adquirir la señal de fotopletismografía mediante la técnica de transmisión. Este

sensor requiere de dos resistencias externas para la polarización de sus elementos, observadas en el circuito final de la Figura 15.

Al ser el mismo sensor empleado en el trabajo de (Betancourt Mediavilla & Yépez Narváez, 2018), se tomó como referencia esta investigación para el diseño del acondicionamiento, siendo reemplazado el amplificador de instrumentación y el circuito de amplificación y offset por los mismo descritos anteriormente.

La señal PPG presenta una componente DC pronunciada, por lo que previa a la amplificación se implementa un filtro pasa altos activo a una frecuencia de corte de 0.1 Hz. Esta etapa, se implementa mediante un filtro activo Butterworth de segundo orden con una configuración tipo Sallen Key.

Para la pre amplificación, se busca mantener la misma ganancia de 10.25 empleada por (Betancourt Mediavilla & Yépez Narváez, 2018), por lo que la resistencia  $R_5$  se calculó como:

$$R_G = \frac{49.4k\Omega}{G - 1} = \frac{49.4k\Omega}{9.25} = 5.34k\Omega$$

Aproximando la resistencia de ganancia a la comercial más cercana, se seleccionó una resistencia de  $5.6k\Omega$ , obteniéndose una ganancia de  $G = 9.82$ . Si bien esta pre-amplificación es menor a la deseada, se compensa con la etapa siguiente.

Para la amplificación, se selecciona la resistencia  $R_i$  con un valor de  $1k\Omega$  y se emplea una resistencia de  $10k\Omega$  en serie con un potenciómetro de precisión de  $50k\Omega$  para obtener una ganancia variable entre 10 y 50.

Para el desplazamiento de la señal, se considera un rango variable entre 0 y 2.5V, y se utiliza el mismo circuito empleado para el módulo de flujo respiratorio, calculándose los valores de resistencia para el offset máximo como:

$$R_i \gg R_2$$

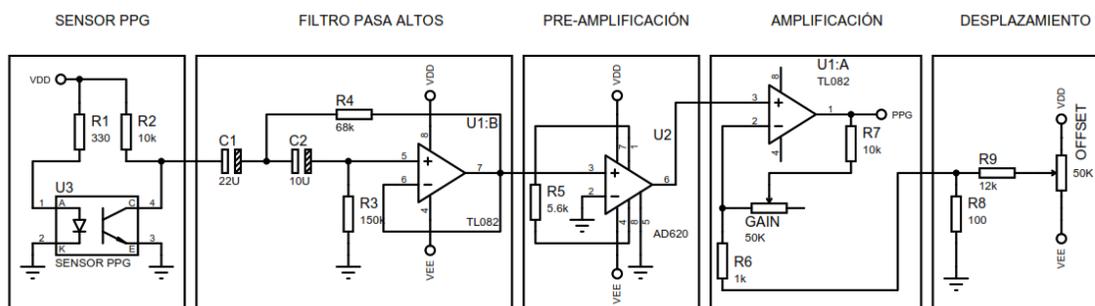
$$1k\Omega \gg 100$$

$$V_{offset} = V_{ref} \frac{R_2}{R_1} * G \rightarrow R_1 = V_{ref} * \frac{R_2}{V_{offset}} * G_{max}$$

$$R_1 = 5 * \frac{100}{2.5} * 60 = 12k\Omega$$

En la Figura 15, se puede observar el circuito completo implementado para la adquisición de la señal de fotopleletismografía y sus diferentes etapas descritas anteriormente.

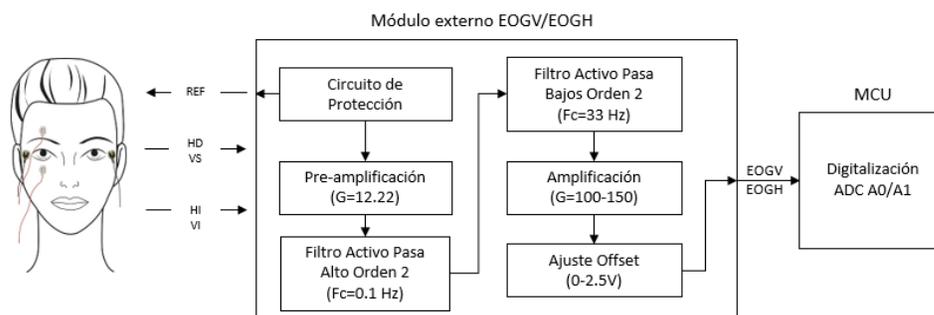
**Figura 15.**  
Circuito implementado para el módulo PPG



### Módulo para electrooculografía (EOG)

Como se explicó en el apartado de Otros cambios fisiológicos de interés, el movimiento ocular resulta de interés para analizar la respuesta de un sujeto ante estímulos audiovisuales. Por ello, se añadió un módulo para la adquisición de la señal bipolar ocular horizontal y vertical a través de electrodos superficiales, similar al implementado por (Betancourt Mediavilla & Yépez Narváez, 2018). Las etapas del módulo para la adquisición de las señales EOG tanto verticales como horizontales se pueden observar en la Figura 16

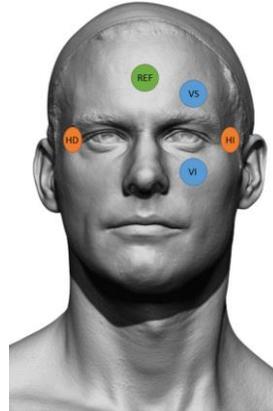
**Figura 16.**  
Diagrama de bloques del módulo EOG



Para la adquisición, se emplean electrodos húmedos desechables convencionales de Ag/AgCl, colocados en el rostro del paciente de acuerdo a la Figura 17. Al ser una señal bipolar, se emplean dos electrodos para cada canal y adicionalmente se emplea un electrodo de referencia que junto al circuito de realimentación y protección impide el paso de corrientes hacia el paciente.

**Figura 17.**

*Posición de los electrodos para EOG*



En la etapa de preamplificación, se emplea nuevamente el amplificador de instrumentación AD620 con una resistencia externa de ganancia  $R_G = 10.22k\Omega$ , dando una ganancia de  $G = 10.22$

Para eliminar las componentes de frecuencia no deseadas, se aplicó un filtro pasa altos y pasa bajos con frecuencias de corte de 0.1 Hz y 33 Hz respectivamente, diseñados mediante la herramienta Filter Design Tools de Texas Instruments (Texas Instruments, 2013). Se debe aclarar que la implementación se realizó mediante filtros activos de segundo orden tipo Butterworth en configuración Sallen-Key y que las frecuencias fueron seleccionadas a raíz del trabajo de (Betancourt Mediavilla & Yépez Narváez, 2018).

Para la amplificación, se selecciona la resistencia  $R_i$  con un valor de  $1k\Omega$  y se emplea una resistencia de  $100k\Omega$  en serie con un potenciómetro de precisión de  $50k\Omega$  para obtener una ganancia variable entre 100 y 150.

Para el desplazamiento de la señal, se considera un rango variable entre 0 y 2.5V, y se utiliza el mismo circuito de los módulos anteriores, siendo calculados los valores de resistencia para el offset máximo como:

$$R_i \gg R_2$$

$$1k\Omega \gg 100$$

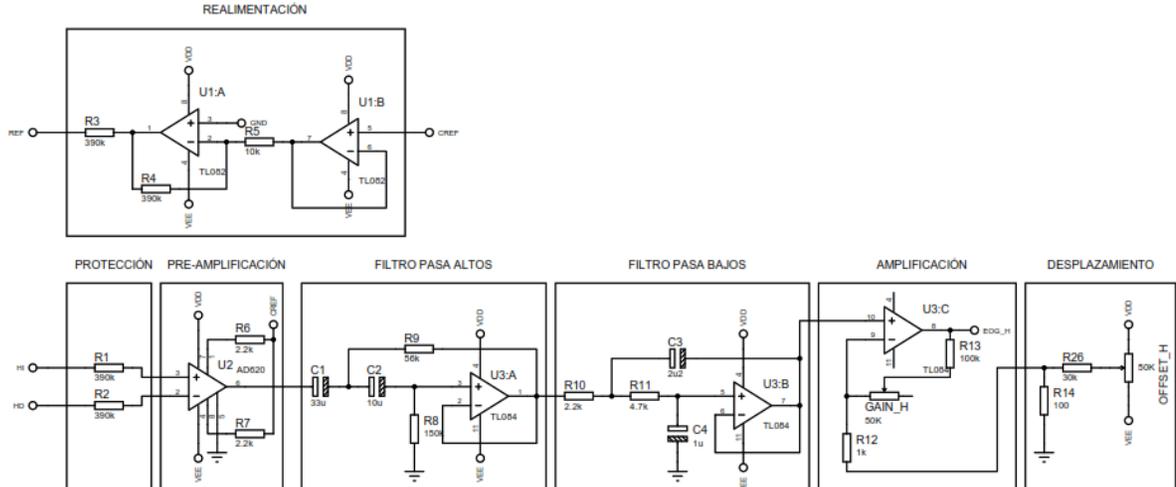
$$V_{offset} = V_{ref} \frac{R_2}{R_1} * G \rightarrow R_1 = V_{ref} * \frac{R_2}{V_{offset}} * G_{max}$$

$$R_1 = 5 * \frac{100}{2.5} * 150 = 30k\Omega$$

En la Figura 18, se puede observar el circuito completo implementado para la adquisición de la señales EOG y sus diferentes etapas descritas anteriormente, destacándose que el circuito tanto para el canal horizontal como vertical es idéntico.

**Figura 18.**

*Circuito implementado para el módulo EOG*



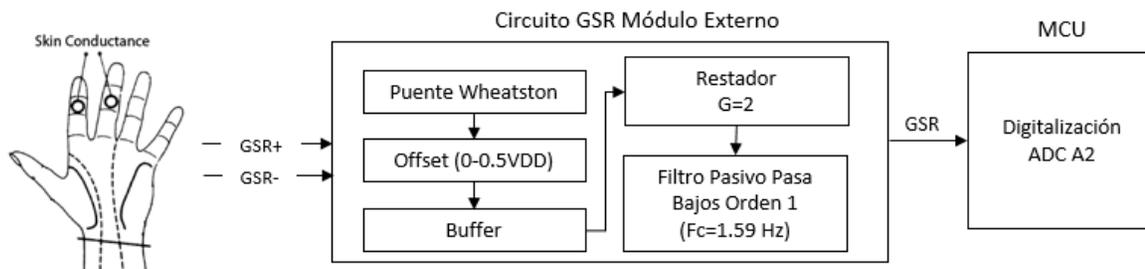
### **Módulo de respuesta galvánica de la piel (GSR)**

Si bien la plataforma MySignals presenta un sistema para adquisición de la respuesta galvánica de la piel, en las pruebas de funcionamiento, se encontró que la señal obtenida resultaba extremadamente ruidosa y no se observaban variaciones cuantificables. Por esta razón,

se adiciona el módulo de GSR diseñado por (Grove, 2014), el cual presenta el diagrama de bloques observado en la Figura 19.

**Figura 19.**

*Diagrama de bloques del módulo GSR externo*



Nota: Diagrama adaptado de *GSR Sensor*, por Grove, 2014

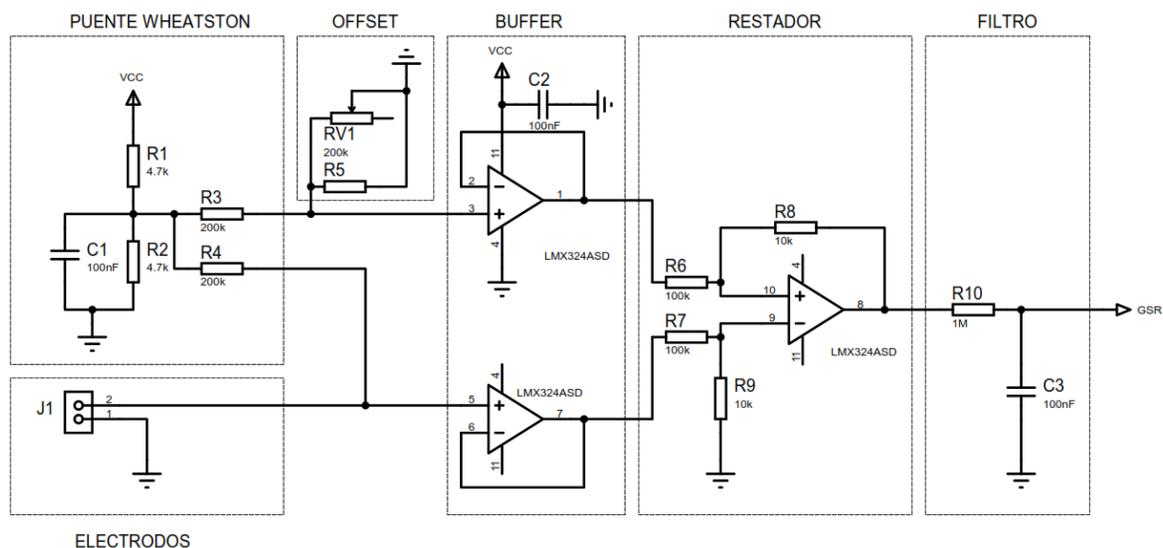
Como se puede visualizar, a diferencia del módulo implementado en la plataforma MySignals, el módulo de Grove emplea un puente de Wheatstone para mejorar la precisión y sobre todo sensibilidad del sistema, además, adiciona una etapa de filtrado, reduciendo el ruido de alta frecuencia que puede afectar la medición.

El circuito de acondicionamiento se puede observar en la Figura 20, del cual se obtiene el valor de resistencia de acuerdo a la siguiente ecuación:

$$V_{out} = 2.5 * \left( \frac{R_{GSR} - 200k\Omega}{200k\Omega + R_{GSR}} \right) \rightarrow R_{GSR} = 200k\Omega \left( \frac{V_{out} + 2.5}{2.5 - V_{out}} \right)$$

**Figura 20.**

*Circuito de acondicionamiento del módulo de GSR externo*

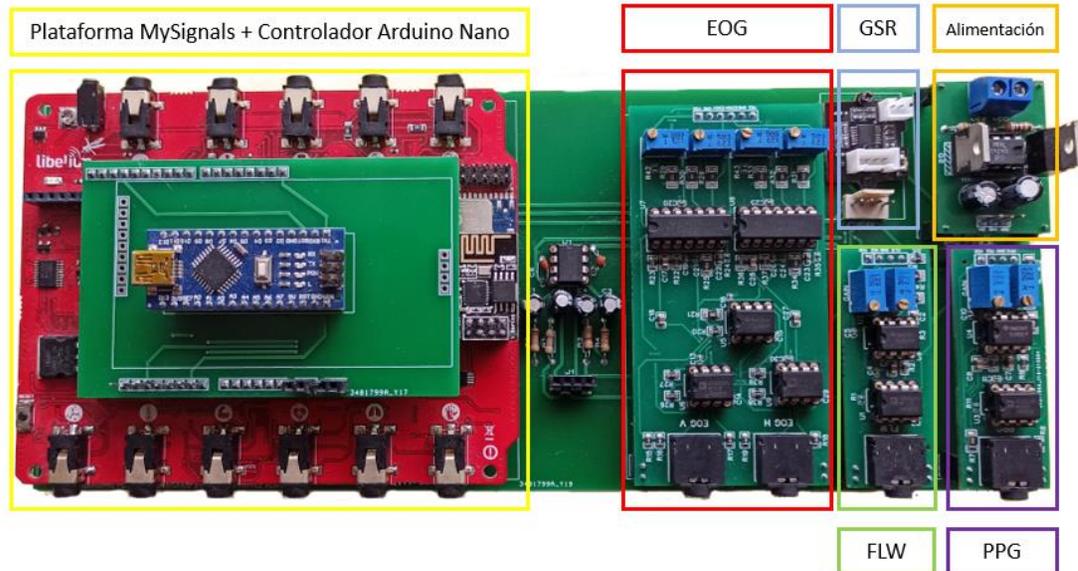


Nota: Diagrama adaptado de *GSR Sensor*, por Grove, 2014

### ***Plataforma implementada para la adquisición de bioseñales***

Una vez descritas las funcionalidades y limitaciones de la plataforma MySignals, y desarrollados módulos adicionales para mejorar el sistema, se procedió a diseñar una plataforma a modo de Mainboard que permita la integración de todos estos sistemas en un solo prototipo fácil de conectar y manipular, obteniéndose el sistema de la Figura 21. Además, otra característica fundamental de la plataforma diseñada es su modularidad, permitiendo el uso de los sistemas por separado a conveniencia del proyecto a realizar.

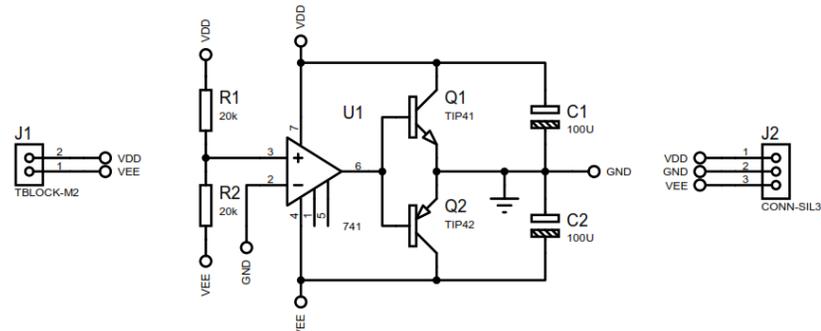
**Figura 21.**  
Plataforma multisensado completa



La plataforma consta de los sistemas descritos anteriormente, incluyendo un módulo adicional de alimentación y un módulo que permite la conexión del Arduino Nano como controlador seleccionado.

El módulo de alimentación permite la conexión de una única fuente positiva de voltaje VCC para la alimentación de los circuitos diseñados, mediante la implementación de un Rail-Splitter simple basado en un amplificador operacional y transistores BJT. Este circuito, observado en la Figura 22, permite obtener un voltaje positivo y negativo, con voltajes  $\frac{VCC}{2}$  y  $-\frac{VCC}{2}$  respectivamente, al generarse una tierra flotante como referencia.

**Figura 22.**  
Circuito de alimentación implementado



Si bien la plataforma MySignalsHW está diseñada para acoplarse sobre un controlador Arduino Uno o Arduino Mega, se diseñó una placa específica para la conexión y operación del sistema con un Arduino Nano. Esto se lo realizó para facilitar las conexiones de los nuevos módulos diseñados a las entradas del microcontrolador

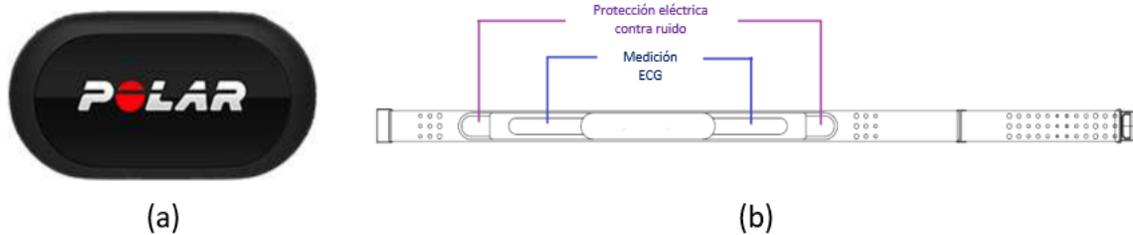
## Dispositivos Wearable

### Dispositivos Polar

El dispositivo Polar H10 corresponde a un sensor de frecuencia cardiaca de alta precisión montado sobre una banda pectoral (Polar, 2019c). Este dispositivo consta de una banda flexible con electrodos secos, y de un módulo para la adquisición y transmisión de la señal cardíaca y de aceleración, como se observa en la Figura 23. Además, en la Tabla 3 se pueden observar especificaciones de interés del sistema, como la frecuencia de muestreo, ancho de banda, etc.

#### Figura 23.

Partes del dispositivo Polar H10.



Nota: Módulo de adquisición, filtrado y transmisión (a) y banda flexible con electrodos secos para medición y protección contra ruido eléctrico (b). Imagen adaptada de *Polar H10 Heart Rate Sensor System*, por Polar, 2019, Polar Research and Technology

**Tabla 3.**  
*Especificaciones técnicas, dispositivo Polar H10.*

Descripción	Especificación
Tiempo de autonomía	400 horas
Temperatura de operación	-10°C a 50°C
Impedancia de entrada	2 MΩ
Ancho de banda	0.7 a 40 Hz
Frecuencia de muestreo	130 Hz $\pm$ 2 % ( $T_{amb} = +20 \dots +40 \text{ }^\circ\text{C}$ )

Nota: Información adaptada de *Polar H10 Heart Rate Sensor System*, por Polar, 2019, Polar Research and Technology

En cuanto al dispositivo Polar OH1 (ver Figura 24), este corresponde a una banda para el antebrazo o brazo que permite la medición continua de la frecuencia cardiaca de un sujeto mediante señales fotopletismográficas (PPG). Este dispositivo, emplea una tecnología patentada de 6 Leds para la adquisición de las señales PPG y permite, al igual que para el Polar H10, la transmisión continua de dichas señales sin procesar. Además de los sensores PPG, el Polar OH1 cuenta con un sensor de luz ambiental y acelerómetro incluido, con el fin de minimizar los artefactos de movimiento generados por la actividad del usuario (Polar, 2019b).

**Figura 24.**  
*Dispositivo Polar OH1*



Nota: Imagen tomada de *Manual del Usuario, Polar OH1*, por Polar, 2019

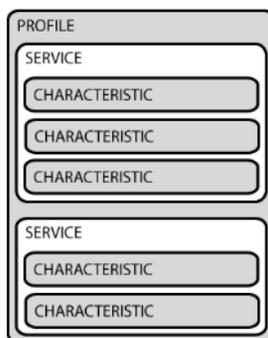
Como se ha explicado anteriormente, los dispositivos wearables presentan como una de sus características principales el envío inalámbrico de información, y sin ser la excepción, los dispositivos Polar se basan en la tecnología Bluetooth Low Energy (BLE) y ANT+ para la comunicación y transmisión de información a un dispositivo central como un teléfono,

computador, etc., siendo el de mayor interés la tecnología BLE para la adquisición continua de las señales fisiológicas.

Bluetooth Low Energy, algunas veces referido como “Bluetooth Smart”, es un subconjunto de la clásica tecnología Bluetooth (Townsend, 2014) y fue introducida como parte de la nueva especificación 4.0, 4.1 y 4.2 de la tecnología Bluetooth desarrollado por Bluetooth Interest Group (SIG). Si bien esta tecnología se basa en el Bluetooth clásico y presenta similitudes con este, BLE debe considerarse como un nuevo estándar enfocados en diversas aplicaciones en donde se requiera la transmisión de pequeñas cantidades de datos y por tanto de ultra-bajo consumo de energía, debido a que el dispositivo únicamente estaría activo cuando se los requiere. Dentro de la tecnología BLE, para establecer un enlace de comunicación, se debe hablar de dos conceptos claves: Generic Access Profile (GAP) y Generic Attribute Profile (GATT). GAP, de forma general, controla la conexión y visibilidad en Bluetooth, determinando como dos dispositivos pueden interactuar entre ellos. Una vez establecida una comunicación entre un dispositivo periférico y un dispositivo central, se emplean servicios y características GATT para la comunicación bidireccional de información. Por su parte, GATT, define la manera en la que dos dispositivos BLE se comunican mediante Servicios y Características embebidos dentro de un objeto de alto nivel denominado Perfil

**Figura 25.**

*Perfil, Servicio y Característica en una comunicación BLE.*



Nota: Imagen tomada de *Introduction to Bluetooth Low Energy*, por Townsend, Kevin, 2014

Un perfil, se lo puede definir como un conjunto lógico predefinido por Bluetooth SIG o por el propio fabricante para agrupar servicios similares en un dispositivo BLE. Un servicio, por otro lado, es otro peldaño de la distribución lógica de información y agrupa un conjunto de características específicas. Un servicio adicionalmente presenta un identificador único denominado UUID que puede ser ya predefinido por Bluetooth SIG como es el caso del Heart Rate Service, Servicio de Ritmo Cardíaco, el cual está identificado por el UUID de 16 bits 0x180D.

Finalmente, una característica BLE es el concepto más bajo de una transacción GATT, el cual encapsula un conjunto único de información, por ejemplo, en el caso de un acelerómetro se agrupan valores de los ejes X/Y/Z dentro de un mismo paquete de datos. De forma similar a los servicios, las características también presentan identificadores únicos UUID que igualmente pueden estar ya predefinidos por Bluetooth SIG o por el fabricante. En el caso de la característica de medida del ritmo cardíaco encontrada dentro del servicio de ritmo cardíaco, el identificador único UUID asociado es el 0x2A37.

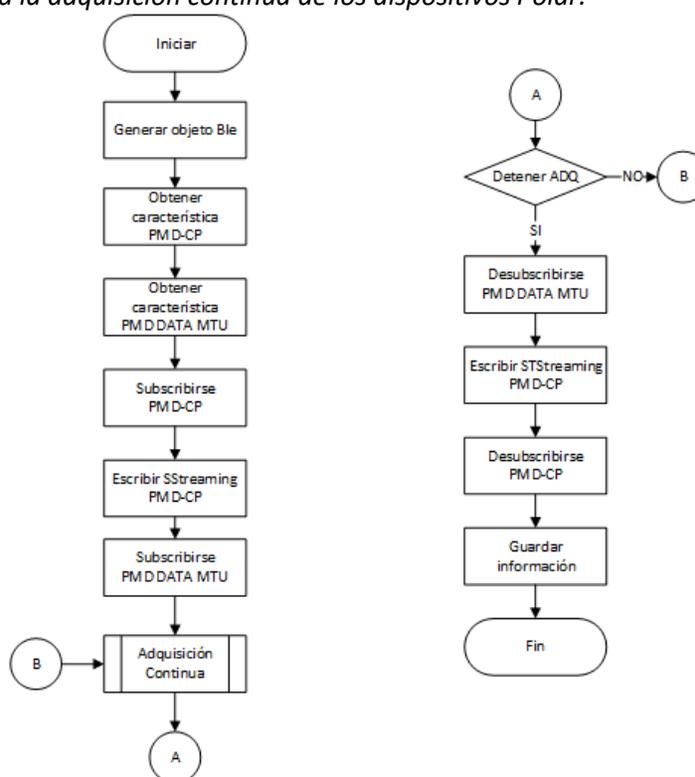
Ahora con estos conceptos, para la adquisición de las señales crudas de los dispositivos Polar, señales PPG, ECG y ACC, Polar definió el servicio PMD, el cual presenta dos características, PMD Control Point (PMD-CP) y PMD Data MTU Characteristic como se observa en la Tabla 4. Se debe destacar que, para maximizar el tiempo de vida de la batería, por defecto los dispositivos Polar no envían las señales crudas de forma continua, sino que se requiere solicitarlo mediante pasos específicos asociados al PMD Control Point, como se observa en el diagrama de flujo de la Figura 26 basado en la documentación entregada por Polar (Polar, s. f.-b). En este diagrama, se observan dos vectores llamadas SStreaming y STStreaming correspondientes a los valores a escribir en el PMD Control Point (PMD CP) para iniciar y finalizar respectivamente el streaming de información. Estos paquetes de datos son asignados en función de la señal fisiológica deseada como se observa en la Tabla 5.

**Tabla 4.**  
Servicio PMD para la comunicación BLE con los dispositivos Polar.

Servicio	Característica	Propiedad	UUID
	NA	NA	FB005C80-02E7-F387-1CAD-8ACD2D8DF0C8
PMD Service	PMD Control Point	Read, Write, Indicate	FB005C81-02E7-F387-1CAD-8ACD2D8DF0C8
	PMD Data MTU Characteristic	Notify	FB005C82-02E7-F387-1CAD-8ACD2D8DF0C8

Nota: Tabla adaptada de *Polar Measurement Data Specifications*, por Polar

**Figura 26.**  
Diagrama de flujo para la adquisición continua de los dispositivos Polar.



**Tabla 5.**  
Valores a escribir en el PMD CP

Señal deseada	SStreaming	STStreaming
ECG	[2, 0, 0, 1, 130, 0, 1, 1, 14, 0]	[3, 0]
PPG	[2, 1, 0, 1, 130, 0, 1, 1, 22, 0, 2, 1, 8, 0]	[3, 1]
ACC	[2, 2, 0, 1, 50, 0, 1, 1, 16, 0, 2, 1, 8, 0]	[3, 2]
PPI	[2, 3]	[3, 3]

Nota: Paquetes de datos enviados para inicializar o finalizar el Streaming de información de los dispositivos Polar. Cada valor separado por una coma corresponde a un grupo de bytes específico

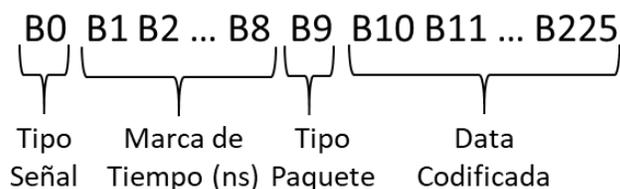
Para el caso del sensor ECG, los valores escritos corresponden a un grupo de bytes definidos de los cuales el byte 5 corresponde a la frecuencia de muestreo (130 Hz) y el byte 9 corresponde a la resolución en bits (14 bits). Para el sensor PPG, se emplea también una frecuencia de muestreo de 130 Hz, pero se tiene una resolución de 22 bits en este caso. Se debe considerar que no todas las señales pueden ser adquiridas por todos los dispositivos, teniéndose para el Polar H10 únicamente las señales electrocardiográficas ECG y del acelerómetro (ACC) y para el dispositivo Polar OH1 el resto con excepción de la señal ECG.

Dentro del subproceso de adquisición continua de datos, Matlab presenta la ventaja de manejar funciones callback, las cuales son ejecutadas en segundo plano únicamente cuando el sensor envía el paquete de datos. Esta funcionalidad fue empleada con el objetivo de adquirir el paquete enviado por los Polar, discriminar el tipo de señal que corresponde, decodificarla y almacenarla como parte de un vector.

Para la decodificación de la información, se debe considerar que llega un paquete de datos en forma de vector con una longitud de 226 valores correspondiente cada uno al valor en decimal de un byte, y se organiza como en la Figura 27.

**Figura 27.**

*Paquete enviado por dispositivos Polar*



El byte 0, como se observa, depende del tipo de señal leída, siendo definido un valor de 0 para la señal ECG, 1 para PPG, 2 para ACC y 3 para PPI. En cuanto a la marca de tiempo, esta se encuentra almacenada en un formato UNIX en nanosegundos. Para decodificar este valor, se considera que el dato se encuentra codificado en formato hexadecimal, y que el vector se

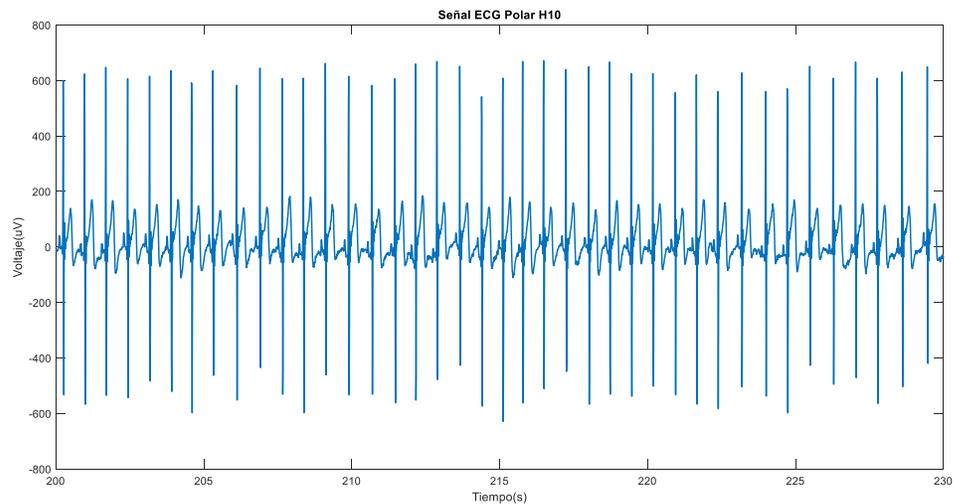
encuentra representado en un formato Little-Endian siendo por tanto el byte 8 el más significativo.

Para la señal ECG, el grupo de datos es subdividido en grupos de 3 bytes, correspondientes cada uno a una muestra de la señal en microvoltios, es decir los 226 bytes de data descrito anteriormente, generan un total de 73 muestras tomadas con un periodo de muestreo de 130 Hz. De esta forma, para la decodificación de la señal ECG, primero se reorganiza el vector de 226 columnas en una matriz de 73 filas, 3 columnas, correspondiendo cada fila a una muestra. Posteriormente, ya que cada columna corresponde a un byte de datos, estos son decodificados en un único valor decimal mediante la relación:

$$V_{ECG} = \text{Byte } 0 + (\text{Byte } 1) * 16^2 + (\text{Byte } 2) * 16^4$$

Si bien, el valor de ECG se encuentra ya en microvoltios, se tiene que considerar que para los valores negativos, los dispositivos Polar emplean complemento a 2 para su representación, por lo que se requirió realizar su correspondiente transformación empleando una xor bit a bit para posteriormente almacenar el valor decimal con signo negativo, obteniéndose la señal ECG de la Figura 28

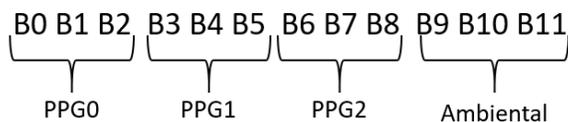
**Figura 28.**  
Señal ECG obtenida del dispositivo Polar H10



Por otro lado, para la decodificación de la señal PPG por otro lado, el paquete de 226 bytes se debe subdividir en grupos de 12, siendo generado un total de 18 muestras por cada paquete de datos. Estos 12 bytes a su vez se encuentran distribuidos como se muestra en la Figura 29, observándose que el dispositivo Polar OH1 envía la información de cada uno de los sensores PPG que posee, incluyendo la señal proporcional a la luz ambiental.

**Figura 29.**

*Subdivisión paquete enviado por dispositivos Polar OH1*

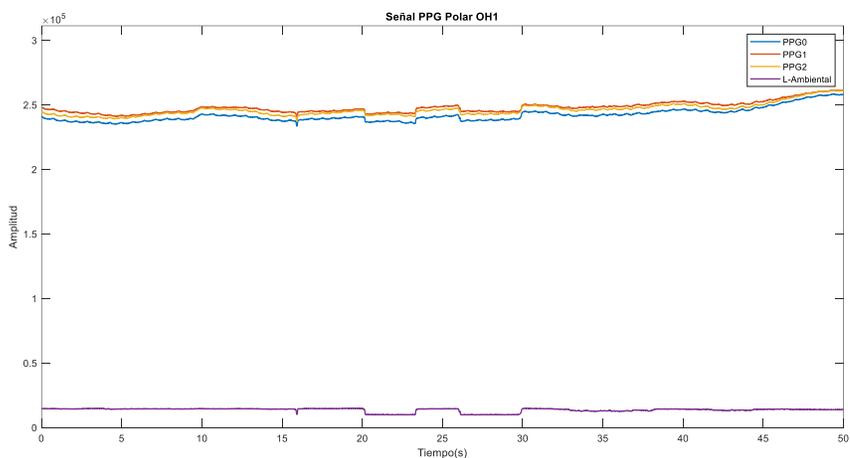


La decodificación es similar a la mostrada con la señal ECG, con la diferencia de que no se tienen valores negativos de la señal por lo que la transformación a complemento a dos no es necesaria.

En la Figura 30, se puede observar las cuatro señales sin procesar obtenidas del dispositivo Polar OH1, destacándose que inicialmente no se distingue la señal PPG deseada, y que ciertas variaciones de la luz ambiental generan cambios en las señales de fotoplestismografía.

**Figura 30.**

*Señal PPG original obtenida del dispositivo Polar OH1*

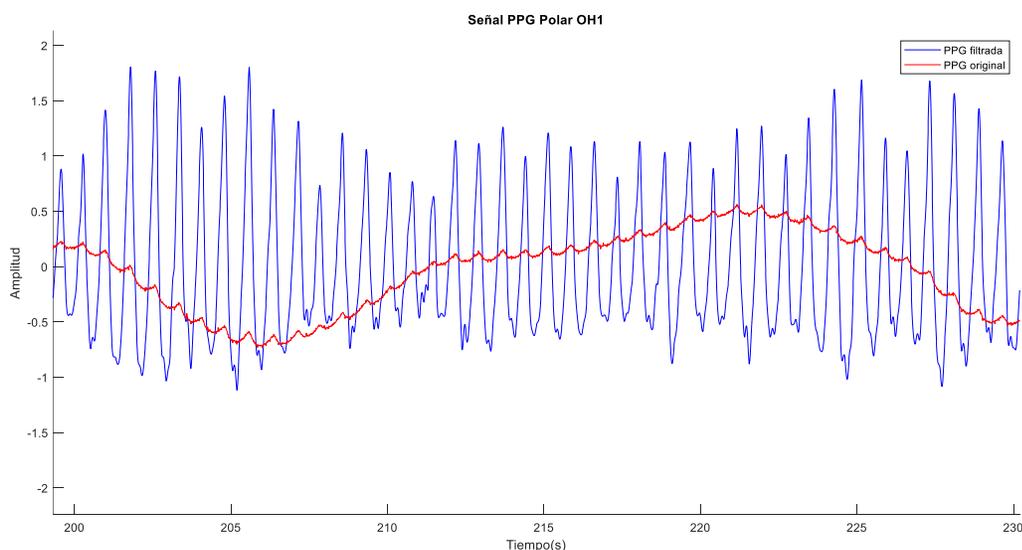


Nota: Señales PPG0 (azul), PPG1 (rojo), PPG2 (amarillo) y luz ambiental (morado) adquiridas por el dispositivo Polar OH1.

Para verificar si las señales del dispositivo Polar OH1 estaban correctamente adquiridas y decodificadas, se procedió a aislar la señal de un único sensor PPG en una ventana más corta de tiempo y se aplicó un preprocesamiento simple basado en promediar las tres señales PPG y aplicar un filtro pasabanda con una banda de paso entre 0.5Hz a 8Hz, obteniéndose las señales observadas en la Figura 31.

**Figura 31.**

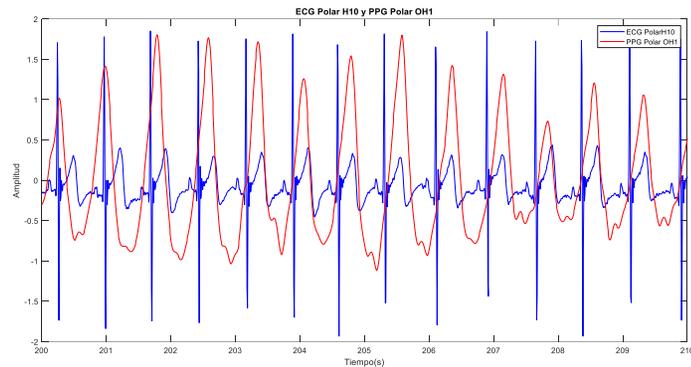
*Señal PPG sin procesar y filtrada del dispositivo Polar OH1*



Nota: En color rojo se observa la señal inicial de sensor PPG0 y en azul la señal filtrada, observándose el efecto de ruido de baja frecuencia en la señal PPG

Si bien la señal PPG filtrada presenta aún ruido, su forma es distinguible y al contraponer con la señal ECG, se observa su alta correlación con los picos R, como se observa en la Figura 32, destacándose que para el momento de dicha adquisición de prueba la sincronización de las señales y preprocesamiento no se encontraban implementadas por lo que existe ruido y un desfase ligero entre ambas señales.

**Figura 32.**  
*Señal ECG y PPG obtenidas de los dispositivos Polar*



Nota: Señal ECG en color azul adquirida por el dispositivo Polar H10 y señal PPG en color rojo adquirida por el dispositivo Polar OH1

#### **Garmin VivoSmart 4**

El dispositivo VivoSmart4, Figura 33, es un reloj inteligente desarrollado por la empresa Garmin (Garmin Ltd., 2018), enfocado para dar seguimiento de parámetros fisiológicos de todo tipo de usuarios por lo que presenta funcionalidades clave como monitoreo de sueño, saturación de oxígeno en sangre, monitoreo del nivel de estrés y ritmo cardiaco, además de otras funcionalidades de conectividad como la visualización de mensajes de texto enviados al teléfono sincronizado. Adicional, el VivoSmart4 permite dar seguimiento a diversas actividades físicas, cronometrándolas y adquiriendo parámetros como ritmo cardiaco, número de repeticiones o calorías quemadas, entre otros, para posteriormente enviarlos a la plataforma de Garmin llamada GarminConnect

**Figura 33.**  
*Dispositivo Garmin VivoSmart4*



Nota: Imagen tomada de *Garmin vivosmart® 4 | Fitness Activity Tracker | Pulse Ox*, por Garmin Ltd., 2018

El VivoSmart4, al igual que la pulsera Polar OH1, basa su tecnología de adquisición de señales fisiológicas en el uso de fotopletimografía por reflexión, y cuenta con sensores de aceleración y luz ambiental para disminuir el efecto de ruido por movimiento. Sin embargo, se debe destacar que la empresa Garmin no permite la transmisión de la señal no procesada, y únicamente hace disponible el envío de los parámetros fisiológicos hacia Garmin Connect mediante una aplicación móvil propia.

El hecho de que la información de Garmin sea tan restringida, limitó las opciones para la obtención de los datos de forma simultánea junto a los otros dispositivos. Para solucionar esta cuestión, se empleó como alternativa el iniciar una actividad en el dispositivo Garmin VivoSmart4, realizar la adquisición de datos y finalizar la actividad de forma manual. Una vez finalizada la adquisición, se descargó, descomprimió y decodificó la data directamente de la plataforma de Garmin mediante la API de conexión desarrollada en Python por (Klinkien, s. f.) y el programa de decodificación desarrollado por (Candocia, 2017). Este último paso se requirió debido a que Garmin posee su propia extensión y protocolo de almacenamiento denominados archivos FIT.

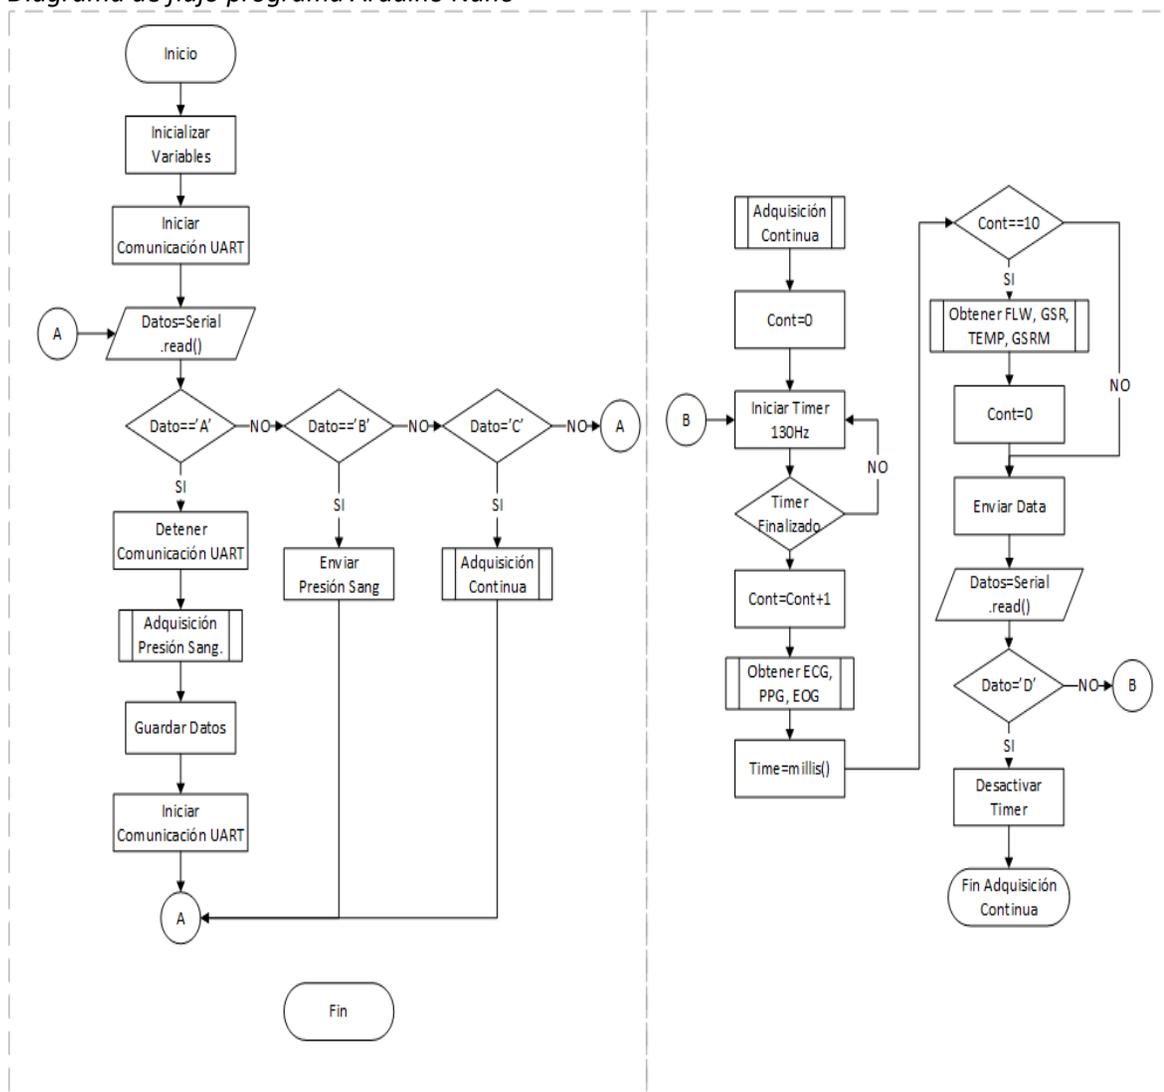
### **Software de integración**

Una vez realizado el diseño de la plataforma multisensado, además de diferentes pruebas para la adquisición de señales de los dispositivos wearables, se procedió a diseñar el software requerido para la adquisición síncrona de todas las señales. Para ello, los programas realizados fueron orientados para el controlador de la plataforma multisensado y para generar una interfaz gráfica que permita el inicio, parado y guardado de la información obtenida en cada adquisición en un paciente.

#### ***Programa para la adquisición de señales***

Para la adquisición simultánea de las ocho señales provenientes de la plataforma multisensado, PPG, FLW, GSR, EOGV y EOGH de los módulos diseñados y ECG, GSR y Temperatura de la plataforma MySignalsHW, se diseñó un programa para el controlador Arduino Nano, el cual de forma general inicializa la comunicación con la plataforma MySignals, adquiere las señales analógicas de los módulos externos y envía la información mediante puerto serial al computador central. El diagrama de flujo del programa diseñado se puede observar en la Figura 34.

**Figura 34.**  
**Diagrama de flujo programa Arduino Nano**



Se puede observar que el sistema realiza las diferentes acciones en función del comando enviado por el computador central, siendo los comandos 'A' y 'B' para la adquisición y envío de la información proveniente del sensor de presión sanguínea, y los comandos 'C' y 'D' empleados para la inicialización y finalización de la adquisición del resto de señales.

Para la digitalización de las señales de la plataforma multisensado adquiridas de forma continua, se configuró uno de los temporizadores disponibles en el controlador para activar una interrupción a una frecuencia de 130Hz. Si bien, para las señales de ECG, PPG, EOGV y EOGH, esta

frecuencia corresponde a la frecuencia de muestreo, para las señales FLW, GSR y TEMP, se emplea una frecuencia igual a 13 HZ. A pesar de ello, se debe destacar que el envío de información hacia el computador central sigue realizándose a 130 Hz mediante una cadena que emplea la coma como separador de valores, y se adiciona un valor booleano, llamado OP, que indica si se realizó o no la actualización de los valores de las señales a 13 Hz, como se observa a continuación

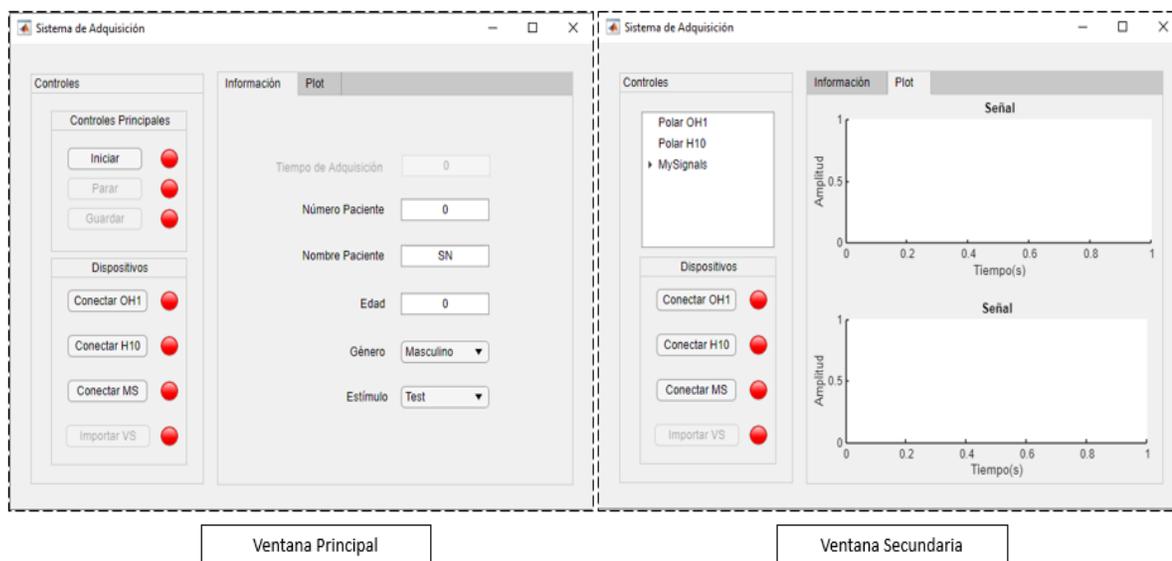
*OP,Time ,ECG ,PPG ,FLW ,EOGV ,EOGH ,GSR ,GSRM ,TEMP*

Esta metodología fue empleada para facilitar la decodificación de la información recibida por el computador y minimizar los tiempos de procesamiento, considerando que los dispositivos Polar también se encuentran enviando de forma continua paquetes de información a ser decodificados y almacenados.

#### ***Interfaz gráfica para la adquisición de señales***

La interfaz de usuario desarrollada en el AppDesigner de Matlab, y presenta tres funcionalidades principales: ingreso de información relevante para la adquisición (número de paciente, nombre, edad, género y tipo de estímulo), verificar las señales de los dispositivos conectados y finalmente controlar el flujo del programa (conectar los dispositivos, iniciar, parar y guardar los datos). Estas tres funcionalidades se encuentran distribuidas en dos ventanas, como se observa en la Figura 35, en donde la verificación en tiempo real de las señales se realiza en la ventana secundaria debido a que es un proceso que se toma en cuenta únicamente antes de comenzar la adquisición de datos.

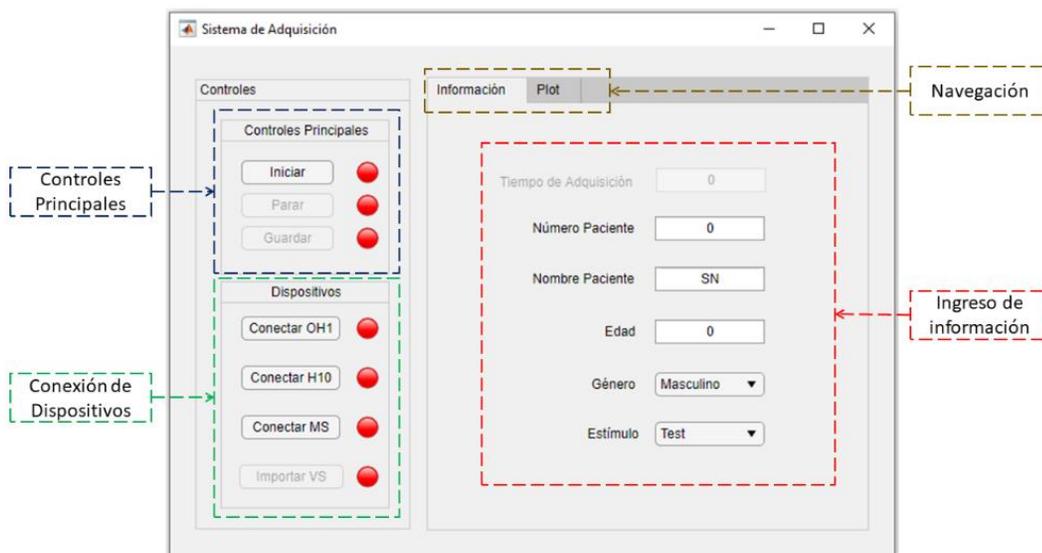
**Figura 35.**  
*Interfaz de usuario*



La ventana principal, cuenta con tres secciones denominadas Controles Principales, Conexión de Dispositivo e Ingreso de información, como se observa en la Figura 36. Además, cuenta con indicadores que permiten visualizar el estado de la adquisición y conexión de los dispositivos.

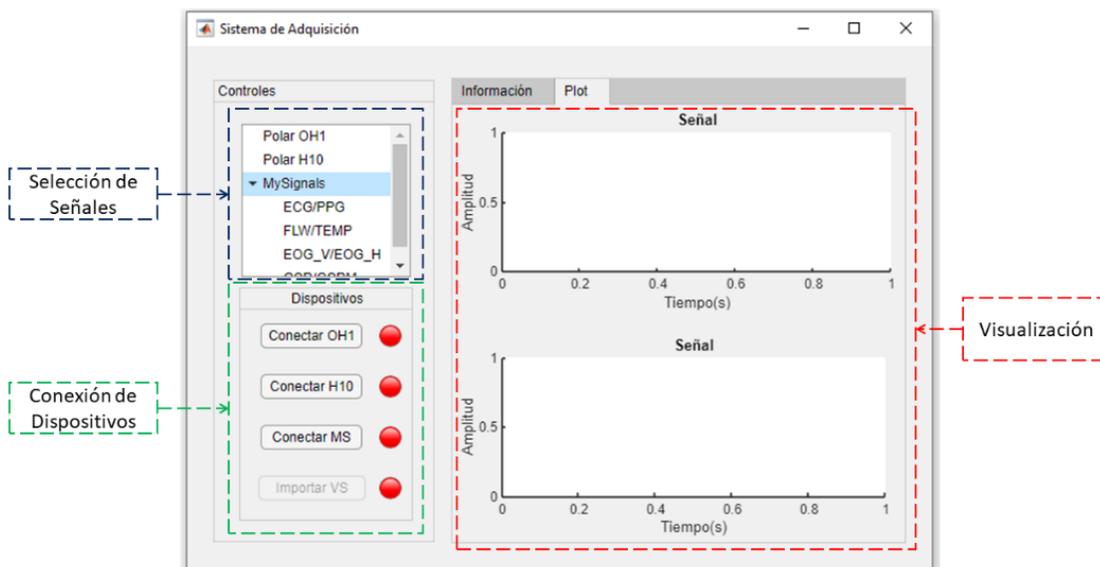
La sección de controles principales se encarga de iniciar y parar la adquisición, además de guardar los datos obtenidos. En la sección de Conexión de Dispositivos, se encuentran los botones para conectarse con los diferentes dispositivos siendo estos el Polar OH1 (botón Conectar OH1), Polar H10 (botón Conectar H10), plataforma MySignals (botón Conectar MS) y el VivoSmart4 (botón Importar VS). De todos estos, cabe destacar que el botón para importar los datos del VivoSmart4 únicamente se habilita una vez parada la adquisición, obteniendo los datos de la plataforma web de Garmin. En la sección de ingreso de información, se ingresan manualmente datos informativos del paciente, como número, nombre, edad, género y estímulo aplicado.

**Figura 36.**  
Ventana principal de la interfaz



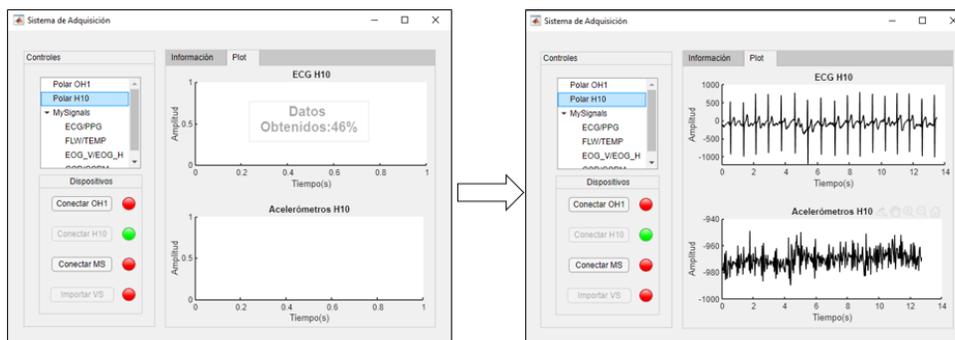
En cuanto a la ventana secundaria, se puede observar en la Figura 37 que, al encargarse de la visualización de las señales previas a la adquisición, consta de una sección de selección y de una sección de visualización.

**Figura 37.**  
Ventana secundaria de la interfaz



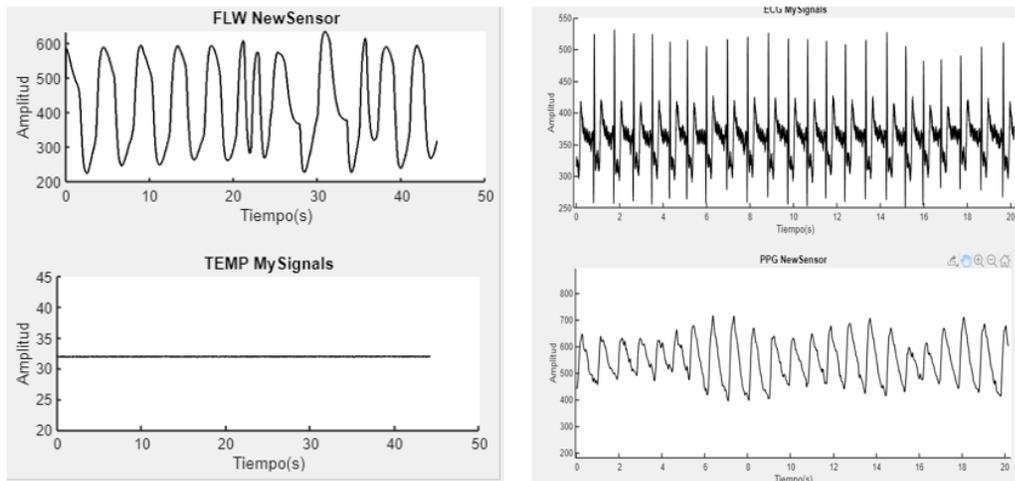
Para los dispositivos Polar, se debe destacar que la visualización de los datos no se realiza en tiempo real, sino que se toman aproximadamente 10 segundos de datos y se grafican en la sección correspondiente, como se observa a modo de ejemplo para el dispositivo Polar H10 en la Figura 38. Esto se realiza debido a que en estos dispositivos no se puede realizar ningún cambio de Hardware o ajuste por lo que una visualización en tiempo real no tiene gran aporte.

**Figura 38.**  
*Visualización señales PolarH10*



Por otro lado, para la plataforma multisensado, al tenerse un hardware ajustable y que depende de factores externos como la posición de los diferentes sensores, si se realiza una visualización en tiempo real. Para ello, se abre una nueva figura que se actualiza a medida que llegan los datos, y para mayor facilidad para manipular la gráfica obtenida, esta se replica en la sección de visualización de la interfaz, como se observa a modo de ejemplo en la Figura 39.

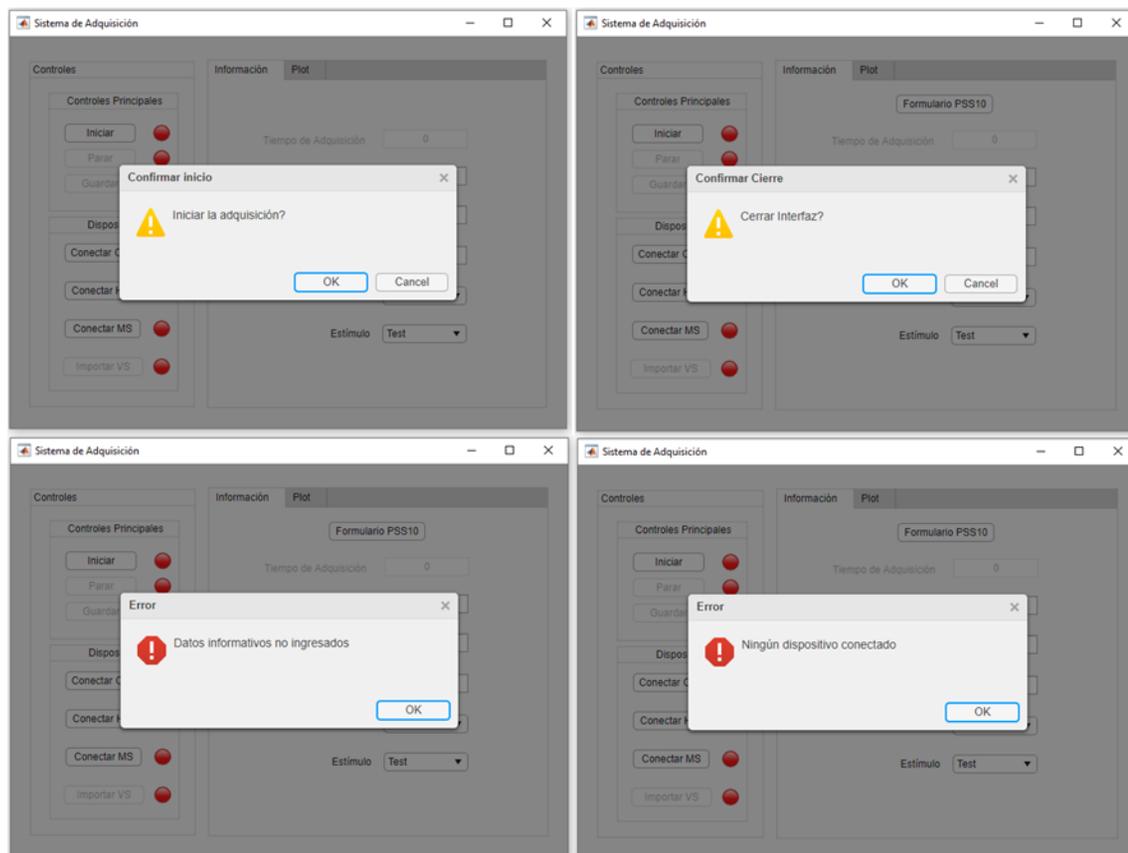
**Figura 39.**  
*Visualización señales de plataforma multisensado*



Nota: Señales FLW, TEMP, ECG y PPG adquiridas de la plataforma multisensado mediante la ventana secundaria de la interfaz gráfica

Se debe mencionar, que adicionalmente se incorporaron mensajes de error e informativas, a modo de ventanas emergentes (Figura 40), para minimizar errores en la adquisición. Este hecho se puede visualizar por ejemplo al iniciar una adquisición y los campos informativos no se encuentran completos, siendo necesario aceptar el cuadro de diálogo para volver a interactuar con la interfaz.

**Figura 40.**  
*Mensajes emergentes de la interfaz*



## Capítulo IV

### Adquisición Y Procesamiento De Las Señales

#### Introducción

Una vez diseñado el hardware y software basado en la plataforma multisensado y los dispositivos wearables, se procedió con la etapa de registro de señales, conformación de la base de datos y procesamiento digital, para posteriormente caracterizar la respuesta fisiológica temporal y frecuencial de un paciente al ser aplicado estímulos audiovisuales.

Este capítulo describe el protocolo de estimulación audiovisual, la estructura empleada para la base de datos y el procedimiento seguido para la extracción de características temporales y frecuenciales de las señales fisiológicas adquiridas

#### Estructura y registro de las señales

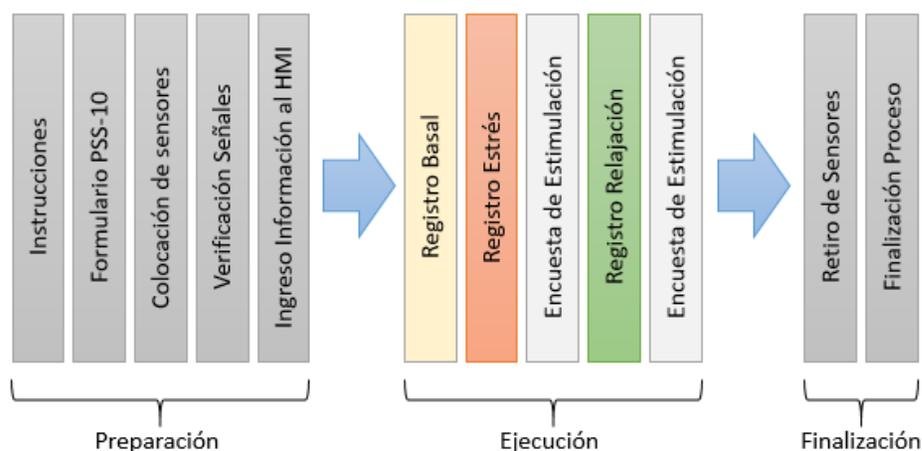
Como explica (Cruz Varela, 2021), para lograr un correcto registro de las señales fisiológicas, se requiere un protocolo de estimulación y adquisición que considere el tipo de estímulo a aplicar, criterios de exclusión y selección de la población, instrumentos de evaluación, entre otros elementos; permitiendo una estandarización del proceso y posterior evaluación objetiva de resultados. En este contexto, para el presente trabajo de investigación se empleó un protocolo de estimulación y adquisición basado en el trabajo de (Cruz Varela, 2021), siendo visualizadas sus tres etapas en la Figura 41.

En la etapa de preparación, se dan instrucciones al paciente sobre el objetivo del proyecto, se anotan sus datos personales y se colocan los diferentes sensores, destacándose que la banda pectoral PolarH10 es el único dispositivo colocado por el propio paciente debido a la ubicación que conlleva. Adicionalmente, dentro de esta etapa se verifica la conexión de los dispositivos y se realiza la calibración de la plataforma multisensado.

Una vez verificadas todas las señales, se procede con la etapa de ejecución, comenzando con el registro basal del paciente durante un tiempo estimado de tres minutos, para pasar posteriormente a la aplicación de los estímulos audiovisuales de estrés y relajación, siendo seleccionados los videoclips “Beautiful relaxing music” de la organización Visit Vestsjælland A/S y la escena de intrusión craneal de la película “Autopsia” del director Adam Gierasch para inducir emociones positivas y negativas respectivamente. Se debe mencionar que, previa y posteriormente a la adquisición continua de las señales, se ingresan los datos de saturación de oxígeno, pulsaciones por minuto y presión sanguínea del sujeto de prueba.

Una vez finalizada la estimulación, en la etapa final, se verifica que la data haya sido correctamente almacenada y se procede a retirar los sensores del cuerpo del paciente para su posterior descarte o desinfección.

**Figura 41. Procedimiento para el registro de señales fisiológicas**



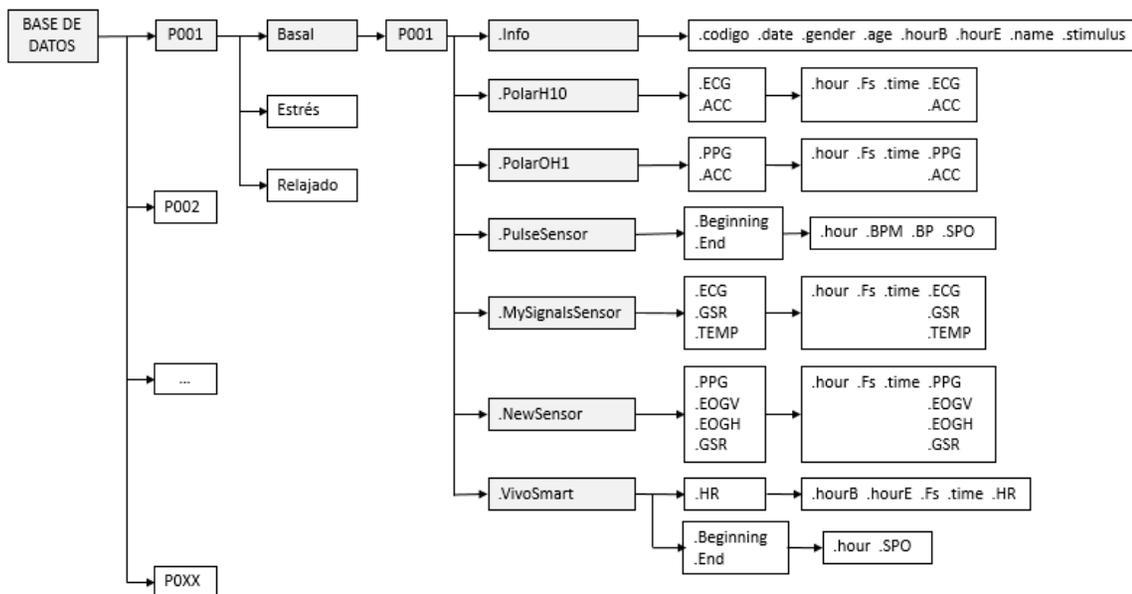
Nota: Procedimiento basado del trabajo de investigación de *Análisis de la correlación de estímulos auditivos y audiovisuales con el sistema cardiorrespiratorio de sujetos sanos*, por Cruz Varela, 2021, Universidad de las Fuerzas Armadas – ESPE

Para la conformación de la base de datos, se realizó el registro de un total de siete sujetos sanos, 3 hombres y 4 mujeres con edades comprendidas entre los 19 y 52 años, siguiendo el

protocolo descrito, adquiriéndose un total de 11 señales fisiológicas, ECG (MySignals y PolarH10), PPG (NewSensor y PolarOH1), FLW, GSR (MySignals y NewSensor), EOGV, EOGH, TEMP y HR (VivoSmart4), siendo distribuida la información en función del código de paciente y tipo de estímulo aplicado como se observa en la estructura de la Figura 42.

**Figura 42.**

*Organización de la base de datos*

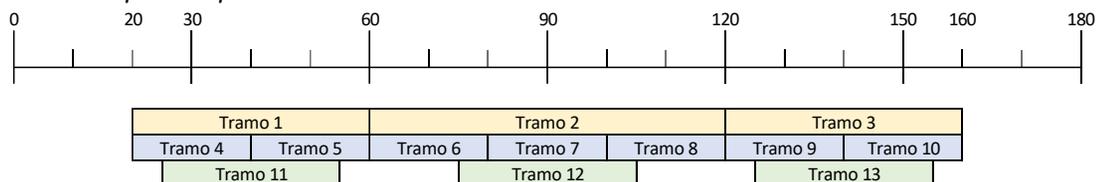


### Procesamiento digital de las señales fisiológicas

Una vez adquiridas y almacenadas las señales fisiológicas de interés en la base de datos, se continuó con su procesamiento digital, reduciéndose las componentes de ruido no deseado y caracterizando su respuesta temporal y frecuencial. Dentro de las señales consideradas en este apartado, se excluye la señal de ritmo cardíaco del dispositivo Garmin VivoSmart4 debido a que esta no requiere de un procesamiento adicional al ser un parámetro cardíaco ya calculado por el propio dispositivo. Además, se debe mencionar que la extracción de características fue realizada en trece tramos temporales observados en la Figura 43, con el fin de determinar posteriormente cual es la sección temporal que mejor permite discriminar entre los tres estados emocionales del paciente (basal, estrés o relajación).

**Figura 43.**

*Tramos temporales para la extracción de características*

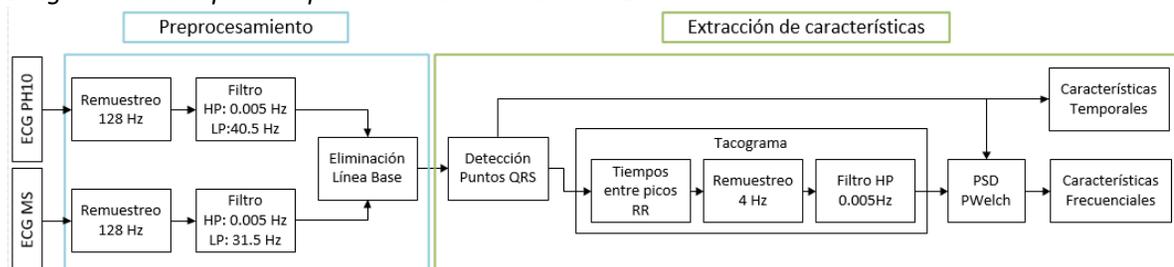


### **Procesamiento de la señal ECG**

Para la señal ECG, en la Figura 44 se presentan las etapas de preprocesamiento y extracción de características tanto para el ECG de la plataforma multisensado como para el dispositivo PolarH10

**Figura 44.**

*Diagrama de bloques del procesamiento de la señal ECG*

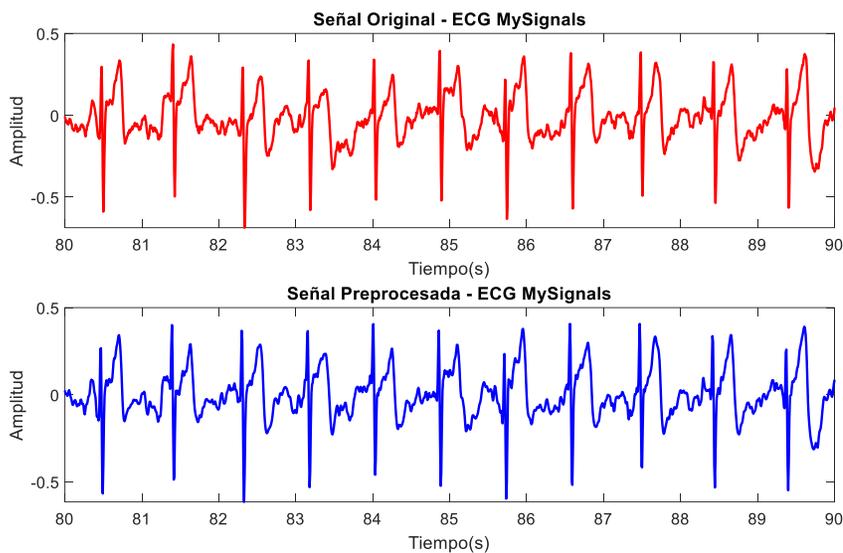


Para el preprocesamiento, se remuestrea la señal ECG a una frecuencia de 128 Hz, como primer paso, debido a que las muestras obtenidas tanto por la plataforma MySignals como por el dispositivo Polar no eran equidistantes y presentaban una variación de  $\pm 2\%$  de la frecuencia original de 130 Hz. Posteriormente se procedió a aplicar un filtro pasabanda digital tipo IIR Butterworth doble pasada compuesto por un filtro pasaalto ( $F_{P_{aro}} = 0.0001 \text{ Hz}$ ,  $F_{P_{aso}} = 0.005 \text{ Hz}$ ) en cascada con un filtro pasabajos ( $F_{P_{aso}} = 31.5 \text{ Hz}$ ,  $F_{P_{aro}} = 32 \text{ Hz}$ ), ambos con una rizado de banda de paso de 1 dB y atenuación de la banda de paro de 40 dB. Por último para esta etapa, basándose en el trabajo de (Betancourt Mediavilla & Yépez Narváez, 2018), se realizó la eliminación de la línea base de la señal ECG, obteniéndose las señales observadas en la Figura 45 para la plataforma MySignals y en la Figura 46 para el dispositivo PolarH10. Se debe acotar que para la señal del PolarH10, el filtro pasabajos empleado tenía una frecuencia de paso de 50 Hz y

una frecuencia de paro de 50.5 Hz debido a que, a las frecuencias originales, la señal se distorsionaba.

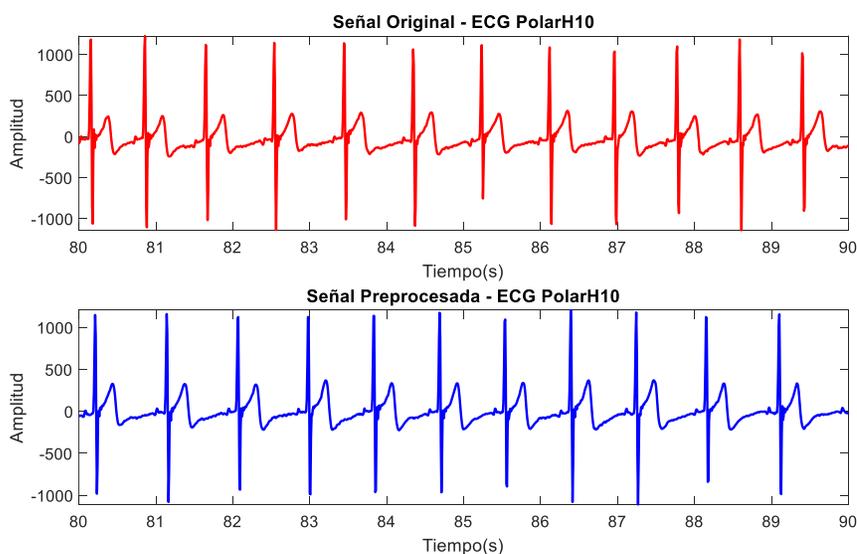
**Figura 45.**

*Señal ECG original y preprocesada, MySignals*



**Figura 46.**

*Señal ECG original y preprocesada, Polar H10*



Una vez concluido el preprocesamiento, se continuó con la etapa de extracción de características, siendo esencial en este punto la detección de los complejos QRS, sobre todo de los picos R, de la señal ECG mediante el algoritmo de Pan Tompkins modificado en la investigación

doctoral de (Arcentales Viteri, 2015). La detección de los intervalos R-R permite extraer una serie de características temporales basadas en la construcción del tacograma, definido en función de la variación de intervalos R-R sucesivos. En cuanto a las características frecuenciales, estas fueron obtenidas mediante la estimación de la densidad espectral de potencia a partir del periodograma de Welch tanto de la señal ECG como del tacograma, de acuerdo al trabajo desarrollado por (Arcentales V et al., 2021). En la Tabla 6 se presentan todas las características temporales y frecuenciales extraídas junto a una descripción de cada una.

**Tabla 6.**

*Características temporales y frecuenciales señal ECG*

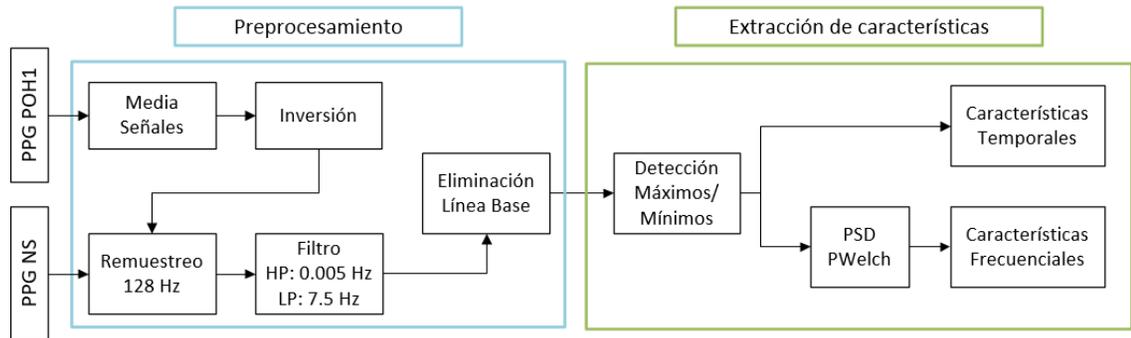
No	Tipo	Nombre	Descripción
1	Temporal	mBT1	Duración media del tiempo entre latidos en ms
2		BPM	Latidos por minuto
3		SSDN	Desviación estándar del tiempo entre latidos en ms
4		RMSSD	Valor RMS del tiempo entre latidos en ms
5		mQRSA	Media de la amplitud del complejo QRS en mV
6		sQRSA	Desviación estándar de la amplitud del complejo QRS en mV
7	Frecuencial	FMP	Frecuencia del mayor pico de potencia de la señal ECG en Hz
8		MP	Valor de potencia pico del espectro de la señal ECG
9		FMPt	Frecuencia del mayor pico de potencia del tacograma en Hz
10		MPT	Valor de potencia pico del espectro del tacograma
11		VLF	Potencia media del espectro del tacograma en la banda VLF
12		LF	Potencia media del espectro del tacograma en la banda LF
13		HF	Potencia media del espectro del tacograma en la banda HF
14		LF/HF	Ratio de potencia entre LF/HF

Nota: Los valores picos y medios de potencia se encuentran en unidades normalizadas

***Procesamiento de la señal PPG***

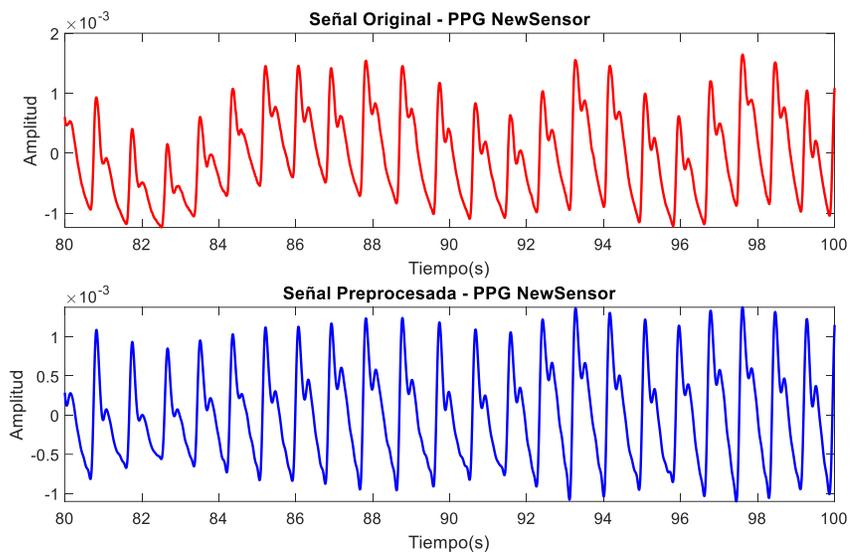
Para la señal PPG, en la Figura 47 se presentan las etapas de preprocesamiento y extracción de características tanto para la señal PPG de la plataforma multisensado como para el dispositivo PolarOH1

**Figura 47.**  
Diagrama de bloques del procesamiento de la señal PPG

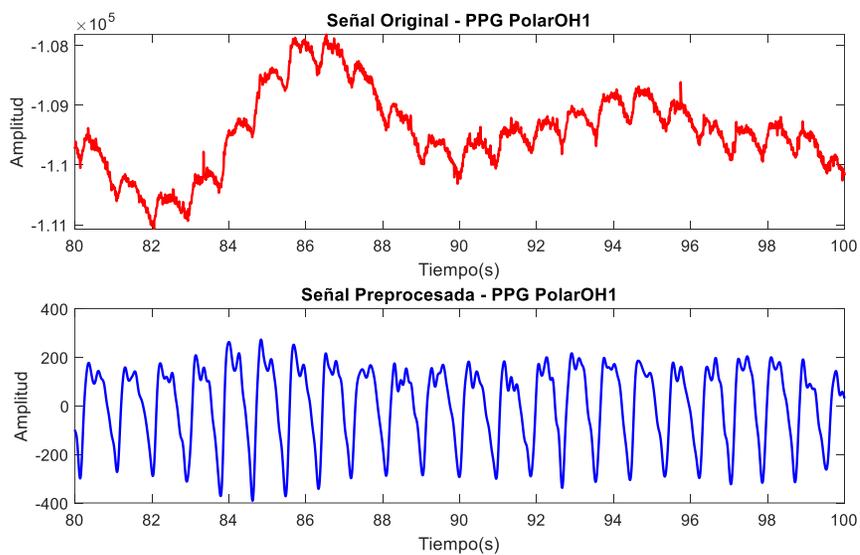


Para el preprocesamiento, similar al aplicado a la señal ECG, se remuestrea la señal PPG a una frecuencia de 128 Hz, debido a que las muestras obtenidas tanto por la plataforma multisensado como las registradas con el dispositivo Polar no eran equidistantes y presentaban variaciones de la frecuencia original de 130Hz. Posteriormente se procedió a aplicar un filtro pasabanda digital tipo IIR Butterworth doble pasada compuesto por un filtro pasaalto ( $F_{Paso} = 0.0001 \text{ Hz}$ ,  $F_{Paso} = 0.005 \text{ Hz}$ ) en cascada con un filtro pasabajos ( $F_{Paso} = 7.5 \text{ Hz}$ ,  $F_{Paso} = 8 \text{ Hz}$ ), ambos con una rizado de banda de paso de 1dB y atenuación de la banda de paro de 20 dB. Por último, se realizó la eliminación de la línea, obteniéndose las señales observadas en la Figura 48 para la plataforma multisensado y en la Figura 49 para el dispositivo PolarOH1. Adicionalmente, se debe considerar que, para el dispositivo de Polar, previo al remuestreo, se realizó el promediado de las tres señales PPG con el fin de reducir problemas derivados por cambios en la luz ambiental y movimiento del usuario. Además, esta señal fue posteriormente invertida al considerar que la tecnología PPG es de transmisión.

**Figura 48.**  
Señal PPG original y preprocesada, NewSensor



**Figura 49.**  
Señal PPG original y preprocesada, PolarOH1



En cuanto a la extracción de características temporales, estas fueron obtenidas principalmente en función de la detección de los puntos de máxima sístole y mínima diástole correlacionados a los intervalos R-R de la señal ECG. Por otro lado, para las características frecuenciales, nuevamente se realiza la estimación espectral de potencia mediante el

periodograma de Welch, observándose finalmente en la Tabla 7 una descripción de las características extraídas.

**Tabla 7.**

*Características temporales y frecuenciales señal PPG*

No	Tipo	Nombre	Descripción
1		BPM	Latidos por minuto
2		SST	Duración media del tiempo entre latidos en ms
3		sdSST	Desviación estándar del tiempo entre latidos en ms
4	Temporal	BPA	Media de la amplitud estimada entre el punto de mínima diástole y máxima sístole en mV
5		sdBPA	Desviación estándar de los cambios de volumen sanguíneo en mV
6	Frecuencial	FMP	Frecuencia del mayor pico de potencia de la señal PPG en Hz
7		MP	Valor de potencia pico del espectro de la señal PPG

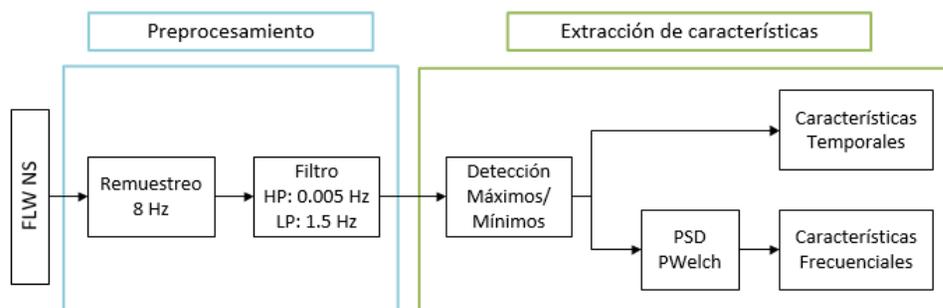
Nota: El valor pico de potencia se encuentran en unidades normalizadas

**Procesamiento de la señal FLW**

La señal de flujo respiratorio, obtenida a partir del módulo desarrollado para el presente trabajo y del sensor de la plataforma MySignals, fue procesada de acuerdo al diagrama de bloques de la Figura 50, observándose que para la etapa de preprocesamiento no se realiza la eliminación de la línea base, y que la extracción de características es similar al empleado para la señal de fotopletimografía

**Figura 50.**

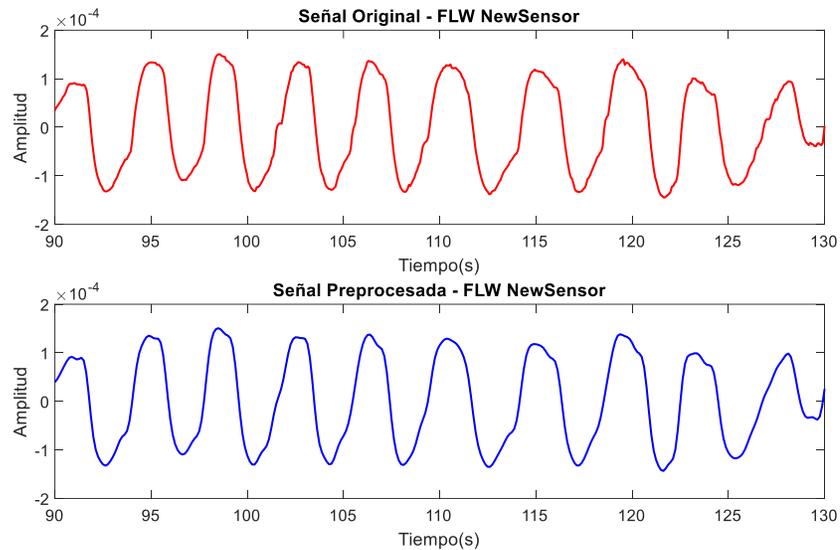
*Diagrama de bloques del procesamiento de la señal FLW*



El preprocesamiento de la señal FLW consistió únicamente en remuestrearla a una frecuencia de 8Hz para posteriormente aplicar un filtrado pasabanda digital tipo IIR Butterworth.

Este filtro, igual que para las señales anteriores, está compuesto por un filtro pasaalto ( $F_{Paso} = 0.0001 \text{ Hz}$ ,  $F_{Paso} = 0.005 \text{ Hz}$ ) en cascada con un filtro pasabajos ( $F_{Paso} = 1.5 \text{ Hz}$ ,  $F_{Paso} = 2 \text{ Hz}$ ), ambos con una rizado de banda de paso de 1dB y atenuación de la banda de paro de 20 dB. En la Figura 51, se puede apreciar la disminución de la componente de ruido de la señal original tras ser preprocesada.

**Figura 51.**  
*Señal FLW original y preprocesada, NewSensor*



Con la señal preprocesada, las características temporales fueron calculadas en función de la detección de los puntos máximos y mínimos relacionados a los ciclos de inspiración-espирación. En cuanto a las características frecuenciales, nuevamente se realiza la estimación espectral de potencia mediante el periodograma de Welch, observándose finalmente en la Tabla 8 una descripción de las características extraídas.

**Tabla 8.**  
*Características temporales y frecuenciales señal FLW*

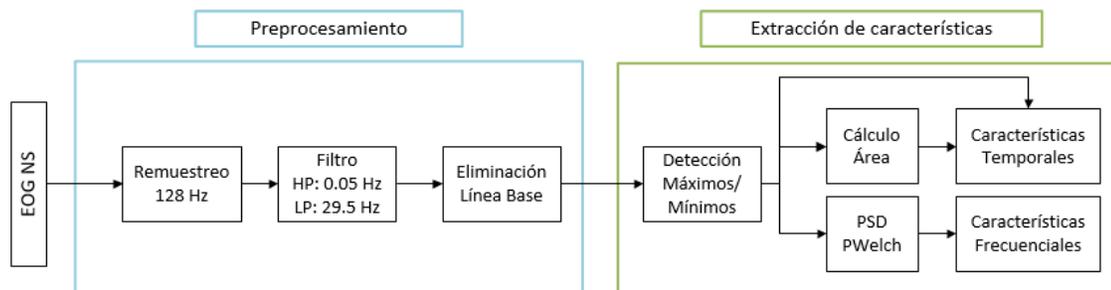
No	Tipo	Nombre	Descripción
1		RPM	Respiraciones por minuto
2		TTot	Duración media del tiempo entre máximos inspiratorios en ms
3		sdTTot	Desviación estándar del tiempo entre respiraciones en ms
4	Temporal	FLWA	Media de la amplitud estimada entre el punto de mínima espiración y máxima inspiración en mV
5		sdBPA	Desviación estándar de las amplitudes de las respiraciones en mV
6	Frecuencial	FMP	Frecuencia del mayor pico de potencia de la señal FLW en Hz
7		MP	Valor de potencia pico del espectro de la señal FLW

Nota: El valor pico de potencia se encuentran en unidades normalizadas

### **Procesamiento de la señal EOG**

Para la señal EOG, en la Figura 52 se presentan las etapas de preprocesamiento y extracción de características, considerando que ambos procedimientos son similares para el canal vertical y horizontal. Este procesamiento se realizó basándose en el trabajo de (Arcentales V et al., 2021).

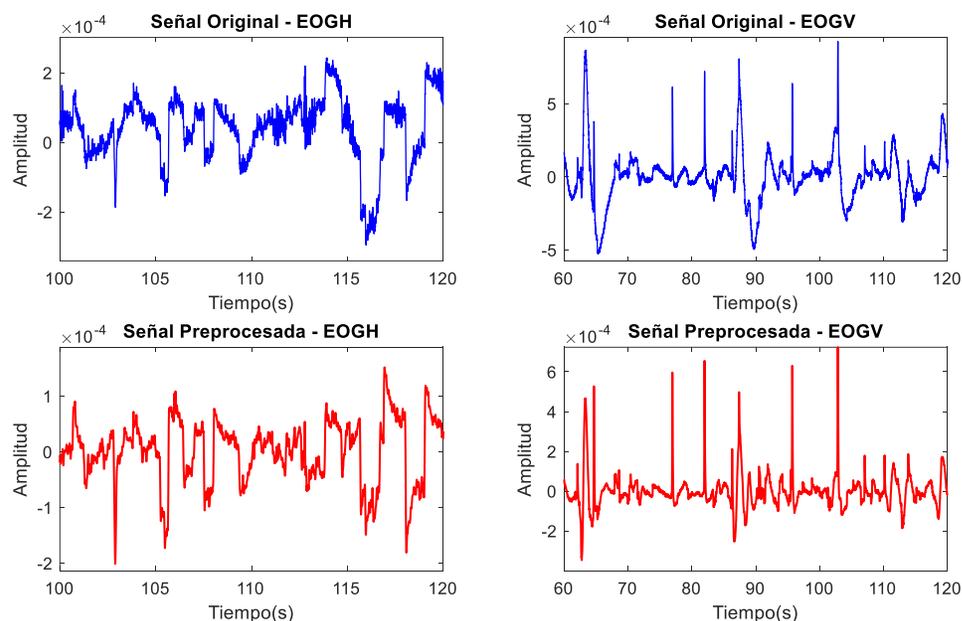
**Figura 52.**  
*Diagrama de bloques del procesamiento de la señal EOG*



Para el preprocesamiento, se remuestrea la señal EOG a una frecuencia de 128 Hz, debido a que las muestras obtenidas del módulo desarrollado acoplado a la plataforma multisensado no eran equidistantes y presentaban variaciones de la frecuencia original de 130Hz. Posteriormente se procedió a aplicar un filtro pasabanda digital tipo IIR Butterworth doble pasada compuesto por un filtro pasaalto ( $F_{Paso} = 0.001 \text{ Hz}$ ,  $F_{Paso} = 0.05 \text{ Hz}$ ) en cascada con un filtro pasabajos ( $F_{Paso} = 29.5 \text{ Hz}$ ,  $F_{Paso} = 30 \text{ Hz}$ ), ambos con una rizado de banda de paso de 1dB y atenuación

de la banda de paro de 40 dB. Por último, se realizó la eliminación de la línea base, obteniendo las señales observadas en la Figura 53 para el canal vertical y horizontal de la señal electrooculográfica. En estas gráficas, se debe apreciar la reducción del ruido de alta frecuencia, especialmente de 60 Hz, presente por efecto de la red eléctrica, siendo notorio principalmente en la señal EOGH.

**Figura 53.**  
*Señal EOGV original y preprocesada, NewSensor*



Con la señal EOG preprocesada, se procedió a caracterizar su respuesta temporal mediante la detección de los puntos máximos y mínimos y al cálculo del área comprendida entre ellos. Se debe mencionar que para la señal EOGV estos picos de señal corresponden al parpadeo del sujeto, y que para la señal de EOGH corresponden a movimientos laterales del ojo.

En cuanto a las características frecuenciales, se realiza la estimación espectral de potencia mediante el periodograma de Welch, observándose finalmente en la Tabla 9 una descripción de las características extraídas.

**Tabla 9.**  
*Características temporales y frecuenciales señal EOG*

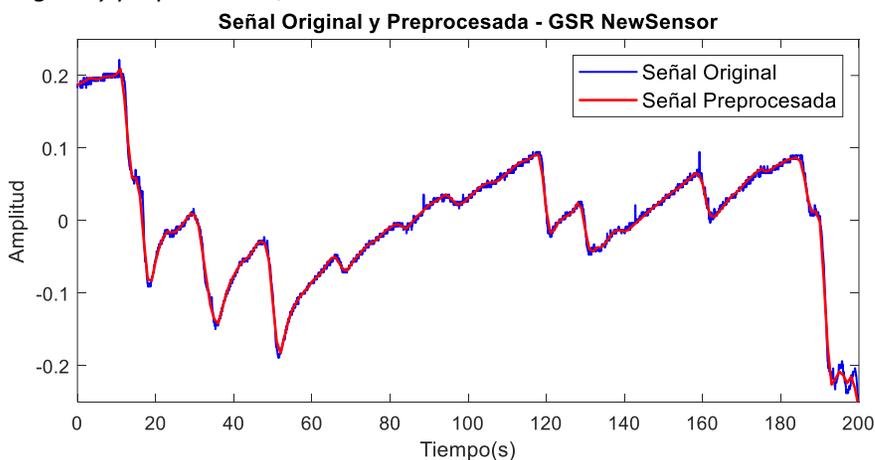
No	Tipo	Nombre	Descripción
1		PPM	Picos por minuto
2		mTToT1	Duración media del tiempo entre máximos en ms
3	Temporal	sdTToT1	Desviación estándar del tiempo entre máximos en ms
4		mEOGA1	Media del área de los picos en mV
5		sEOGA1	Desviación estándar del área de los picos en mV
6	Frecuencial	FMP	Frecuencia del mayor pico de potencia de la señal EOG en Hz
7		MP	Valor de potencia pico del espectro de la señal EOG

Nota: El valor pico de potencia se encuentran en unidades normalizadas

### **Procesamiento de la señal GSR**

A diferencia del proceso seguido para las señales anteriores, a la señal de respuesta galvánica de la piel, posterior al remuestreo a 1 Hz, se le aplica un suavizado mediante un filtro espacial de Savitzky-Golay de cuarto orden y una ventana de 5 muestras, basándose en el trabajo de (Betancourt Mediavilla & Yépez Narváez, 2018). Se optó por este tipo de suavizado debido a que un filtrado del tipo pasa bajos, similar al descrito en las secciones anteriores, distorsionaba la señal y generaba un notable rizado en ciertos tramos de la misma. Las señales original y preprocesada de GSR se pueden observar en la Figura 54, siendo notorio la reducción de la componente de ruido de la señal mientras su forma no se ve modificada, cuestión a considerar al emplearse filtros espaciales.

**Figura 54.**  
*Señal GSR original y preprocesada, NewSensor*



En cuanto al procesamiento, se extraen como características la pendiente que mejor se ajusta a la señal GSR en un tramo de tiempo, la desviación estándar de la señal y la frecuencia y valor de potencia máxima extraídas a partir de la estimación de la densidad espectral de potencia, de forma similar a la explicada para las otras señales (ver Tabla 10).

**Tabla 10.**

*Características temporales y frecuenciales señal GSR*

No	Tipo	Nombre	Descripción
1		EDAm	Pendiente de ajuste de la señal GSR
2		EDAs	Desviación estándar de la señal GSR en V
3	Frecuencial	FMP	Frecuencia del mayor pico de potencia de la señal GSR en Hz
4		MP	Valor de potencia pico del espectro de la señal GSR

Nota: El valor pico de potencia se encuentran en unidades normalizadas

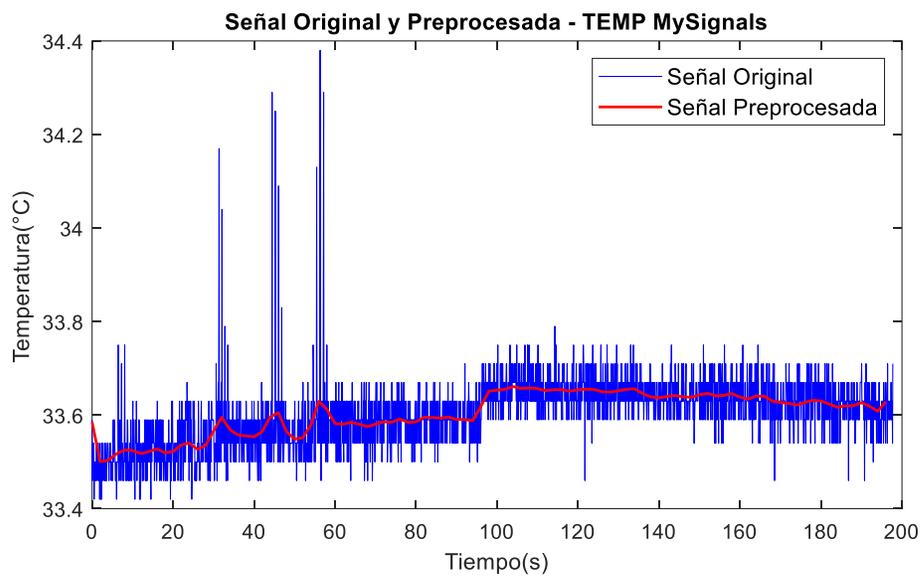
Se debe acotar que, debido a los elevados niveles de ruido que presentaba la señal GSR adquirida por la plataforma MySignals, estas señales registradas fueron descartadas y sólo se emplearon las señales adquiridas por el módulo externo desarrollado por (Grove, 2014).

***Procesamiento de la señal de Temperatura***

Finalmente, para la señal de temperatura corporal (TEMP), el preprocesamiento consistió en el remuestreo a una frecuencia de 0.5 HZ y en la aplicación de un filtro de media móvil con una ventana de 40 muestras, siendo observadas en la Figura 55 una comparativa entre la señal original y la señal preprocesada. Si bien en la gráfica se observa una señal extremadamente ruidosa, se debe considerar la escala, en donde la variación media se encuentra alrededor de 0.1°C

**Figura 55.**

*Señal original y preprocesada de temperatura corporal, MySignals*



En cuanto a la extracción de características, para la señal de temperatura únicamente se extrajo su media y desviación estándar como características temporales al no existir rasgos frecuenciales que puedan verse influenciados en respuesta a un estímulo audiovisual.

## Capítulo V

### Análisis De Resultados

#### Introducción

El trabajo de investigación tiene por objetivo analizar el desempeño de una serie de dispositivos wearables al aplicarlos en estudios de la estimación de estrés, por lo que en este capítulo se realiza un análisis de similitud temporal y frecuencial entre los dispositivos PolarH10 y PolarOH1 respecto a las señales adquiridas por la plataforma multisensado durante el protocolo de estimulación mencionado anteriormente. En cuanto al reloj inteligente VivoSmart4 de Garmin, se realiza una comparación de los estadísticos de las pulsaciones por minuto registradas por este dispositivo y las estimadas de las señales PPG y ECG de la plataforma multisensado.

Posteriormente, se explica el diseño y resultados de una serie de clasificadores diseñados con las características explicadas en la sección de Procesamiento digital de las señales fisiológicas, enfocados en la detección de estados de calma y estrés causados por los estímulos aplicados. Como técnica de machine learning, fue seleccionado el algoritmo de K vecinos más cercanos, K Nearest Neighbors KNN, para la generación de los clasificadores basados en todas las características y en una serie de características estadísticamente relevantes de las señales ECG, PPG, FLW y GSR.

#### Análisis comparativo de dispositivos

##### Polar H10-ECG

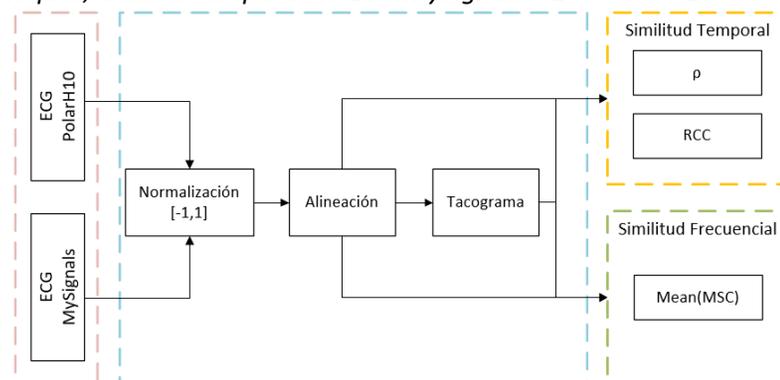
Para el análisis del dispositivo PolarH10, se realiza una comparación de similitud temporal y frecuencial entre su señal ECG y la registrada simultáneamente por la plataforma MySignals durante el protocolo de estimulación descrito. En este contexto, la plataforma MySignals actúa como base referencial al emplear la técnica clásica para adquisición de señales cardíacas basadas

en el uso de tres electrodos húmedos de Ag/AgCl en una derivación, como se explicó en el apartado de Dispositivos estándar para adquisición de señales fisiológicas.

El análisis comparativo realizado, se centra en la extracción de tres índices, dos temporales y uno frecuencial, que describen la similitud entre señales, siendo necesaria previamente la normalización y alineación de las mismas, como se observa en la Figura 56. Para el análisis en el dominio temporal, se aplica el coeficiente de correlación de Pearson ( $\rho$ ) y el coeficiente de correlación relativo (RCC), mientras que para el análisis frecuencial, se estima la media de la magnitud de coherencia cuadrada (MSC). Además, se debe destacar que no solo se analiza la señal electrocardiográfica, sino que su correspondiente señal de tacograma, siendo esta importante para la extracción de parámetros relevantes relacionados con la estimación de estrés, como se observó en la Tabla 6.

**Figura 56.**

*Diagrama de bloques, análisis comparativo ECG MySignals – ECG PolarH10*



Como explica (Grice, 2013), el coeficiente de correlación de Pearson ( $\rho$ ), es una medida de la dependencia lineal entre dos variables  $X$  y  $Y$ , siendo definido en función de la covarianza ( $cov$ ) y de la desviación estándar ( $\sigma$ ) de las señales

$$\rho(X, Y) = \frac{cov(X, Y)}{\sigma_X \sigma_Y} \quad ; \quad -1 \leq \rho \leq 1$$

Si bien, el coeficiente de correlación de Pearson es uno de los más comunes, se buscó otro índice que permita corroborar el valor obtenido, siendo seleccionado el coeficiente de

correlación relativo, RCC por sus siglas en inglés. Este coeficiente fue empleado en la investigación de (Madhav et al., 2010) para determinar el grado de similitud entre la señal FLW referencial y la estimada a partir de la señal de fotopleletismografía, siendo definido en función de la relación entre el valor máximo de correlación cruzada entre dos señales  $R_{XY}(0)$  y el valor máximo de autocorrelación de la señal seleccionada como referencial  $R_{XX}(0)$ . Se debe acotar que para que su aplicación sea adecuada, las secuencias de autocorrelación deben ser normalizadas, obteniéndose un valor de 1 en el retraso cero.

$$RCC = \frac{R_{XY}(0)}{R_{XX}(0)}$$

Para verificar la similitud en el dominio de la frecuencia, se emplea la media de la magnitud de coherencia cuadrada en la banda frecuencial de la señal ECG, siendo en este caso de 0 a 32 Hz. La estimación de la magnitud de coherencia cuadrada (MSC por sus siglas en inglés) es una función continua la cual describe la similitud de la señal  $X$  y  $Y$  en función de la frecuencia. La MSC es la resultante de la relación entre la densidad espectral de potencia cruzada  $P_{XY}(f)$  y las densidades espectrales de potencia  $P_X(f)$  y  $P_Y(f)$  de la señales  $X$  y  $Y$  respectivamente. Se debe acotar que, para la estimación de la densidad espectral de potencia, se emplea el periodograma de Welch.

$$MSC(f) = \frac{|P_{XY}(f)|^2}{P_X(f)P_Y(f)}$$

Definidos los índices de similitud a emplear, para el análisis de desempeño de los dispositivos, se emplea la escala presentada en la Figura 57, considerando cinco intervalos que permiten describir verbalmente el nivel de correlación existente en donde un valor de cero corresponde a una correlación nula y un valor de uno una correlación perfecta (Evans, 1996).

**Figura 57.**

*Escala de correlación sugerida para los coeficientes  $\rho$ , RCC y MSC*

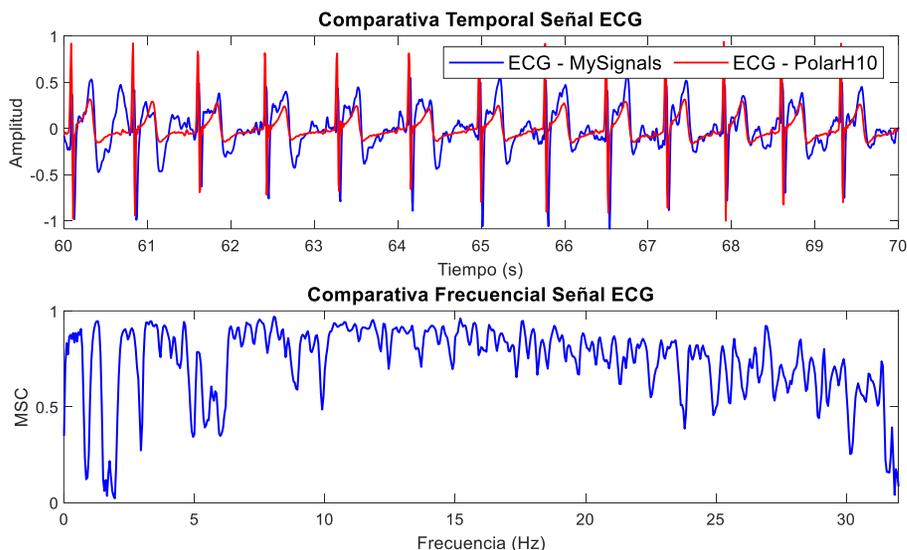
0	0.20	0.40	0.60	0.80	1.00
$0 \leq  \rho  \leq 0.19$	$0.20 \leq  \rho  \leq 0.39$	$0.40 \leq  \rho  \leq 0.59$	$0.60 \leq  \rho  \leq 0.79$	$0.80 \leq  \rho  \leq 1.00$	
Correlación muy débil		Correlación débil		Correlación moderada	Correlación fuerte

Nota: Escala adaptada de *Straightforward statistics for the behavioral sciences*, por Evans, J. D., 1996, Thomson Brooks/Cole Publishing Co.

En la Figura 58, se puede observar las señales superpuestas de ECG de la plataforma multisensado MySignals y del dispositivo wearable PolarH10, además de la gráfica de la estimación de la coherencia de magnitud cuadrada en función de la frecuencia. En la comparativa en el dominio temporal, se debe notar que los picos R-R de ambas señales se encuentran prácticamente superpuestos, sin embargo, se aprecia una considerable variación en los complejos PQ y ST, posiblemente debido a que el PolarH10 no utiliza una derivada estándar para la medición, a diferencia de la plataforma MySignals que utiliza la segunda derivada.

**Figura 58.**

*Comparación temporal / frecuencial PolarH10 - ECG*



En la Tabla 11 se presentan los valores máximos, mínimos y medios de los coeficientes de correlación temporal y frecuencial aplicados a la base de datos para la señal ECG. Se puede visualizar que se tiene una correlación media temporal moderada y una correlación media frecuencial fuerte, de acuerdo a la escala presentada en la Figura 57. Adicionalmente, se debe apreciar que la correlación temporal y frecuencial disminuye para la estimulación de estrés respecto al estado basal y relajado.

**Tabla 11.**

*Índices de similitud temporal / frecuencial PolarH10 - ECG*

Estímulo	Tipo	$\rho$	RCC	MSC
Basal	Max	0,529	0,539	0,743
	Min	0,380	0,380	0,568
	Mean	0,458 $\pm$ 0,062	0,469 $\pm$ 0,069	0,674 $\pm$ 0,075
Estrés	Max	0,456	0,487	0,704
	Min	0,270	0,307	0,623
	Mean	0,361 $\pm$ 0,083	0,414 $\pm$ 0,081	0,655 $\pm$ 0,037
Relajado	Max	0,467	0,502	0,729
	Min	0,401	0,406	0,597
	Mean	0,440 $\pm$ 0,034	0,463 $\pm$ 0,050	0,673 $\pm$ 0,068
Total	Max	0,529	0,539	0,743
	Min	0,270	0,307	0,568
	Mean	0,418 $\pm$ 0,075	0,447 $\pm$ 0,068	0,667 $\pm$ 0,056

Nota: Se presentan marcados los valores máximos y mínimos de correlación total como ayuda visual de los índices de similitud obtenidos

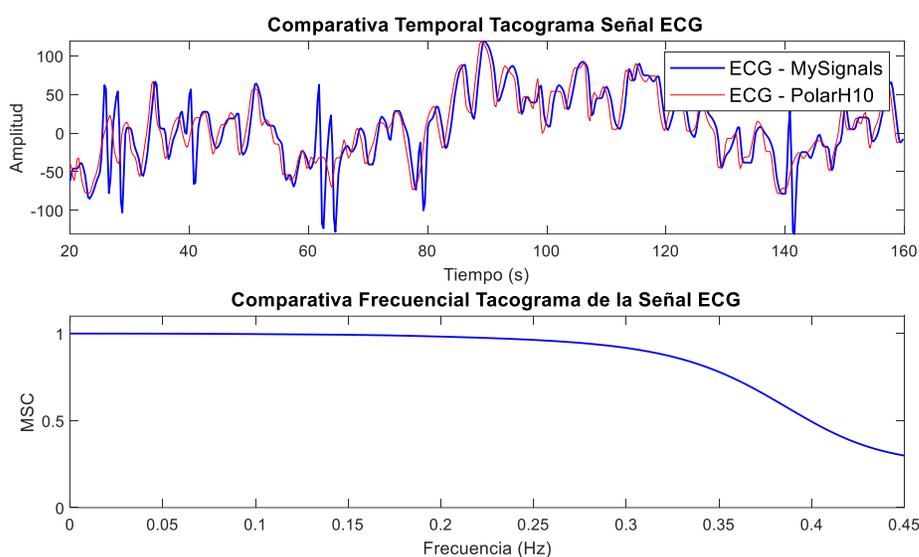
Basándose en el estado del arte desarrollado, se puede apreciar que la señal de variabilidad de ritmo cardíaco supone de interés para el análisis de estrés, por este motivo y observando la gran concordancia de los picos R de las señales del PolarH10 y ECG de la plataforma multisensado, adicional a la comparación de la señal ECG, se extrajo y se comparó temporal y frecuencialmente las señales de tacograma para cada dispositivo. Como se aprecia en la Figura 59, visualmente en el dominio temporal las señales del tacograma son muy similares y en el

dominio frecuencial, se observa un índice elevado de MSC en las bandas VLF (0-0.04 Hz), LF (0.04-0.15 Hz) y parcialmente en la banda HF (0.15-0.4 Hz).

En la Tabla 12, se presentan los valores máximos, mínimos y medios de los coeficientes de correlación temporal y frecuencial para la señal de tacograma derivada del ECG. Se puede visualizar que se tiene una correlación media temporal y correlación media frecuencial muy fuerte, de acuerdo a la escala presentada en la Figura 57. Se debe mencionar además que el valor de MSC observado corresponde a la media de valores comprendidos entre 0 a 0.4 Hz, siendo este rango frecuencial el de interés en estudios de estrés.

**Figura 59.**

*Comparación temporal / frecuencial tacograma extraído del PolarH10 - ECG*



**Tabla 12.**

*Índices de similitud temporal / frecuencial tacograma extraído del PolarH10 - ECG*

Estímulo	Tipo	$\rho$	RCC	MSC
Basal	Max	0,980	0,981	0,983
	Min	0,918	0,920	0,925
	Mean	$0,952 \pm 0,026$	$0,955 \pm 0,026$	$0,957 \pm 0,024$
Estrés	Max	0,993	0,993	0,994
	Min	0,828	0,814	0,813
	Mean	$0,928 \pm 0,076$	$0,924 \pm 0,082$	$0,902 \pm 0,085$

Estímulo	Tipo	$\rho$	RCC	MSC
Relajado	Max	0,929	0,887	0,961
	Min	0,447	0,437	0,652
	Mean	$0,754 \pm 0,266$	$0,728 \pm 0,252$	$0,779 \pm 0,161$
Total	Max	0,993	0,993	0,994
	Min	0,447	0,437	0,652
	Mean	$0,889 \pm 0,154$	$0,882 \pm 0,158$	$0,889 \pm 0,114$

Nota: Se presentan marcados los valores máximos y mínimos de correlación total como ayuda visual de los índices de similitud obtenidos

### Polar OH1-PPG

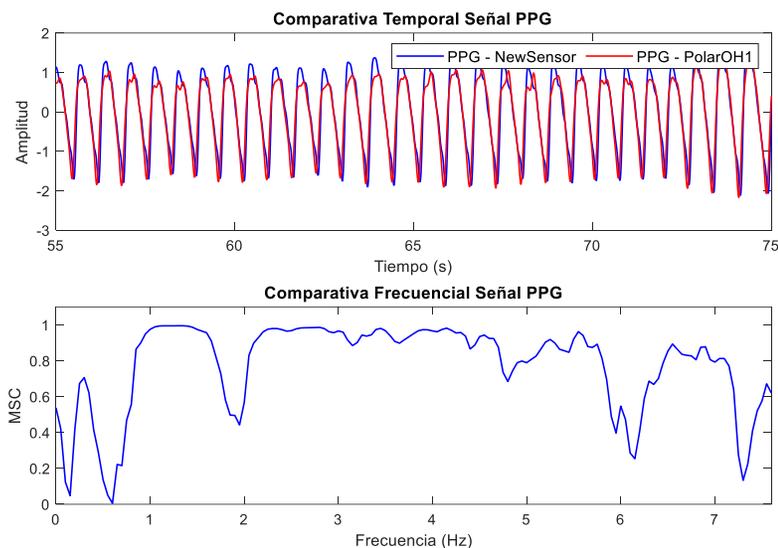
Para el análisis del dispositivo PolarOH1, se realiza una comparación de similitud temporal y frecuencial entre su señal PPG y la registrada simultáneamente por la plataforma multisensado durante el protocolo de estimulación descrito. En este contexto, el módulo PPG de la plataforma multisensado actúa como base referencial al emplear la técnica convencional para adquisición de señales fotopletimográficas basándose en la medición de la cantidad absorbida por el tejido microvascular, como se explicó en el apartado de Dispositivos estándar para adquisición de señales fisiológicas. Además, para el análisis comparativo realizado, se aplican nuevamente los coeficientes de correlación de Pearson, el coeficiente de correlación relativo para el análisis temporal y la estimación de la media de la magnitud de coherencia cuadrada.

En la Figura 60, se puede observar las señales superpuestas de PPG del módulo diseñado para la plataforma multisensado y del dispositivo wearable PolarOH1, además de la gráfica de la estimación de la coherencia de magnitud cuadrada en función de la frecuencia (obtenida en un rango frecuencial de 0 a 7.5 Hz). Visualmente, se aprecia una gran similitud temporal de la señal, presentando incluso la misma modulación de amplitud debidos a los cambios en la frecuencia respiratoria. Esta apreciación visual, es corroborada por los índices obtenidos en la Tabla 13, en donde se presenta una muy fuerte correlación media temporal y una moderada correlación media

frecuencial. Adicionalmente, se debe apreciar que la correlación temporal disminuye para la estimulación de estrés respecto al estado Basal y de Relajación

**Figura 60.**

*Comparación temporal / frecuencial PolarOH1 - PPG*



**Tabla 13.**

*Índices de similitud temporal / frecuencial Polar OH1 - PPG*

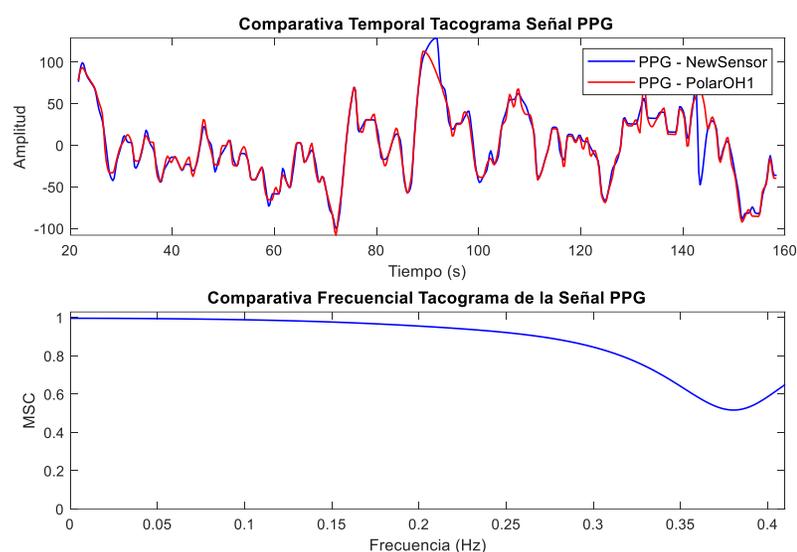
Estímulo	Tipo	$\rho$	RCC	MSC
Basal	Max	0,962	0,962	0,784
	Min	0,853	0,853	0,360
	Mean	$0,904 \pm 0,046$	$0,904 \pm 0,046$	$0,545 \pm 0,156$
Estrés	Max	0,941	0,941	0,725
	Min	0,838	0,841	0,352
	Mean	$0,893 \pm 0,039$	$0,893 \pm 0,038$	$0,529 \pm 0,128$
Relajado	Max	0,911	0,914	0,632
	Min	0,861	0,861	0,390
	Mean	$0,880 \pm 0,023$	$0,882 \pm 0,023$	$0,490 \pm 0,088$
Total	Max	0,962	0,962	0,784
	Min	0,838	0,841	0,352
	Mean	$0,892 \pm 0,037$	$0,893 \pm 0,036$	$0,521 \pm 0,122$

Nota: Se presentan marcados los valores máximos y mínimos de correlación total como ayuda visual de los índices de similitud obtenidos

Debido a que los picos de máxima sístole de la señal PPG están estrechamente relacionados con los picos R de la señal ECG, se puede estimar la serie temporal a partir de los tiempos entre máximos (SST del inglés Systole to Systole Time), señal equivalente al tacograma. En este contexto, se obtuvo la SST derivada de la señal PPG de la plataforma multisensado y del dispositivo Polar OH1 para su comparación en el dominio del tiempo y de la frecuencia, como se visualiza en la Figura 61.

**Figura 61.**

*Comparación temporal / frecuencial de la señal SST extraída del PolarOH1 – PPG*



Visualmente, se aprecia una gran similitud temporal de la señal de SST, siendo corroborada parcialmente esta apreciación visual por los índices obtenidos en la Tabla 14, en donde se presenta una fuerte correlación media temporal y frecuencial.

**Tabla 14.**

*Índices de similitud temporal / frecuencial SST extraído del PolarOH1 - PPG*

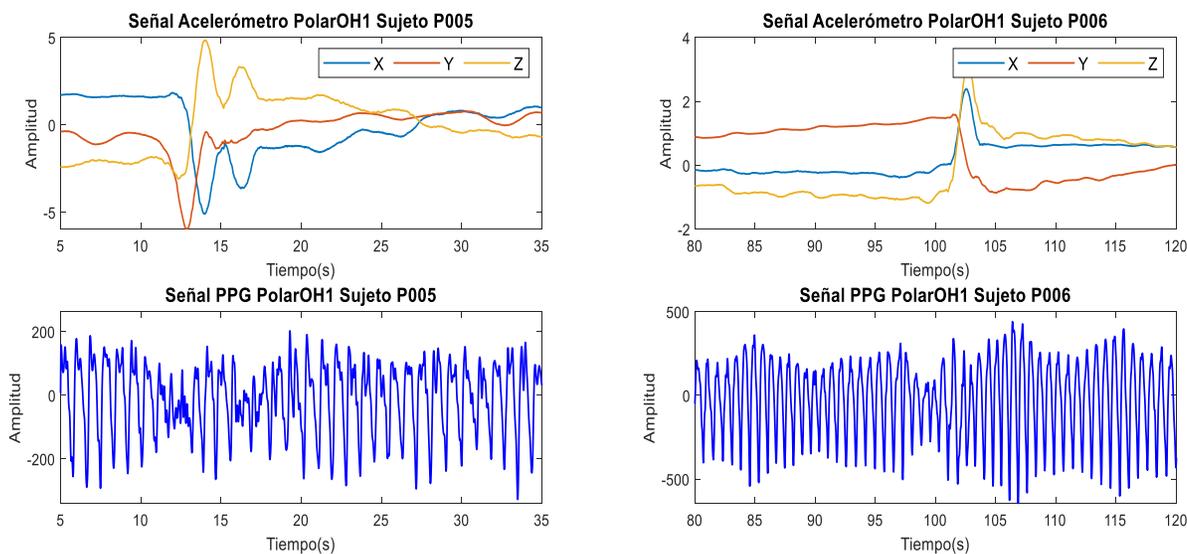
Estímulo	Tipo	$\rho$	RCC	MSC
Basal	Max	0,990	0,990	0,920
	Min	0,810	0,810	0,740
	Mean	0,906 $\pm$ 0,067	0,906 $\pm$ 0,067	0,832 $\pm$ 0,080
Estrés	Max	0,941	0,941	0,908
	Min	0,437	0,437	0,472
	Mean	0,666 $\pm$ 0,230	0,666 $\pm$ 0,230	0,694 $\pm$ 0,178

Estímulo	Tipo	$\rho$	RCC	MSC
Relajado	Max	0,944	0,944	0,915
	Min	0,191	0,148	0,118
	Mean	$0,616 \pm 0,416$	$0,673 \pm 0,287$	$0,535 \pm 0,329$
Total	Max	0,990	0,990	0,920
	Min	0,191	0,148	0,118
	Mean	$0,729 \pm 0,291$	$0,748 \pm 0,233$	$0,679 \pm 0,325$

Nota: Se presentan marcados los valores máximos y mínimos de correlación total como ayuda visual de los índices de similitud obtenidos

A pesar de la fuerte similitud media observada en la señal de SST, se tiene una desviación estándar elevada debido a un valor mínimo muy bajo en comparación a la media y al valor máximo. Este hecho se debe a fallas en la detección de los picos de máxima sístole, y por tanto generación errónea de la SST, de la señal obtenida por el PolarOH1, debido a movimientos voluntarios o involuntarios por parte del paciente. Esta apreciación se vuelve notable en las señales de acelerómetro y fotopletoemografía presentadas en la Figura 62 para dos sujetos de la base de datos, observándose como los movimientos generan picos adicionales no deseados y una disminución en la amplitud de la señal.

**Figura 62.**  
*Efecto del movimiento en la señal PPG del PolarOH1*



### VivoSmart- BPMs

Para el dispositivo VivoSmart, al presentar una plataforma tan cerrada, únicamente se pudo obtener el ritmo cardiaco con su respectiva marca de tiempo, por lo que se realizó la estimación y comparación de pulsaciones por minuto de los dispositivos MySignals-ECG y NewSensor-PPG de la plataforma multisensado seleccionados como referenciales. Para ello, el cálculo de pulsaciones por minuto (BPMs) fue realizada de dos formas distintas, siendo la estimación de los BPMs en función de la diferencia de tiempo entre un intervalo R-R sucesivo y la estimación mediante la media de la diferencia de tiempos en una ventana de 30 segundos

A modo comparativo, se puede observar en la Tabla 15 el error absoluto medio (EAM) en BPM, el error relativo medio (ERM) y la raíz cuadrada del error cuadrático medio (RMSE) entre el VivoSmart y los dos dispositivos seleccionados como referenciales al tomarse una ventana de 30 segundos. Se debe notar que el error entre los dos dispositivos referenciales es el menor encontrado, como era de esperarse, y que el mayor error se genera entre los BPMs estimados por el dispositivo VivoSmart y por el sensor de fotopleletismografía.

**Tabla 15.**

*Comparativa BPMs estimados en una Ventana 30 s, VivoSmart – Plataforma Multisensado*

Dispositivos	Estímulos	EAM (BPM)	ERM	RMSE
MySignals ECG - NewSensor PPG	Basal	0,060 ± 0,238	0,001 ± 0,003	0,244
	Estrés	0,700 ± 0,470	0,011 ± 0,007	0,837
	Relajado	0,346 ± 0,477	0,004 ± 0,006	0,588
	Total	0,238 ± 0,426	0,003 ± 0,005	0,488
MySignals ECG - VivoSmart HR	Basal	1,988 ± 1,686	0,024 ± 0,021	2,600
	Estrés	1,967 ± 1,345	0,025 ± 0,017	2,378
	Relajado	1,667 ± 1,471	0,021 ± 0,018	2,216
	Total	1,891 ± 1,505	0,023 ± 0,019	2,4151
NewSensor PPG - VivoSmart HR	Basal	2,308 ± 1,969	0,029 ± 0,025	3,026
	Estrés	2,000 ± 1,430	0,027 ± 0,019	2,454
	Relajado	2,140 ± 1,833	0,027 ± 0,024	2,804
	Total	2,142 ± 1,726	0,028 ± 0,022	2,748

Nota: Se presentan marcados los valores máximos y mínimos como ayuda visual de los errores totales obtenidos

Por otro lado, para la estimación realizada con un solo intervalo R-R sucesivo, se presentan los resultados de la Tabla 16, observándose como estos errores resultan mayores a los observados en la Tabla 15.

**Tabla 16.**

*Comparativa BPMs estimados entre intervalos R-R sucesivos, VivoSmart – Plataforma Multisensado*

Dispositivos	Estímulos	EAM	ERM	RMSE
MySignals ECG - NewSensor PPG	Basal	2,113 ± 2,932	0,035 ± 0,048	3,606
	Estrés	2,944 ± 3,429	0,040 ± 0,047	4,510
	Relajado	1,449 ± 2,304	0,021 ± 0,034	2,715
	Total	2,142 ± 2,961	0,032 ± 0,044	3,652
MySignals ECG - VivoSmart HR	Basal	3,700 ± 2,488	0,047 ± 0,031	4,451
	Estrés	3,510 ± 3,113	0,044 ± 0,039	4,681
	Relajado	2,184 ± 1,655	0,028 ± 0,021	2,734
	Total	3,200 ± 2,633	0,041 ± 0,033	4,141
NewSensor PPG - VivoSmart HR	Basal	4,468 ± 3,887	0,057 ± 0,049	5,909
	Estrés	4,585 ± 2,767	0,056 ± 0,034	5,348
	Relajado	4,958 ± 2,601	0,729 ± 0,038	5,586
	Total	4,613 ± 3,203	0,060 ± 0,041	5,612

Nota: Se presentan marcados los valores máximos y mínimos como ayuda visual de los errores totales obtenidos

### Algoritmo de clasificación supervisada

Una vez analizado el desempeño de los diferentes wearables empleados, se procede con la generación de los modelos de clasificación con el fin de estimar los niveles de estrés causados por estímulos audiovisuales, y posteriormente validar si los wearables son adecuados para esta estimación. En este apartado, se comparan una serie de clasificadores generados tanto con las características de la plataforma multisensado como con las extraídas por los wearables PolarH10 y PolarOH1. Se debe mencionar que se desarrollaron dos modelos generales en función de las características empleadas siendo el modelo 1 basado en todas las características de la señal ECG, PPG, FLW y GSR; y el modelo 2 basado en un número reducido de características de dichas señales

seleccionadas como estadísticamente relevantes. Cabe mencionar que en el caso del ECG y PPG se realizó una combinación de dispositivos entre la plataforma multisensado y los wearables, con lo que el modelo 1 y 2 tienen cuatro versiones cada uno, como se visualiza de mejor manera en las tablas de resultados posteriormente.

Ambos modelos de clasificación, emplean  $K$  vecinos más cercanos, KNN, como algoritmo de clasificación supervisada. Este algoritmo, de forma general calcula la distancia de un nuevo dato respecto a los ya etiquetados, ordena dichas distancias de menor a mayor y selecciona el grupo correspondiente en función del número  $K$  de observaciones, nombrados como vecinos, más próximas. Como métrica de similitud, se seleccionó la distancia euclídea, mientras que se varió el parámetro  $K$  entre un valor de 3 a 9 con el fin de determinar el que mejor se adecuó a las características propuestas.

Para la validación de los clasificadores, se emplea Leave One Out Cross-Validation, el cual es un método iterativo que selecciona para el entrenamiento todas las observaciones excepto una, la cual es usada como validación para calcular el error respecto a dicha observación y poder reajustar el modelo. Este proceso es repetido tantas veces como observaciones existentes.

En cuanto a la evaluación de los diferentes clasificadores, se emplean tres métricas basadas en la matriz de confusión generada a partir de los resultados del método del método de validación cruzada, siendo éstas la exactitud (Acc), asociada al desempeño general del clasificador, la sensibilidad (Se), correspondiente a la capacidad para identificar condiciones positivas correctamente, y la especificidad (Sp), relacionada a la capacidad para identificar condiciones negativas correctamente.

### **Modelo de clasificación I**

El primer modelo de clasificación fue basado en el uso de un total de 32 características obtenidas de las señales ECG, PPG, FLW y GSR, de donde para las señales ECG y PPG se emplea una combinación de uno de los dos dispositivos ECG, PolarH10 y plataforma MySignals, junto a uno de los dos dispositivos PPG, PolarOH1 y plataforma multisensado. Esta combinación de dispositivos se realiza para determinar la aplicabilidad de las características obtenidas por los wearables en estudios de estrés.

Por otro lado, debido al extenso número de características, y con el fin de reducir la dimensionalidad y concentrar la información que cada una aporta, se aplicó el algoritmo de análisis de componentes principales (PCA). Este algoritmo entrega una nueva matriz con un número reducido de componentes, generados a partir de la combinación lineal de las características originales, manteniendo al menos el 95% de la varianza.

Un resumen de los mejores modelos propuestos para la detección entre un estado basal de uno de estrés se puede observar en la Tabla 17, destacándose que el mejor clasificador corresponde a aquel que utiliza la señales ECG y PPG de la plataforma multisensado, seguido de aquel que emplea la señal ECG del dispositivo PolarH10 y la PPG de la plataforma multisensado. También se puede notar como el desempeño de los clasificadores mejora al aplicar PCA, siendo además interesante la reducción de dimensionalidad de 32 características originales a 3 o 4 componentes principales. En cuanto a los intervalos de tiempo, se debe acotar que se generaron todos los clasificadores para cada uno de los 13 tramos temporales mencionados (ver Figura 43), siendo visible en las tablas únicamente los de mejor desempeño, notándose que en su mayoría componen los primeros 30 segundos del tercer minuto de medición.

**Tabla 17.**  
*Clasificadores Basal-Estrés, todas las características*

Tipo	Disp. Señal ECG	Disp. Señal PPG	K	N_PCA	ACC	Se	Sp	T. temporal
	P. Multisensado	P. Multisensado	9	NA	0,688	0,688	0,688	125-155
Sin	P. Multisensado	PolarOH1	9	NA	0,467	0,333	0,600	100-120
PCA	PolarH10	P. Multisensado	5	NA	0,633	0,467	0,800	140-160
	PolarH10	PolarOH1	9	NA	0,467	0,200	0,733	140-160
	P. Multisensado	P. Multisensado	9	3	0,719	0,750	0,688	125-155
Con	P. Multisensado	PolarOH1	5	4	0,533	0,533	0,533	80-100
PCA	PolarH10	P. Multisensado	5	3	0,700	0,600	0,800	140-160
	PolarH10	PolarOH1	5	4	0,500	0,400	0,600	80-100

Nota:  $K$  corresponde al número de vecinos más cercanos y  $N\_PCA$  se encuentra asociada al número de componentes principales. Adicionalmente se encuentran marcados los mejores clasificadores (verde) y peores clasificadores (rojo) como ayuda visual para su comparación

En cuanto a la detección de un estado relajado de uno de estrés, se resume en la Tabla 18 los mejores clasificadores generados, observándose que en este caso sin aplicar PCA tantos los modelos que emplean la señal ECG del Polar como de la plataforma multisensado presentan métricas similares. Además, de forma general estos clasificadores presentan una exactitud mejor y una mayor sensibilidad respecto a los generados en la Tabla 17.

**Tabla 18.**  
*Clasificadores Relajado-Estrés, todas las características*

Tipo	Disp. Señal ECG	Disp. Señal PPG	K	N_PCA	ACC	Se	Sp	T. temporal
	P. Multisensado	P. Multisensado	3	NA	0,750	0,813	0,688	125-155
Sin	P. Multisensado	PolarOH1	9	NA	0,656	0,688	0,625	125-155
PCA	PolarH10	P. Multisensado	5	NA	0,750	0,813	0,688	125-155
	PolarH10	PolarOH1	9	NA	0,688	0,750	0,625	125-155
	P. Multisensado	P. Multisensado	7	3	0,719	0,875	0,563	125-155
Con	P. Multisensado	PolarOH1	7	4	0,700	0,800	0,600	120-140
PCA	PolarH10	P. Multisensado	7	3	0,719	0,750	0,688	120-160
	PolarH10	PolarOH1	9	4	0,656	0,688	0,625	125-155

Nota:  $K$  corresponde al número de vecinos más cercanos y  $N\_PCA$  se encuentra asociada al número de componentes principales. Adicionalmente se encuentran marcados los mejores clasificadores (verde) y peores clasificadores (rojo) como ayuda visual para su comparación

## Modelo de clasificación II

Para el segundo modelo de clasificación, se realizó una selección de las características basándose en aquellas que presentan cambios estadísticamente significativos entre estímulos; es decir, las 32 características obtenidas en estado basal fueron comparadas con aquellas obtenidas durante la estimulación de estrés y estas últimas fueron a su vez comparadas con aquellas correspondientes a la estimulación de relajación. Como método estadístico, se aplicó la prueba de los rangos con signo de Wilcoxon (Wilcoxon Signed Rank Test), el cual es un test estadístico no paramétrico basado en la comparación de la mediana de dos muestras relacionadas y así determinar si la diferencia entre ellas es estadísticamente representativa (Shier, 2004). Para esta investigación, se establece como hipótesis nula  $H_0$  que no existe diferencia significativa entre las características de un estímulo respecto a otro con un nivel de confianza del 90% ( $\alpha = 0.1$ )

El test de Wilcoxon mencionado, fue aplicado en todas características considerando los 13 intervalos de tiempo definidos, siendo observado en la Tabla 19 y Tabla 20, la frecuencia absoluta de veces que aparecieron las principales características como estadísticamente relevantes ( $f_i$ ). Este método de selección fue aplicado variando nuevamente los dispositivos ECG y PPG, similar a como se realizó para el modelo de clasificación 1.

**Tabla 19.**  
*Selección de característica Basal-Estrés*

PH10-POH1		MS-NS		MS-POH1		PH10-NS	
Característica	$f_i$	Característica	$f_i$	Característica	$f_i$	Característica	$f_i$
RPM_FLW	10	RPM_FLW	10	RPM_FLW	10	RPM_FLW	10
mTTot1_FLW	10	mTTot1_FLW	10	mTTot1_FLW	10	mTTot1_FLW	10
FMP_FLW	10	FMP_FLW	10	FMP_FLW	10	FMP_FLW	10
mQRSA1_ECG	9	mFLWA1_FLW	9	mFLWA1_FLW	9	mQRSA1_ECG	9
mFLWA1_FLW	9	EDAs_EDA	8	EDAs_EDA	8	mFLWA1_FLW	9
EDAs_EDA	8	mBT1_ECG	6	mBT1_ECG	6	EDAs_EDA	8
mVLF_ECG	5	RMSSD_ECG	6	RMSSD_ECG	6	mVLF_ECG	5
mBT1_ECG	4	BPM_ECG	5	BPM_ECG	5	mBT1_ECG	4
BPM_ECG	4	mQRSA1_ECG	5	mQRSA1_ECG	5	BPM_ECG	4
RMSSD_ECG	4	FMP2_ECG	3	FMP2_ECG	3	RMSSD_ECG	4

Nota: Dispositivos ECG: PolarH10 (PH10) y MySignals (MS). Dispositivos PPG: PolarOH1 (POH1) y módulo externo NewSensor (NS)

**Tabla 20.**  
*Selección de características Relajado-Estrés*

PH10-POH1		MS-NS		MS-POH1		PH10-NS	
Característica	$f_i$	Característica	$f_i$	Característica	$f_i$	Característica	$f_i$
FMP_FLW	13	FMP_FLW	13	FMP_FLW	13	FMP_FLW	13
sQRSA1_ECG	12	mTTot1_FLW	10	mTTot1_FLW	10	sQRSA1_ECG	12
mTTot1_FLW	10	RPM_FLW	9	RPM_FLW	9	mTTot1_FLW	10
RPM_FLW	9	SDNN_ECG	9	SDNN_ECG	9	RPM_FLW	9
EDAm_EDA	6	EDAm_EDA	6	EDAm_EDA	6	EDAm_EDA	6
sSST1_BP	6	sQRSA1_ECG	3	sSST1_BP	6	SDNN_ECG	3
SDNN_ECG	3	RP_ECG	3	sQRSA1_ECG	3	mHF_ECG	3
mHF_ECG	3			RP_ECG	3		

Nota: Dispositivos ECG: PolarH10 (PH10) y MySignals (MS). Dispositivos PPG: PolarOH1 (POH1) y módulo externo NewSensor (NS)

Una vez evaluadas las características, se realizó una selección de aquellas que se repiten de forma consistente para todas las combinaciones de dispositivos, como se observa en la Tabla 21, en donde se presenta una breve descripción de cada una y en qué tipo de clasificador, Basal-Estrés o Relajado-Estrés, fue empleada.

**Tabla 21.**  
*Características más relevantes seleccionadas por estímulo*

Señal	Características	Descripción	Basal-Estrés	Relajado-Estrés
ECG	mBT1	Media tiempo medio entre latidos	X	
	BPM	Latidos por minuto	X	
	SDNN	STD del HRV		X
	RMSSD	RMS del HRV	X	
	mQRSA1	Media de amplitud complejo QRS	X	
	sQRSA1	Desviación estándar de amplitud complejo QRS		X
	mVLF	Potencia media banda VLF del tacograma	X	
	mHF	Potencia media banda HF del tacograma		X
	RP	Ratio de potencia LF/HF del tacograma		X

Señal	Características	Descripción	Basal-Estrés	Relajado-Estrés
FLW	RPM	Respiraciones por minuto	X	X
	mTTot1	Media tiempo medio de cada respiración	X	X
	mFLWA1	Media de la amplitud entre cada respiración	X	
	FMP	Frecuencia potencia máxima	X	X
EDA	EDAm	Pendiente de la recta ajustada		X
	EDAs	Desviación estándar	X	

Con las características estadísticamente significativas seleccionadas, se procedió con la generación de nuevos clasificadores basándose en la misma metodología empleada para los modelos anteriores, la cual se basa en la variación de K, aplicación de PCA sobre las características seleccionadas y evaluación en los diferentes intervalos de tiempo. Sin embargo, se debe mencionar que para este apartado únicamente se varía el dispositivo de señal ECG entre la plataforma multisensado y el PolarH10 debido a que como se observa en la Tabla 21, no existen características estadísticamente significativas para las señales de fotopleletismografía.

En la Tabla 22 y en la Tabla 23 se visualizan las métricas obtenidas para los mejores clasificadores generados en este apartado, siendo de interés como nuevamente el intervalo temporal que se repite con mayor frecuencia es el correspondiente entre los 125s a 155s de medición.

**Tabla 22.**

*Clasificadores Basal-Estrés generados con características seleccionadas*

Tipo	Disp. Señal ECG	K	N_PCA	ACC	Se	Sp	T. temporal
Sin	P.Multisensado	5	NA	0,688	0,813	0,563	125-155
PCA	PolarH10	9	NA	0,688	0,938	0,438	40-60
Con	P.Multisensado	5	2	0,688	0,813	0,563	125-155
PCA	PolarH10	9	2	0,719	0,688	0,750	140-160

Nota: Se marca el mejor clasificador generado con característica seleccionadas para la detección de un estado basal de un estado de estrés

**Tabla 23.***Clasificadores Relajado-Estrés con características seleccionadas*

Tipo	Disp. Señal ECG	K	N_PCA	ACC	Se	Sp	T. temporal
Sin	P.Multisensado	3	NA	0,813	0,875	0,750	125-155
PCA	PolarH10	3	NA	0,813	0,813	0,813	125-155
Con	P.Multisensado	3	1	0,813	0,813	0,813	125-155
PCA	PolarH10	3	1	0,813	0,813	0,813	125-155

Nota: Al tenerse clasificadores similares, se marca el clasificador que presenta una mayor sensibilidad.

Analizando los clasificadores generados con el modelo basado en la selección de características respecto a aquellos que emplearon todas las características, no se observa un aumento de la exactitud en la detección de un estado basal de uno de estrés, sin embargo, si aumenta notablemente la sensibilidad, asociada a la detección de verdaderos positivos. En cuanto a los clasificadores de Relajado–Estrés, si se aprecia una mejor exactitud y sobre todo un incremento en la especificidad, asociada a la detección de verdaderos negativos.

En cuanto al uso de PCA, si bien la matriz de características no resultaba excesiva a diferencia del apartado anterior, se lo vuelve a aplicar con el fin de establecer una comparativa objetiva respecto a la selección o no de características, observándose que los clasificadores con PCA presentan un desempeño similar a aquellos que no lo aplican con la gran diferencia que se redujeron el espacio a dos e incluso una única componente principal.

## Capítulo VI

### Conclusiones Y Recomendaciones

Tras finalizarse las actividades propuestas para el cumplimiento de los objetivos del proyecto, se presentan las conclusiones y recomendaciones obtenidas, siendo estas enfocadas en la plataforma multisensado empleada, la generación de la base de datos, procesamiento de señales, diseño de los clasificadores, y naturalmente en el desempeño de los dispositivos wearables utilizados, siendo estos la banda pectoral PolarH10, la pulsera PolarOH1 y el reloj inteligente Garmin VivoSmart4. En este último punto se analiza a nivel cualitativo y cuantitativo los dispositivos empleados y sus señales registradas con el fin de verificar la aplicabilidad de esta creciente tecnología en ámbitos investigativos como la detección de estrés en sujetos sanos estimulados mediante estresores audiovisuales.

#### Plataforma multisensado

En función del estado del arte desarrollado, se seleccionaron una serie de señales fisiológicas que resultan de interés en estudios para la detección de estrés, siendo estas las señales electrocardiográficas (ECG), de fotopleletismografía (PPG), flujo respiratorio (FLW), respuesta galvánica de la piel (GSR), temperatura corporal (TEMP) y electrooculografía (EOG). Para su adquisición, inicialmente se planteó emplear en su mayoría las prestaciones que ofrece la plataforma MySignalsHW especializada para investigaciones y prototipado de hardware, sin embargo, durante el desarrollo se notaron una serie de limitaciones entre las que se destacan una señal de flujo respiratorio rectificadas, ruido excesivo y baja sensibilidad de la señal GSR, y ausencia de sistemas para adquisición de señales EOG y PPG. Por estos motivos, se emplearon módulos adicionales para la adquisición de señales FLW, PPG, EOG y GSR, siendo posteriormente acoplados en una placa a modo de Mainboard para su integración con la plataforma MySignals, componiéndose lo que vendría a ser la plataforma multisensado empleada para la adquisición de

señales. Este prototipo, se caracterizó por ser flexible, modular, de sencilla calibración, fácil de conectar, fácil de manipular, y relativamente sencillo de programar al emplear el Arduino Nano como sistema microcontrolado para la adquisición y envío de la información. Si bien el controlador fue adecuado para el trabajo desarrollado, este se encontraba casi al límite de sus capacidades, por lo que para otros estudios puede ser útil una repotenciación del controlador por uno con mejores prestaciones en cuanto a velocidad de procesamiento, memoria de almacenamiento e interfaces de comunicación.

Por otro lado, el sistema de adquisición de señales fisiológicas se encuentra compuesto también por una etapa de software, correspondiente a una interfaz de usuario desarrollada en el programa Matlab 2019b mediante la herramienta de AppDesigner, siendo seleccionado este software debido a que presenta funciones propias para establecer de forma sencilla la comunicación serial con el controlador de la plataforma MySignals y comunicación BLE con los dispositivos wearables. Esta interfaz, presentó tres funcionalidades principales, siendo estas el ingreso de información relevante para la adquisición (número de paciente, nombre, edad, género y tipo de estímulo), verificación de las señales de los dispositivos conectados y control del flujo del programa (conectar los dispositivos, iniciar, parar y guardar los datos); teniéndose como consideraciones en su diseño que sea de fácil manejo e intuitiva para evitar inconvenientes y minimizar errores en el registro de las señales fisiológicas para la base de datos.

Se debe mencionar que, si bien la interfaz permitía la conexión y comunicación de forma sencilla con los dispositivos wearables, no se logra una visualización efectiva en tiempo real de sus señales obtenidas, cuestión si lograda con las señales de la plataforma multisensado, debido a que al momento que se lo intentó implementar se perdía la comunicación BLE con uno o ambos de los dispositivos. Este hecho fue parcialmente solucionado mediante la visualización posterior de las señales adquiridas por los wearables en un periodo de aproximadamente 30s, y se presume

como causa el hecho de que las aplicaciones desarrolladas con AppDesigner pueden llegar a utilizar una mayor cantidad de recursos en segundo plano, ralentizando procesos del computador personal empleado, entre ellos la comunicación BLE.

En cuanto al computador personal empleado como concentrador central, se debe aclarar que, si bien soportó la comunicación BLE simultánea de los dos dispositivos wearables, el uso de un mayor número de ellos resulta inadecuado y puede provocar desconexión parcial o total de la comunicación. Por este motivo, de desearse la adquisición de una mayor densidad de dispositivos inalámbricos por tecnología Bluetooth o BLE, es necesaria la aplicación de otros métodos de adquisición, como la adición de un adaptador que realice un puente entre comunicación BLE con comunicación serial a través del puerto USB del computador.

### **Generación de la base de datos y procesamiento de las señales**

Para el registro de las señales fisiológicas, fue aplicado un protocolo de estimulación basado en la investigación desarrollada por (Cruz Varela, 2021), replicándose principalmente la etapa de estimulación audiovisual propuesta siendo adaptada en términos del número y tipos de dispositivos utilizados. Este protocolo permite una adquisición de señales de forma metodológica e intenta asegurar una estimulación uniforme para todos los sujetos seleccionados para la base de datos. Se debe aclarar que, al no ser el objetivo de la investigación profundizar en métodos de inducción de estados emocionales, resultó adecuado el adaptar un protocolo de estimulación ya establecido y probado en otra investigación.

De forma general, el protocolo aplicado constó de tres etapas basadas en la preparación y colocación de sensores en el paciente, registro continuo de las señales al aplicarse los estímulos audiovisuales y finalmente en la remoción de los dispositivos empleados y control final de la información obtenida. Como una aclaración adicional, previa a la aplicación de los estímulos se realizó la calibración de los sensores (ajuste de ganancia y desplazamiento), y posterior al registro,

se realizó la desinfección o descarte de los sensores empleados como parte de las medidas de bioseguridad.

Establecido el protocolo de estimulación, se procedió con la conformación de la base de datos, obteniéndose tres registros de aproximadamente 180s, correspondientes a los estados basal, estrés y relajado, de un total de siete pacientes con edades comprendidas entre los 19 y 52 años. Los registros generados corresponden a la adquisición simultánea de un total de 11 señales fisiológicas, ECG (MySignals y PolarH10), PPG (NewSensor y PolarOH1), FLW, GSR (MySignals y NewSensor), EOGV, EOGH, TEMP y HR (VivoSmart4).

Una vez adquiridas y almacenadas las señales fisiológicas de interés en la base de datos, se continuó con su procesamiento digital, con el objetivo de reducir las componentes de ruido no deseado y caracterizar su respuesta temporal y frecuencial. En esta etapa, se aprovecharon los algoritmos desarrollados en los trabajos de (Arcentales V et al., 2021) y (Arcentales Viteri, 2015) para la extracción de un total de 47 características de las señales ECG (14), PPG (7), FLW (7), EOGV (7), EOGH (7), GSR (4) y TEMP (1), en un total de 13 tramos temporales.

Adicionalmente, se debe aclarar que el procesamiento y extracción de características fue aplicado tanto para las señales obtenidas por la plataforma multisensado como por los dispositivos wearables. En este contexto, para la señal ECG de la banda PolarH10, se aplicó un filtro pasabajos con una frecuencia de corte mayor ( $F_{\text{paso}}=50$  Hz,  $F_{\text{paro}}=50.5$  Hz) a la empleada a la señal ECG de la plataforma MySignals ( $F_{\text{paso}}=31.5$  Hz,  $F_{\text{paro}}=32$  Hz). Esto debido a que un filtro con  $F_{\text{paso}}=31.5$  Hz distorsionaba la respuesta temporal de la ECG del PolarH10 de forma no deseada. Adicionalmente, la señal ECG del wearable no presentaba componentes de ruido en frecuencias superiores a los 32 Hz por lo que el filtro usado fue el adecuado.

Por otro lado, debido a que el dispositivo PolarOH1 cuenta con tres sensores PPG basados en la medición de la cantidad de luz reflejada por el tejido microvascular, se calculó la media

invertida de las señales de los tres sensores para generar una única señal PPG. A esta única señal, se le aplicó posteriormente el mismo preprocesamiento seguido para la señal PPG del módulo desarrollado para la plataforma multisensado para poder establecer una comparativa temporal y frecuencial posteriormente.

Cabe mencionar también, que, dentro de las señales consideradas en este apartado, se excluye la señal de ritmo cardíaco del dispositivo Garmin VivoSmart4 debido a que esta no requiere de un procesamiento adicional al ser un parámetro cardíaco ya calculado por el propio dispositivo.

### **Estimación de los niveles de estrés**

Con el fin de estimar los niveles de estrés causado por estímulos audiovisuales, y posteriormente validar si los wearables son adecuados para esta estimación, se diseñaron y compararon una serie de clasificadores a partir de las características extraídas de la señal ECG, PPG, FLW y GSR. Si bien, en un inicio se planteó el emplear las señales de todos los sistemas adquiridos, las características de la señal de temperatura fueron descartadas al ser prácticamente constantes y no presentar variaciones cuantificables entre estímulos; mientras que para las señales EOG, si bien existe un incremento de la actividad eléctrica ocular para el estímulo de estrés respecto al basal, esto se puede deber al tipo de estimulación empleada y su respuesta ocular, y no necesariamente a la emoción inducida, además se observan variaciones considerables entre un sujeto y otro, siendo descartadas de igual manera para la generación del modelo de clasificación.

Centrándose en los clasificadores, se desarrollaron dos modelos generales en función de las características empleadas siendo el modelo 1 basado en todas las características de las señales mencionadas y el modelo 2 basado en un número reducido de ellas, seleccionadas como estadísticamente relevantes. Todos los clasificadores fueron basados en el algoritmo supervisado

K vecinos más cercanos (KNN), y validados mediante Leave One Out Cross-Validation, obteniéndose de cada uno como métricas comparativas su exactitud (Acc), sensibilidad (Se) y especificidad (Sp).

El primer modelo de clasificación fue basado en un total de 32 características obtenidas de las señales mencionadas, de donde para las señales ECG y PPG se emplea una combinación de uno de los dos dispositivos ECG, PolarH10 y plataforma MySignals, junto a uno de los dos dispositivos PPG, PolarOH1 y plataforma multisensado. Esta combinación de dispositivos se realiza para analizar la aplicabilidad de las características obtenidas por los wearables en estudios de estrés. Adicionalmente, se aplicó el análisis de componentes principales (PCA) para reducir la dimensionalidad del extenso número de características originales y concentrar la información que cada una aporta.

De estos primeros modelos, el mejor clasificador, tanto sin aplicar PCA como aplicándolo, corresponde a aquel que utiliza la señales ECG y PPG de la plataforma multisensado, obteniéndose en el mejor de los casos para el clasificador Basal-Estrés una exactitud de 71,9% aplicando PCA (K=9, Acc=71,9%, Se=7,50%, Sp=68,8%), y para Relajado-Estrés una exactitud de 75,0% sin aplicar PCA (K=3, Acc=75,0%, Se=81,3%, Sp=68,8%). En cuanto al uso de PCA, si bien no se incrementó la exactitud en todos los casos, se observó una clara mejora en cuanto a sensibilidad tanto para la distinción de un estado basal de uno de estrés como de un estado de relajación de uno de estrés, siendo notable la reducción de 32 características originales a 3 o 4 componentes principales.

Por otro lado, para la generación del segundo modelo de clasificación, aplicándose el test de los rangos con signo de Wilcoxon (Wilcoxon Signed Rank Test), se realizó la selección de características basándose en aquellas que presentan cambios estadísticamente significativos entre un estímulo y otro. Este test estadístico no paramétrico, fue aplicado en todas características considerando los 13 intervalos de tiempo definidos (ver sección Procesamiento

digital de las señales fisiológicas, Figura 43), siendo seleccionadas finalmente aquellas que se presentaron con mayor frecuencia como estadísticamente relevantes de forma consistente para las 4 combinaciones de dispositivo ECG y PPG.

Para los clasificadores Basal-Estrés, se seleccionaron un total de 10 características de las señales ECG (5), FLW (4) y GSR (1), mientras que para los de Relajación-Estrés, se seleccionaron un total de 8 características de las mismas señales ECG (4), FLW (3) y GSR (1), destacándose que las tres características coincidentes para ambos grupos de estímulos corresponden al número de respiraciones por minuto, tiempo medio de cada respiración y frecuencia de potencia máxima de la señal de flujo respiratorio, observándose la importancia de esta señal en la detección de estrés como lo señala (Meijer & Morssink, 2020) en su trabajo.

Analizando los clasificadores generados con el modelo basado en la selección de características respecto a aquellos que emplearon todas las características, no se observó un aumento de la exactitud en la detección de un estado basal de uno de estrés, sin embargo, si aumenta notablemente la sensibilidad, asociada a la detección de verdaderos positivos. En cuanto a los clasificadores de Relajado-Estrés, si se aprecia una mejor exactitud y sobre todo un incremento en la especificidad, asociada a la detección de verdaderos negativos.

Por otro lado, se observa un desempeño similar entre los clasificadores que aplican PCA a las características seleccionadas respecto a aquellos que no lo aplican, con la gran diferencia que se reduce el espacio de características a dos componentes principales para el clasificador Basal-Estrés y una sola componente principal para el clasificador Relajado-Estrés

En cuanto al análisis de los intervalos de tiempo utilizados en la extracción de características, se debe acotar que, si bien se generaron todos los clasificadores para cada uno de los 13 tramos temporales mencionados, únicamente se mostraron como resultados aquellos que mejor desempeño tuvieron, siendo notorio que predominan aquellos clasificadores que

involucran características obtenidas durante el tercer minuto de medición, siendo el intervalo que aparece con mayor frecuencia aquel comprendido entre los 125s a 155s tanto para los estímulos Basal-Estrés como para Relajado-Estrés.

### **Desempeño de los dispositivos wearables**

El uso de wearables es uno de los ejes fundamentales de este trabajo de investigación, por lo que, a lo largo del proyecto, se analizó el desempeño tanto cualitativo como cuantitativo de ellos, sus señales entregadas y su aplicabilidad a estudios de estimación de estrés. Para ello, los tres wearables empleados fueron la banda pectoral para señales ECG PolarH10, la banda de antebrazo para señales PPG PolarOH1 y el reloj inteligente VivoSmart4 de Garmin.

El primer reto a solucionar con los dispositivos wearables empleados, fue la conectividad y adquisición de señales no procesadas. Por defecto, para maximizar el tiempo de uso de los dispositivos, estos emplean protocolos de bajo consumo energético para la transmisión de información basados en comunicación ANT+ o Bluetooth Low Energy (BLE), siendo este último la alternativa empleada por los tres wearables en este trabajo de investigación. Además, los datos transmitidos generalmente corresponden a parámetros fisiológicos ya procesados, como ritmo cardiaco, número de pasos, saturación de oxígeno, entre otros, sin embargo, empresas como Polar permiten el envío de las señales no procesadas adquiridas mediante paquetes de información por comunicación BLE. Para esto, se requiere una serie de pasos, explicados en la sección Dispositivos Polar, que permiten habilitar la opción para streaming de las señales ECG, PPG o ACC según corresponda, en función de la escritura de bytes específicos en las características del servicio PMD. Se debe destacar que si bien la información para habilitar el streaming de data es pública y relativamente sencilla de entender la información de su implementación es vaga y poco concisa encontrándose entre las pocas descripciones completas la desarrollada por (Pareek, 2020), la cual fue publicada posterior al inicio del trabajo de investigación. Por este motivo, fueron

exploradas una serie de opciones para la adquisición, siendo seleccionado en este caso el software privado Matlab versión 2019b al ser un software integral con funciones propias para la comunicación BLE, diseño de la interfaz de usuario, procesamiento y generación de los modelos de clasificación. En este punto, se debe destacar que otras empresas como Garmin no están abiertas al envío de data y únicamente permiten la adquisición y visualización de parámetros ya procesados a través de sus aplicaciones, restringiendo incluso el tipo de información descargable de la plataforma online y generando archivos con extensiones propias.

Los dispositivos wearables, presentan la gran ventaja de ser fáciles de utilizar y relativamente cómodos de emplear, además que no limitan la movilidad del usuario, a diferencia de los dispositivos convencionales para adquisición de señales fisiológicas. Este hecho, se ve reflejado sobre todo en la banda pectoral de Polar, que, a diferencia de un electrocardiógrafo o monitor Holter estándar, no requiere conocimiento especializado para la colocación de los electrodos, minimizando errores humanos en este aspecto.

Si bien los wearables utilizados tienen estas ventajas mencionadas dadas a su diseño y capacidad de transmisión inalámbrica de información, en torno a las señales registradas por cada uno, se tienen diferencias a considerar previa a su selección como parte de estudios investigativos. Por un lado, la señal ECG que entrega el dispositivo Polar H10 cuenta con poca presencia de ruido y no requiere un preprocesamiento extenso. Sin embargo, se aprecia una considerable variación en los complejos PQ y ST respecto a la señal ECG adquirida por la plataforma MySignals, utilizada como referencia, por la diferencia en la derivación empleada por cada uno de los dispositivos, obteniéndose una correlación temporal moderada ( $\rho=0,418 \pm 0,075$ ,  $RCC=0,447 \pm 0,068$ ) y una correlación frecuencial fuerte ( $MSC=0,667 \pm 0,056$ ). A pesar de ello, se destaca que los complejos R-R se encuentran estrechamente relacionados entre ambos dispositivos, como se observa al adquirir y analizar la similitud del tacograma correspondiente,

obteniéndose una correlación temporal y frecuencial muy fuerte ( $\rho=0,889 \pm 0,154$ ,  $RCC=0,882 \pm 0,158$ ,  $MSC=0,889 \pm 0,114$ ).

En cuanto al Polar OH1, al ser comparada su señal PPG con la adquirida con el módulo diseñado para la plataforma multisensado, se aprecia una gran similitud temporal de la señal, presentando incluso la misma modulación de amplitud debida a los cambios en la frecuencia respiratoria, obteniéndose una muy fuerte correlación temporal media ( $\rho=0,892 \pm 0,037$ ,  $RCC=0,893 \pm 0,036$ ) y una moderada correlación frecuencial ( $MSC=0,521 \pm 0,122$ ). De igual forma, debido a que los picos de máxima sístole de la señal PPG están estrechamente relacionados con los picos R de la señal ECG, se analizó la similitud entre las series temporales SST (Systole to Systole Time) de ambos dispositivos, obteniéndose una fuerte correlación temporal y frecuencial ( $\rho=0,729 \pm 0,291$ ,  $RCC=0,748 \pm 0,233$ ,  $MSC=0,748 \pm 0,233$ ). A pesar de los elevados índices de similitud obtenidos en la serie SST, se tiene una desviación estándar elevada debido a un valor mínimo muy bajo en comparación a la media y al valor máximo. Este hecho se debe a fallas en la detección de los picos de máxima sístole, y por tanto generación errónea de la SST, de la señal obtenida por el PolarOH1, debido a movimientos voluntarios o involuntarios por parte del paciente. Al emplear tecnología por reflexión, la señal PPG del Polar OH1 registrada es notablemente afectada por artefactos de movimiento y cambios en la luz ambiental, siendo generadas variaciones no deseados en la amplitud y forma de la señal, por lo que previo a ser utilizado el Polar OH1 en estudios investigativos, es recomendable la implementación de algoritmos robustos que minimicen los efectos generados por el movimiento del usuario basándose en los sensores de aceleración y luz ambiental presentes en el mismo dispositivo. Como alternativa, de requerirse únicamente la serie STT o tacograma, se puede utilizar la señal de intervalo entre pulso y pulso (PPI del inglés Pulse-Pulse Interval) entregada por ambos

dispositivos Polar, obtenida posterior al algoritmo de detección de picos propio de la compañía, aclarándose que el análisis de dicha señal queda fuera del alcance del presente trabajo.

Por otro lado, debido a que el reloj inteligente Garmin Vivosmart4 no provee la información para el envío de la data no procesada y limita de sobremanera el tipo de información descargable, únicamente se logra analizar las pulsaciones por minuto obtenidas respecto a las estimadas de las señales ECG y PPG de la plataforma multisensado. Al realizarse la estimación en una ventana de 30 segundos, se obtuvo un error absoluto medio relativamente bajo que va entre  $1,891 \pm 1,505$  BPMs (ERM=0,023  $\pm$  0,019, RMSE=2,4151) y  $2,142 \pm 1,726$  BPMs (ERM=0,028  $\pm$  0,022, RMSE=2,748) dependiendo del dispositivo comparado, cuestión consistente con los resultados presentados por (Pasadyn et al., 2019), en donde se observó una subestimación por parte del Vivosmart4 de 2 BPMs respecto a un ECG estándar.

En lo que respecta a la aplicabilidad de estos wearables para la estimación de estrés, los resultados obtenidos varían en función del dispositivo empleado. Por un lado, al utilizar las características extraídas de la señal ECG del dispositivo PolarH10 y PPG de la plataforma multisensado, todos los clasificadores obtenidos presentaban métricas comparables a aquellos basados en la señal ECG y PPG de la plataforma multisensado, siendo incluso iguales en el caso del clasificador de estímulos Relajado-Estrés sin PCA y con todas las características (Acc=0,750, Se=0,813, Sp=0,688). Este hecho, permite afirmar que, si bien las señales ECG del dispositivo Polar H10 presenta claras diferencias con el dispositivo referencial, se pueden extraer características significativas y aplicables al diseño de sistemas de estimación de estrés. Esto se debe a que los clasificadores se encuentran basados principalmente en la detección y caracterización del tiempo entre pulso-pulso y existe una muy fuerte correlación temporal y frecuencial del tacograma generado a partir de ambos dispositivos.

En cuanto al Polar OH1, se observa una notable disminución del performance por parte de aquellos clasificadores que utilizan las características extraídas de su señal PPG (Ej. clasificador Basal-Estrés con PCA,  $Acc=0,533$ ,  $Se=0,533$ ,  $Sp=0,533$ ) respecto a aquellos que utilizan las señales de la plataforma multisensado (Ej. Clasificador Basal-Estrés con PCA,  $Acc=0,719$ ,  $Se=0,750$ ,  $Sp=0,688$ ), sobre todo para la discriminación entre un estado basal de uno de estrés. Esta diferencia de rendimiento en términos de exactitud, sensibilidad y especificidad, se debe al efecto que tienen los artefactos de movimiento en la señal del Polar OH1, alterando la capacidad del algoritmo de procesamiento para extraer características basadas en la detección de los máximos correctamente, por lo que, previa a su adopción en estudios futuros para la estimación de estrés, es recomendable implementar algoritmos de preprocesamiento adicionales para minimizar los efectos generados por el movimiento, como se explicó anteriormente.

Por último, dispositivos como el Vivosmart4 de Garmin al presentar una plataforma y sistema tan cerrados, no resultan adecuados para su uso en ámbitos investigativos, debido a que no proporcionan información significativa ni tampoco la señal no procesada. A pesar de que, si bien se obtienen parámetros de interés como el porcentaje de estrés percibido, estos son calculados en ventanas temporales más extensas y no se encuentran disponibles para su análisis offline sino son únicamente observables en la plataforma web o en la aplicación propia de la compañía.

Como aclaración final, se tiene que, si bien los resultados estadísticos e índices de similitud calculados no pueden ser generalizados debido a la reducida base de datos, al ser seleccionados como sujetos únicamente aquellos cercanos al entorno del investigador por causa de la pandemia de COVID-19, estos sí pueden ser tomados como referenciales al ser consistentes con el estado del arte investigado, como es el caso de las características seleccionadas como estadísticamente significativas, el efecto de artefactos de movimiento en la señal PPG y

desempeño general de los wearables en otros estudios. A pesar de ello, para trabajos futuros se recomienda un incremento en el número de sujetos de prueba para poder corroborar y generalizar las conclusiones obtenidas en esta investigación.

## Referencias

- 2M Engineering. (2018). *CardioSense-Wearable ECG sensor with atrial fibrillation detection*. 2M Engineering. <https://www.2mel.nl/projects/cardiosense-wireless-ecg-sensor-with-atrial-fibrillation-detection/>
- Al-Kaisey, A. M., Koshy, A. N., Ha, F. J., Spencer, R., Toner, L., Sajeev, J. K., Teh, A. W., Farouque, O., & Lim, H. S. (2020). Accuracy of wrist-worn heart rate monitors for rate control assessment in atrial fibrillation. *International Journal of Cardiology*, *300*, 161-164. <https://doi.org/10.1016/j.ijcard.2019.11.120>
- Allen, J. (2007). Photoplethysmography and its application in clinical physiological measurement. *Physiological Measurement*, *28*(3). <https://doi.org/10.1088/0967-3334/28/3/R01>
- Amazfit. (2020). *Amazfit PowerBuds*. Amazfit. <https://www.amazfit.com/us/powerbuds.html>
- Ambiotex. (s. f.). *Ambiotex Smartshirt - Understand your heartbeat!* Ambiotex. Recuperado 7 de julio de 2021, de <https://www.ambiotex.com/en/#product>
- Analog Devices. (s. f.). AD620 Low Cost, Low Power Instrumentation Amplifier. En *Analog Devices*.
- Angulo Fuato, C. (2010). *Diseño e implementación de un pulsómetro digital basado en la fotopletismografía* (Número 2693) [Universitat Politecnica de Valencia]. <https://doi.org/10.1111/j.1467-8330.1974.tb00606.x>
- Apple. (2021, marzo 24). *Apple Watch Series 4 - Technical Specifications*. Apple. [https://support.apple.com/kb/SP778?locale=en\\_US](https://support.apple.com/kb/SP778?locale=en_US)
- Arcentales V, A., Triviño, R. D., Betancourt M, C., Yépez, I., Alulema, D., & Guamán, A. V. (2021). A Multivariate Signal Analysis of a Sensing Platform Prototype for Stress Detection. *Lecture Notes in Electrical Engineering*, *762 LNEE*(1), 63-77. [https://doi.org/10.1007/978-3-030-72208-1\\_6](https://doi.org/10.1007/978-3-030-72208-1_6)
- Arcentales Viteri, A. R. (2015). *Análisis de la interacción cardíaca y respiratoria en pacientes con cardiomiopatía y pacientes en proceso de extubación* [Universitat Politècnica de Catalunya (UPC) Institut]. <http://hdl.handle.net/2117/95819>
- Autosense Project. (s. f.). *AutoSense: A Wireless Sensor System to Quantify Personal Exposures to Psychosocial Stress and Addictive Substances in Natural Environments*. Recuperado 2 de julio de 2021, de <https://sites.google.com/site/autosenseproject/>
- Berrío García, N., & Mazo Zea, R. (2011). Estrés Académico. *Revista de Psicología: (Universidad de Antioquía)*, *3*(2), 65-82.
- Betancourt Mediavilla, C. K., & Yépez Narváez, I. A. (2018). *Diseño e implementación de una plataforma multisensado para el monitoreo de sujetos sanos sometidos a un test de inducción de estrés*. Universidad de las Fuerzas Armadas -ESPE.
- Betti, S., Lova, R. M., Rovini, E., Acerbi, G., Santarelli, L., Cabiati, M., Ry, S. Del, & Cavallo, F. (2018). Evaluation of an integrated system of wearable physiological sensors for stress monitoring in working environments by using biological markers. *IEEE Transactions on Biomedical*

- Engineering*, 65(8), 1748-1758. <https://doi.org/10.1109/TBME.2017.2764507>
- Billinghamurst, M., & Starner, T. (1999). New ways to manage information. *Computer*, 32(1), 57-64. <https://doi.org/10.1109/2.738305>
- Boucsein, W., Fowles, D. C., Grimnes, S., Ben-Shakhar, G., Roth, W. T., Dawson, M. E., & Filion, D. L. (2012). Publication recommendations for electrodermal measurements. *Psychophysiology*, 49(8), 1017-1034. <https://doi.org/10.1111/j.1469-8986.2012.01384.x>
- Bradt, J., Dileo, C., & Grocke, D. (2013). Music interventions for mechanically ventilated patients (Review) SUMMARY OF FINDINGS FOR THE MAIN COMPARISON. *Cochrane Database of Systematic Reviews*, CD006908(6). <https://doi.org/10.1002/14651858.CD006908.pub2.www.cochranelibrary.com>
- Brainbit. (2016). *Wearable EEG Headband*. Brainbit. <https://brainbit.com/>
- Brown, L., Grundlehner, B., Van De Molengraft, J., Penders, J., & Gyselinckx, B. (2009). Body area network for monitoring autonomic nervous system responses. *2009 3rd International Conference on Pervasive Computing Technologies for Healthcare - Pervasive Health 2009, PCTHealth 2009*, 10-12. <https://doi.org/10.4108/ICST.PERVASIVEHEALTH2009.5973>
- Busso, C., Deng, Z., Yildirim, S., Bulut, M., Lee, C. M., Kazemzadeh, A., Lee, S., Neumann, U., & Narayanan, S. (2004). Analysis of emotion recognition using facial expressions, speech and multimodal information. *ICMI'04 - Sixth International Conference on Multimodal Interfaces*, 205-211. <https://doi.org/10.1145/1027933.1027968>
- Can, Y. S., Chalabianloo, N., Ekiz, D., & Ersoy, C. (2019). Continuous stress detection using wearable sensors in real life: Algorithmic programming contest case study. *Sensors (Switzerland)*, 19(8). <https://doi.org/10.3390/s19081849>
- Candocia, M. (2017). *Converting Garmin FIT Files to CSV*. <https://maxcandocia.com/article/2017/Sep/22/converting-garmin-fit-to-csv/>
- Chi, Y. M., Wang, Y. Te, Wang, Y., Maier, C., Jung, T. P., & Cauwenberghs, G. (2012). Dry and noncontact EEG sensors for mobile brain-computer interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20(2), 228-235. <https://doi.org/10.1109/TNSRE.2011.2174652>
- Cooking Hacks. (2012). *e-Health Sensor Platform Schematic*. Cooking Hacks.
- Cooking Hacks. (2017). *MySignals HW v2 - eHealth and Medical IoT Development Platform for Arduino*. <https://www.cooking-hacks.com/mysignals-hw-ehealth-medical-biometric-iot-platform-arduino-tutorial/index.html#step5>
- Cruz Varela, I. E. (2021). *Análisis de la correlación de estímulos auditivos y audiovisuales con el sistema cardiorrespiratorio de sujetos sanos* [Universidad de las Fuerzas Armadas - ESPE]. [http://dspace.ucuenca.edu.ec/bitstream/123456789/35612/1/Trabajo de Titulacion.pdf](http://dspace.ucuenca.edu.ec/bitstream/123456789/35612/1/Trabajo%20de%20Titulacion.pdf) <https://educacion.gob.ec/wp-content/uploads/downloads/2019/01/GUIA-METODOLOGICA-EF.pdf>
- De Santos Sierra, A., Sánchez Ávila, C., Guerra Casanova, J., & Bailador Del Pozo, G. (2011). A

- stress-detection system based on physiological signals and fuzzy logic. *IEEE Transactions on Industrial Electronics*, 58(10), 4857-4865. <https://doi.org/10.1109/TIE.2010.2103538>
- Dimberg, U. (1990). Facial Electromyography and Emotional Reactions. En *Psychophysiology* (Vol. 27, Número 5, pp. 481-494). <https://doi.org/10.1111/j.1469-8986.1990.tb01962.x>
- Empatica. (s. f.). *Real-time physiological signals | E4 EDA/GSR sensor*. Recuperado 2 de julio de 2020, de <https://www.empatica.com/en-int/research/e4/>
- Empatica. (2019). *E4 wristband data*. Empatica. <https://www.empatica.com/en-int/research/e4/>
- Evans, J. D. (1996). *Straightforward Statistics For The Behavioral Sciences*. Thomson Brooks/Cole Publishing Co.
- Fernández Megías, C. (2012). *Inducción de Emociones en Condiciones Experimentales: Un Banco de Estímulos Audiovisuales*. Universitat Autònoma de Barcelona.
- Fletcher, R. R., Poh, M. Z., & Eydgahi, H. (2010). Wearable sensors: Opportunities and challenges for low-cost health care. *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC'10*, 1763-1766. <https://doi.org/10.1109/IEMBS.2010.5626734>
- Garmin Ltd. (s. f.). *Garmin HRM-Pro™ | Heart Rate Monitor*. Garmin Ltd. Recuperado 7 de julio de 2021, de <https://buy.garmin.com/en-US/US/p/682155>
- Garmin Ltd. (2018). *Garmin vivosmart® 4 | Fitness Activity Tracker | Pulse Ox*. Garmin Ltd. <https://buy.garmin.com/en-US/US/p/605739>
- Garmin Ltd. (2019). *vívactive® 4 | Smartwatch with GPS | GARMIN*. Garmin Ltd. <https://buy.garmin.com/en-US/US/p/643382>
- Gedam, S., & Paul, S. (2021). A Review on Mental Stress Detection using Wearable Sensors and Machine Learning Techniques. *IEEE Access*, XX, 1-1. <https://doi.org/10.1109/access.2021.3085502>
- Gerrards-Hesse, A., Spies, K., & Hesse, F. W. (1994). Experimental inductions of emotional states and their effectiveness: A review. *British Journal of Psychology*, 85(1), 55-78. <https://doi.org/10.1111/j.2044-8295.1994.tb02508.x>
- Giannakakis, G., Padiaditis, M., Manousos, D., Kazantzaki, E., Chiarugi, F., Simos, P. G., Marias, K., & Tsiknakis, M. (2017). Stress and anxiety detection using facial cues from videos. *Biomedical Signal Processing and Control*, 31, 89-101. <https://doi.org/10.1016/j.bspc.2016.06.020>
- Giannakakis, Giorgos, Grigoriadis, D., Giannakaki, K., Simantiraki, O., Roniotis, A., & Tsiknakis, M. (2019). Review on psychological stress detection using biosignals. *IEEE Transactions on Affective Computing*, 1-22. <https://doi.org/10.1109/TAFFC.2019.2927337>
- Giannakakis, Giorgos, Trivizakis, E., Tsiknakis, M., & Marias, K. (2019). A novel multi-kernel 1D convolutional neural network for stress recognition from ECG. *2019 8th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW)*, 273-276. <https://doi.org/10.1109/ACIIW.2019.8925020>

- Giles, D., Draper, N., & Neil, W. (2016). Validity of the Polar V800 heart rate monitor to measure RR intervals at rest. *European Journal of Applied Physiology*, 116(3), 563-571. <https://doi.org/10.1007/s00421-015-3303-9>
- Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C. K., & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 101(23). <https://doi.org/10.1161/01.cir.101.23.e215>
- Grice, J. W. (2013). *Pearson's Correlation Coefficient*.
- Grove. (2014). *Grove - GSR Sensor*. [https://wiki.seeedstudio.com/Grove-GSR\\_Sensor/](https://wiki.seeedstudio.com/Grove-GSR_Sensor/)
- Haghi, M., Thurow, K., & Stoll, R. (2017). Wearable devices in medical internet of things: Scientific research and commercially available devices. *Healthcare Informatics Research*, 23(1), 4-15. <https://doi.org/10.4258/hir.2017.23.1.4>
- Hernando, D., Garatachea, N., Casajús, J. A., & Bailón, R. (2017). Comparison of heart rate variability assessment during exercise from polar RS800 and ECG. *Computing in Cardiology*, 44, 1-4. <https://doi.org/10.22489/CinC.2017.206-225>
- Hernando, D., Roca, S., Sancho, J., Alesanco, Á., & Bailón, R. (2018). Validation of the apple watch for heart rate variability measurements during relax and mental stress in healthy subjects. *Sensors (Switzerland)*, 18(8). <https://doi.org/10.3390/s18082619>
- Jadoun, N. K., Kushwah, A. S., Barodiya, P., & Holani, U. (2012). Need of stress management. *Journal of management value & ethics*, 2(9826734821). [http://shodhganga.inflibnet.ac.in/bitstream/10603/111123/14/second paper need of stress management.pdf](http://shodhganga.inflibnet.ac.in/bitstream/10603/111123/14/second%20paper%20need%20of%20stress%20management.pdf)
- Keelawat, P., Thammasan, N., Numao, M., & Kijirikul, B. (2019). Spatiotemporal Emotion Recognition using Deep CNN Based on EEG during Music Listening. *arXiv*, 1, 1-11. <http://arxiv.org/abs/1910.09719>
- Klinkien, R. (s. f.). *garminconnect · PyPI*. Recuperado 16 de julio de 2021, de <https://pypi.org/project/garminconnect/>
- Koelsch, S., & Jancke, L. (2015). Music and the heart. *European Heart Journal*, 36(44), 3043-3048. <https://doi.org/10.1093/eurheartj/ehv430>
- Kreibig, S. D. (2010). Autonomic nervous system activity in emotion: A review. *Biological Psychology*, 84(3), 394-421. <https://doi.org/10.1016/j.biopsycho.2010.03.010>
- Lu, Y., Zheng, W. L., Li, B., & Lu, B. L. (2015). Combining eye movements and EEG to enhance emotion recognition. *IJCAI International Joint Conference on Artificial Intelligence, 2015-Janua(Ijcai)*, 1170-1176.
- Luque Ordóñez, J. (2016). *Dispositivos y tecnologías wearables*.
- Machado Fernández, J. R., & Anishchenko, L. (2018). Mental stress detection using bioradar respiratory signals. *Biomedical Signal Processing and Control*, 43, 244-249.

<https://doi.org/10.1016/j.bspc.2018.03.006>

- Madhav, K. V., Ram, M. R., Krishna, E. H., Reddy, K. N., & Reddy, K. A. (2010). Estimation of respiratory rate from principal components of photoplethysmographic signals. *Proceedings of 2010 IEEE EMBS Conference on Biomedical Engineering and Sciences, IECBES 2010, December*, 311-314. <https://doi.org/10.1109/IECBES.2010.5742251>
- Mayo Clinic. (s. f.). *Monitor Holter*. Mayo Clinic. Recuperado 6 de julio de 2021, de <https://www.mayoclinic.org/es-es/tests-procedures/holter-monitor/about/pac-20385039>
- McEwen, B., & Sapolsky, R. (2006). El estrés y su salud. *The Journal of Clinical Endocrinology & Metabolism*, 91(2), 0-0. <https://doi.org/10.1210/jcem.91.2.9993>
- Meijer, I., & Morssink, B. (2020). *Stress Detection System Using ECG and Respiratory Signals* .
- Menghini, L., Gianfranchi, E., Cellini, N., Patron, E., Tagliabue, M., & Sarlo, M. (2019). Stressing the accuracy: Wrist-worn wearable sensor validation over different conditions. *Psychophysiology*, 56(11), 1-15. <https://doi.org/10.1111/psyp.13441>
- Messmer, K., Blackman, D., Cumming, R., & Coyne, K. (2017). *Wearable Devices and Mobile Technology in Clinical Trials | Evidera* (Número November 2017). <https://www.evidera.com/wp-content/uploads/2017/11/Wearable-Devices-and-Mobile-Technology-in-Clinical-Trials.pdf>
- Müller, S. C., & Fritz, T. (2015). Stuck and frustrated or in flow and happy: Sensing developers' emotions and progress. *Proceedings - International Conference on Software Engineering*, 1, 688-699. <https://doi.org/10.1109/ICSE.2015.334>
- NeuroSky. (2020). *EEG Sensors - EEG Headsets | NeuroSky*. Neurosky. <http://neurosky.com/biosensors/eeg-sensor/biosensors/>
- Ollander, S., Godin, C., Campagne, A., & Charbonnier, S. (2017). A comparison of wearable and stationary sensors for stress detection. *2016 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2016 - Conference Proceedings*, 4362-4366. <https://doi.org/10.1109/SMC.2016.7844917>
- Parak, J., & Korhonen, I. (2014). Evaluation of wearable consumer heart rate monitors based on photoplethysmography. *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2014*, 3670-3673. <https://doi.org/10.1109/EMBC.2014.6944419>
- Parak, J., Tarniceriu, A., Renevey, P., Bertschi, M., Delgado-Gonzalo, R., & Korhonen, I. (2015). Evaluation of the beat-to-beat detection accuracy of PulseOn wearable optical heart rate monitor. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2015-Novem*, 8099-8102. <https://doi.org/10.1109/EMBC.2015.7320273>
- Pardamean, B., Soeparno, H., Mahesworo, B., Budiarto, A., & Baurley, J. (2019). Comparing the accuracy of multiple commercial wearable devices: A method. *Procedia Computer Science*, 157, 567-572. <https://doi.org/10.1016/j.procs.2019.09.015>

- Pareek, N. (2020, diciembre 30). *Creating an ECG Data Stream with Polar device | by Pareeknikhil | Towards Data Science*. towards data science. <https://towardsdatascience.com/creating-a-data-stream-with-polar-device-a5c93c9ccc59>
- Pasadyn, S. R., Soudan, M., Gillinov, M., Houghtaling, P., Phelan, D., Gillinov, N., Bittel, B., & Desai, M. Y. (2019). Accuracy of commercially available heart rate monitors in athletes: A prospective study. *Cardiovascular Diagnosis and Therapy*, 9(4), 379-385. <https://doi.org/10.21037/cdt.2019.06.05>
- Phan, K. L., Wager, T., Taylor, S. F., & Liberzon, I. (2002). Functional neuroanatomy of emotion: A meta-analysis of emotion activation studies in PET and fMRI. *NeuroImage*, 16(2), 331-348. <https://doi.org/10.1006/nimg.2002.1087>
- Plarre, K., Raij, A., Hossain, S. M., Ali, A. A., Nakajima, M., Al'Absi, M., Ertin, E., Kamarck, T., Kumar, S., Scott, M., Siewiorek, D., Smailagic, A., & Wittmers, L. E. (2011). Continuous inference of psychological stress from sensory measurements collected in the natural environment. *Proceedings of the 10th ACM/IEEE International Conference on Information Processing in Sensor Networks, IPSN'11*, 97-108.
- Plews, D. J., Scott, B., Altini, M., Wood, M., Kilding, A. E., & Laursen, P. B. (2017). Comparison of heart-rate-variability recording with smartphone photoplethysmography, polar H7 chest strap, and electrocardiography. *International Journal of Sports Physiology and Performance*, 12(10), 1324-1328. <https://doi.org/10.1123/ijsp.2016-0668>
- Polar. (s. f.-a). *H7 HR Sensor | Polar España*. Recuperado 29 de junio de 2020, de [https://support.polar.com/es/ayuda/H7\\_HR\\_Sensor](https://support.polar.com/es/ayuda/H7_HR_Sensor)
- Polar. (s. f.-b). *Polar Measurement Data Specifications*.
- Polar. (2016). *Heart Rate Monitors, activity trackers and bike computers*. Polar Inc. <https://www.polar.com/us-en>
- Polar. (2019a). *Introducing the Polar OH1 optical heart rate sensor*. Polar Inc. <https://www.polar.com/us-en/products/accessories/oh1-optical-heart-rate-sensor>
- Polar. (2019b). *Manual del Usuario, Polar OH1*.
- Polar. (2019c). Polar H10 Heart Rate Sensor System. En *Polar Research and Technology* (Vol. 1, Número 6).
- Push. (2020). *PUSH Pro Band 2.0*. <https://www.trainwithpush.com/product-system>
- Ramasamy, S., & Balan, A. (2018). Wearable sensors for ECG measurement: a review. *Sensor Review*, 38(4), 412-419. <https://doi.org/10.1108/SR-06-2017-0110>
- Randazzo, V., Ferretti, J., & Pasero, E. (2020). A wearable smart device to monitor multiple vital parameters—VITAL ECG. *Electronics (Switzerland)*, 9(2), 1-13. <https://doi.org/10.3390/electronics9020300>
- Raza Raza, M. A. (2016). *Caracterización de la variabilidad del ritmo cardíaco y de las pendientes del complejo QRS en sujeto sanos sometidos a estímulos musicales*. Universidad de las

Fuerzas Armadas -ESPE.

- Rizwan, M. F., Farhad, R., Mashuk, F., Islam, F., & Imam, M. H. (2019). Design of a biosignal based stress detection system using machine learning techniques. *1st International Conference on Robotics, Electrical and Signal Processing Techniques, ICREST 2019*, 364-368. <https://doi.org/10.1109/ICREST.2019.8644259>
- Scosche. (2021). *Scosche Rhythm24 Waterproof Heart Monitor Armband*. Scosche. <https://www.scosche.com/rhythm24-waterproof-armband-heart-rate-monitor>
- Searle, A., & Kirkup, L. (2000). A direct comparison of wet , dry and insulating bioelectric recording electrodes. *Physiol*, 21, 271-283. <http://stacks.iop.org/0967-3334/21/i=2/a=307>
- Seneviratne, S., Hu, Y., Nguyen, T., Lan, G., Khalifa, S., Thilakarathna, K., Hassan, M., & Seneviratne, A. (2017). A Survey of Wearable Devices and Challenges. *IEEE Communications Surveys and Tutorials*, 19(4), 2573-2620. <https://doi.org/10.1109/COMST.2017.2731979>
- Sensoria. (2019). *Sensoria fitness Socks*. <https://www.sensoriafitness.com/smartsocks>
- Setz, C., Arnrich, B., Schumm, J., Marca, R. La, Tr, G., & Ehlert, U. (2010). Discriminating Stress From Cognitive Load Using a Wearable EDA Device. *IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE*, 14(2), 410-417.
- Shi, Y., Nguyen, M. H., Blitz, P., French, B., Fisk, S., Torre, F. D. La, Smailagic, A., & Siewiorek, D. P. (2010). Personalized Stress Detection from Physiological Measurements. *Second International Symposium on Quality of Life Technology*. <http://www.shrs.pitt.edu/qolt/qolt.aspx?id=2212>
- Shier, R. (2004). *The Wilcoxon signed rank sum test*. Statstutor.ac.uk. <http://www.statstutor.ac.uk/resources/uploaded/wilcoxonsignedranktest.pdf>
- Shimmer Sensing. (2020). *Wearable GSR Sensor | Shimmer Galvanic Skin Response Sensor | EDA sensor*. Shimmer. <https://www.shimmersensing.com/products/shimmer3-wireless-gsr-sensor>
- Tamura, T., Maeda, Y., Sekine, M., & Yoshida, M. (2014). Wearable photoplethysmographic sensors—past and present. *Electronics*, 3(2), 282-302. <https://doi.org/10.3390/electronics3020282>
- Texas Instruments. (2013). *Filter Design Tool*. Texas Instruments. <https://webench.ti.com/filter-design-tool/filter-type>
- Torrado, J. C. (2018). *Tecnologías móviles y wearables para la autorregulación emocional de personas con Trastornos del Espectro Autista*. [https://repositorio.uam.es/bitstream/handle/10486/684214/torrado\\_vidal\\_juan\\_carlos.pdf?sequence=1&isAllowed=y](https://repositorio.uam.es/bitstream/handle/10486/684214/torrado_vidal_juan_carlos.pdf?sequence=1&isAllowed=y)
- Townsend, K. (2014). Introduction to Bluetooth Low Energy. En *2014-04-17*. <https://doi.org/10.1128/AEM.66.7.3083-3087.2000.Updated>
- Udovičić, G., Derek, J., Russo, M., & Sikora, M. (2017). Wearable Emotion Recognition system

based on GSR and PPG signals. *MMHealth 2017 - Proceedings of the 2nd International Workshop on Multimedia for Personal Health and Health Care, co-located with MM 2017*, 53-59. <https://doi.org/10.1145/3132635.3132641>

- Varon, C., Lazaro, J., Bolea, J., Hernando, A., Aguilo, J., Gil, E., Van Huffel, S., & Bailon, R. (2019). Unconstrained Estimation of HRV Indices after Removing Respiratory Influences from Heart Rate. *IEEE Journal of Biomedical and Health Informatics*, 23(6), 2386-2397. <https://doi.org/10.1109/JBHI.2018.2884644>
- Wang, R., Blackburn, G., Desai, M., Phelan, D., Gillinov, L., Houghtaling, P., & Gillinov, M. (2017). Accuracy of wrist-worn heart rate monitors. *JAMA Cardiology*, 2(1), 104-106. <https://doi.org/10.1001/jamacardio.2016.3340>
- Wijsman, J., Grundlehner, B., Liu, H., Hermens, H., & Penders, J. (2011). Towards mental stress detection using wearable physiological sensors. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 1798-1801. <https://doi.org/10.1109/IEMBS.2011.6090512>
- Wijsman, J., Grundlehner, B., Penders, J., & Hermens, H. (2013). Trapezius muscle EMG as predictor of mental stress. *Transactions on Embedded Computing Systems*, 12(4). <https://doi.org/10.1145/2485984.2485987>