



UNIVERSIDAD DE CONCEPCIÓN

FACULTAD DE INGENIERÍA

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

**DESARROLLO DE UN SISTEMA *WEARABLE* PARA LA
DETECCIÓN DE ESTRÉS MEDIANTE APRENDIZAJE
AUTOMÁTICO BASADO EN RITMO CARDIACO**

Tesis para optar al grado de Magíster en Ciencias de la Ingeniería con mención
en Ingeniería Eléctrica

ANDRÉS JACOBO NAVARRO CERMENATI

CONCEPCIÓN-CHILE

2021

Profesor Guía: Pablo Esteban Aqueveque Navarro

Dpto. de Ingeniería Eléctrica, Facultad de Ingeniería

Universidad de Concepción

Profesor Co-Guía: Aníbal Morales Montecinos

Dpto. de Ingeniería Eléctrica, Facultad de Ingeniería

Universidad Católica de la Santísima Concepción

Esta tesis forma parte del proyecto FONDECYT N°1201543

Ninguna parte de esta tesis puede reproducirse o transmitirse bajo ninguna forma o por ningún medio o procedimiento, sin permiso por escrito del autor.

Este estudio ha sido financiado parcialmente por la Agencia Nacional de Investigación y Desarrollo y forma parte del Proyecto Fondecyt N° 1201543.

Este estudio ha sido financiado parcialmente por el programa Capital Semilla de CORFO (18CS-96220).



AGRADECIMIENTOS

Llegó el momento de finalizar una etapa, la cual está plasmada en esta Tesis, pero no llegue solo hasta aca y por ello es necesario agradecer a las personas e instituciones que me apoyaron en este camino. En primer lugar, a las dos personas que me dieron su apoyo tanto en la licenciatura, como en el magister y en este momento de pandemia global, mi señora esposa María Josse Sánchez Toledo, quien es mi pilar, mi amiga, mi amante y mi confidente, sin ella esta tesis no existiría, y en igual grado a mi hija Javi quien igual me apoyo, hizo reír y rabiarse en este momento.

A mis padres y abuelos por estar ahí cuando se le necesitaba y recordarme lo importante que es la familia en todo momento.

Agradezco a mis profesores guías, Dr. Pablo Aqueveque y Dr. Aníbal Morales, por su ayuda, retos, consejos no solo por el magister si no que en la vida. A todo el laboratorio de Biomédica por la ayuda constante y esos gratos momentos de risa que se daban cuando era necesario y cuando no, igual.

Agradezco a Fondecyt (proyecto 1201543) por su apoyo financiero durante el desarrollo de mi magister.

Y, por último, pero no menos importante al Javo, Wlady, Edo y Britam (sin importancia de orden) por estar siempre en las malas y en las buenas, escuchar mis reclamos, momentos de debilidad y de fortaleza sin flaquear en ningún momento.

TABLA DE CONTENIDO

| | |
|---|-----------|
| ÍNDICE DE TABLAS | 8 |
| ÍNDICE DE FIGURAS | 9 |
| ACRONIMOS..... | 11 |
| RESUMEN..... | 12 |
| CAPÍTULO 1. INTRODUCCIÓN | 15 |
| 1.1 Introducción..... | 15 |
| 1.2 Estrés. | 16 |
| 1.2.1 Tipos de detección de estrés | 19 |
| 1.3 Posicionamiento de electrodos para la medición de ECG | 37 |
| 1.4 Discusión | 40 |
| CAPÍTULO 2. HIPÓTESIS, OBJETIVOS Y METODOLOGÍA | 42 |
| 2.1 Hipótesis..... | 42 |
| 2.2 Objetivo General..... | 42 |
| 2.3 Objetivo Específicos | 42 |
| 2.4 Alcances y limitaciones..... | 43 |
| 2.5 Financiamiento | 43 |

| | | |
|--|---------------------------------------|----|
| 2.6 | Metodología..... | 43 |
| CAPÍTULO 3. DISEÑO Y DESARROLLO DE DISPOSITIVO DE MEDICIÓN DE VARIABLES FISIOLÓGICAS..... 46 | | |
| 3.1 | Introducción..... | 46 |
| 3.2 | Variables fisiológicas..... | 47 |
| 3.2.1 | Electrocardiograma..... | 48 |
| 3.3.1 | Diseño del Hardware..... | 56 |
| 3.3.2 | Implementación del Hardware..... | 60 |
| 3.4 | Firmware..... | 64 |
| CAPÍTULO 4. ANALISIS DE DATOS, ALGORITMO PARA LA DETECCIÓN DE ESTRÉS Y RESULTADOS..... 69 | | |
| 4.1 | Introducción..... | 69 |
| 4.2 | Obtención de datos..... | 70 |
| 4.3 | Preprocesamiento..... | 72 |
| 4.4 | Análisis de datos..... | 73 |
| 4.4.1 | Análisis de distribución..... | 75 |
| 4.4.2 | Análisis bidimensional..... | 77 |
| 4.4.3 | Análisis tridimensional..... | 79 |
| 4.5 | Algoritmo de detección de estrés..... | 80 |

| | | |
|-------------|---|-----|
| 4.6 | Resultados..... | 83 |
| 4.6.1 | Rendimiento de HR para clasificación de estrés..... | 85 |
| 4.6.2 | Rendimiento de Delta HR para clasificación de estrés | 85 |
| 4.6.3 | Rendimiento de Delta HR y HR para clasificación de estrés | 86 |
| 4.6.4 | Rendimiento de HR y Temperatura para clasificación de estrés | 86 |
| 4.6.5 | Rendimiento de Delta HR y Temperatura para clasificación de estrés 87 | |
| 4.6.6 | Rendimiento de HR, Delta HR, Temperatura para clasificación de estrés 88 | |
| 4.6.7 | Rendimiento de HR, Delta HR, Temperatura y datos del paciente para clasificación de estrés | 89 |
| 4.7 | Conclusión..... | 90 |
| CAPÍTULO 5. | CONCLUSIÓN Y DISCUSIÓN | 93 |
| 5.1 | Discusión | 93 |
| 5.2 | Conclusión..... | 94 |
| 5.3 | Trabajos futuros..... | 96 |
| CAPÍTULO 6. | BIBLIOGRAFIA | 98 |
| CAPÍTULO 7. | ANEXOS | 107 |
| 7.1 | Encuestas para la detección de estrés..... | 107 |

| | | |
|-------|--|-----|
| 7.1.1 | PSS en sus tres versiones [13] | 107 |
| 7.1.2 | DASS en su versión de 21 preguntas o DASS-21[13] | 109 |
| 7.2 | Circuitos electrónicos..... | 110 |
| 7.2.1 | Etapa Procesamiento..... | 110 |
| 7.2.2 | Etapa Electrocardiograma..... | 111 |
| 7.2.3 | Etapa Filtros..... | 111 |
| 7.2.4 | Temperatura corporal..... | 112 |
| 7.2.5 | Etapa Energización..... | 113 |



ÍNDICE DE TABLAS

| | |
|--|----|
| Tabla 1-1 : Características extraídas de la señal ECG [19] | 29 |
| Tabla 3-1 : Derivaciones ECG [36] | 50 |
| Tabla 3-2: Tiempo de vida útil de tipo de electrodos..... | 52 |
| Tabla 4-1 : Rendimiento de HR..... | 85 |
| Tabla 4-2 : Rendimiento de Delta HR | 86 |
| Tabla 4-3 Rendimiento de Delta HR y HR | 86 |
| Tabla 4-4: Rendimiento de HR y Temperatura | 87 |
| Tabla 4-5: Rendimiento de Delta HR y Temperatura | 88 |
| Tabla 4-6: Rendimiento de HR, Delta HR y Temperatura | 88 |
| Tabla 4-7: Rendimiento de HR, Delta HR, Temperatura y datos del paciente.. | 89 |

ÍNDICE DE FIGURAS

| | |
|--|----|
| Figura 1-1 :Glándulas suprarrenales, productoras de cortisol [27]..... | 22 |
| Figura 1-2: (a) Esquemáticos del dispositivo, (b) el dispositivo adaptado para la obtención de muestras, (c) sujeto de prueba con el dispositivo..... | 23 |
| Figura 1-3 Parche bio-sensor para cortisol propuesto por Parlak et al. [31] | 26 |
| Figura 1-4: Esquema del parche bio-sensor de cortisol [31]..... | 26 |
| Figura 1-5 Disposición de los sensores para medir variables fisiológicas mientras se realizan las pruebas de detección de estrés | 27 |
| Figura 1-6 Diagrama del procesamiento de datos [20] | 31 |
| Figura 1-7 Screenshots de los test utilizados por F. Sun et al. [20] | 32 |
| Figura 1-8 Condiciones experimentales realizados en la prueba de F. Sun et al. [20]..... | 33 |
| Figura 1-9 Diagrama General del sistema utilizado por M. Villarejo et al. [21]. | 34 |
| Figura 1-10: Modelo propuesto por Sritamprakash et al [23] | 35 |
| Figura 1-11 : Cambios de HR ante momentos de estrés realizado por E. Silbolboro [55]..... | 37 |
| Figura 1-12 : Sistemas wearable con obtención de ECG [39] | 39 |
| Figura 1-13 : Sistemas wearable comerciales que obtienen EMG..... | 40 |
| Figura 3-1: Ondas P,QRS, T e intervalos PR y ST [35] | 49 |
| Figura 3-2: Construcción del ECG a partir de la conducción de impulsos en el corazón [36], en (e) se observa la despolarización de los ventrículos, desde el interior hacia el exterior. Mientras que (g) los ventrículos se repolarizan. | 49 |

| | |
|---|----|
| Figura 3-3 : a) Electrodo de tipo "almohada" b) Electrodo de tipo "cobertura" .. | 52 |
| Figura 3-4 : Diagrama de posicionamiento de los electrodos | 53 |
| Figura 3-5 : Cinto medidor de ECG (elaboración propia)..... | 54 |
| Figura 3-6 : Intervalo R-R de un ECG..... | 54 |
| Figura 3-7 : Esquema general del sistema de medición | 56 |
| Figura 3-8 : Circuito esquemático de la obtención de ECG | 57 |
| Figura 3-9 : Configuración recomendada para Monitor Cardíaco | 58 |
| Figura 3-10 : Señal obtenida del sensor de ECG..... | 58 |
| Figura 3-11: Placa número uno del dispositivo medidor de variables fisiológicas. | 62 |
| Figura 3-12 : Placa número dos del dispositivo medidor de variables fisiológicas | 63 |
| Figura 3-13 : Sistema de medición: (a) Placa uno, pre procesa datos obtenidos, (b) placa dos, obtiene los datos de la interfaz, (c) interfaz persona-hardware .. | 64 |
| Figura 3-14 : Diagrama de flujo del Setup | 65 |
| Figura 3-15 : Diagrama de flujo del núcleo 0 | 66 |
| Figura 3-16 : Diagrama de flujo del núcleo 1 | 68 |

ACRONIMOS

| | |
|---------|---|
| P.S.S. | : Escala de Estrés Percibido. |
| D.A.S.S | : Escala de Depresión, Ansiedad y Estrés. |
| A.N.N. | : Artificial Neural Network. |
| S.V.M. | : Support Vector Machine |
| K-N.N | : K-Nearest Neighbor. |
| C.B.R. | : Case-Based Reasoning. |
| F.T. | : Temperatura de los dedos (Del inglés, Finger Temperature). |
| H.V.R. | : Variabilidad de la frecuencia cardiaca (Del inglés Heart Rate Variability). |
| H.R | : Frecuencia Cardiaca (Del inglés, Heart Rate). |
| D.H.R | : Delta Frecuencia Cardiaca |
| E.C.G. | : Electrocardiograma. |
| E.M.G. | : Electromiograma. |
| G.S.R. | : Respuesta Galvánica de la piel (Del inglés, Galvanic Skin Response). |
| B.T. | : Temperatura corporal (Del inglés, Body Temperature). |
| F.R. | : Frecuencia Respiratoria. |
| R.A. | : Brazo derecho (Del inglés, right arm). |
| L.A. | : Brazo izquierdo (Del inglés, left arm). |
| R.L. | : Pierna derecha (Del inglés, right leg). |
| L.L. | : Pierna izquierda (Del inglés, left leg). |
| I.2.C. | : Circuito Inter-Integrado (Del inglés, Inter-Integrated Circuit) |

RESUMEN

El estrés es un mecanismo natural de los seres vivos para abordar situaciones peligrosas, específicamente en el ser humano es la reacción del cuerpo a un desafío o momento demandante tanto físico como mental. Si esta condición se mantiene por tiempos prolongados se transforma en un estrés crónico que puede generar problemas graves en la salud de las personas.

Actualmente es uno de los principales problemas laborales en Chile. Durante el año 2016 el 21% de las licencias médicas aprobadas se asociaban a enfermedades mentales ubicándose en el primer puesto, de las cuales un 20,7% corresponde a estrés, 45% a episodios depresivos y 24,9% a otros trastornos de ansiedad, mientras que para el año 2019 la cantidad de licencias médicas aprobadas asociadas a enfermedades mentales subió a un 24,3%.

El estrés genera problemas físicos, psicológicos y conductuales y en casos muy extremos la muerte de la persona. Actualmente para poder medir el estrés existen principalmente tres métodos a nivel mundial; el primer método es por cuestionarios o encuestas, el segundo método se basa en la medición de cortisol salival y el tercer método es por medición de variables fisiológicas.

Esta tesis realiza una investigación relacionada con el tercer método de medición y tiene como principal objetivo desarrollar un sistema *wearable* que, mediante la medición de variables fisiológicas como ritmo cardíaco (H.R) y herramientas de aprendizaje automático, permita detectar estrés en personas.

Se desarrolla un dispositivo wearable el cual mide temperatura y Heart Rate. Este último se mide en base a ECG, el cual es obtenido mediante electrodos textiles. Para la creación de los electrodos textiles se estudia los diseños existentes tanto comerciales como de laboratorio y se determina su posición y formato más idónea para la obtención de ECG.

Debido a la pandemia generada por la enfermedad del coronavirus 2019 (COVID-19), en primera instancia, se obtiene una base de datos previamente etiquetada desde PhysioNet ("*Non-EEG Dataset for Assessment of Neurological Status*"), cuyos datos fueron analizados mediante estadísticas descriptivas para determinar cómo las variables afecta al sistema, para luego realizar un análisis de relación entre variables donde se observa que existe una concentración de datos relacionados a Delta Heart Rate y que la temperatura no afecta mayormente en la clasificación de estados de estrés y relajó.

Debido a lo antes expuesto, y según lo observado en el estado del arte, se determina que los mejores modelos a utilizar corresponden a aquellos de clasificación binaria, específicamente los clasificadores KNN (K-Nearest Neighbor), Support Vector Machine y Naive Bayes. Posteriormente, en base a la cantidad de datos contenidos de la base de datos, se define utilizar 16 personas (80%) como entrenamiento y verificación del modelo y 4 personas (20%) para pruebas del estado de estrés en dichas personas.

Los principales resultados indican que el mejor clasificador corresponde a KNN cuando se utilizan todas las variables consideradas y Delta Heart Rate, con una

exactitud (accuracy) promedio de 68.5% y 70.5% respectivamente y F1, variable que combina las medidas de precisión y exhaustividad en un solo valor, de 73.47% y 70.74% respectivamente. Un buen desempeño en ambas métricas permite asegurar un resultado exacto, preciso y exhaustivo, evitando posibles resultados engañoso al considerar solo una la exactitud.

Estos resultados pueden mejorar si, en la base de datos utilizada, se incorporarán una mayor cantidad de personas sanas y personas que padecen de estrés crónico, ya que así el modelo podría reconocer de mejor manera los estados de estrés y relajación.



CAPÍTULO 1. INTRODUCCIÓN

1.1 Introducción

El estrés es uno de los principales problemas laborales en Chile. En una encuesta realizada por la Mutual de Seguridad y GFK [1] se observó que el 66% de los encuestados indica que el principal problema en la seguridad laboral es el estrés. Sumado a la agitada vida actual, hacen que el estrés sea una problemática relevante para la población chilena y también para los empleadores ¿Pero de qué manera puede afectar el estrés en la vida de los trabajadores chilenos?

Los efectos negativos del estrés de los trabajadores que afectan en el ámbito laboral se generan cuando este se mantiene por largos periodos de tiempo, lo cual se traduce en problemas físicos, psicológicos y conductuales, entre los cuales tenemos [4]:

- Físicos: Problemas cardiovasculares, alergias, problemas cutáneos, migrañas, dificultades respiratorias, problemas de sueño, problemas gastrointestinales.
- Psicológicos: Ansiedad, aburrimiento, frustración, irritabilidad, aislamiento, baja concentración, pérdida de memoria, dificultades para tomar decisiones.
- Conductuales: Agresividad, abuso del alcohol o drogas, trastornos alimenticios, conflictos, ausentismo laboral, disminución de la

productividad, mayor predisposición a tener accidentes.

Todos estos problemas desencadenan una baja en la productividad de los trabajadores de diversas empresas, tanto por un mal desempeño como por ausentismo laboral, que queda de manifiesto ya que en el año 2016 se aprobaron 5.027.060 licencias médicas en las cuales un 21% de los casos fueron aprobadas por enfermedades mentales, y de estas 20.7% corresponde a estrés [2].

Debido a esta realidad, las empresas han buscado e implementado soluciones para bajar los niveles de estrés, sin embargo, estos son reactivos y se llevan a cabo una vez que se “descubre” que la persona este estresada, una vez que ya fue diagnosticada. Por lo tanto, es de suma importancia poder detectar el estrés en etapas tempranas y evitar, de esa manera, todos los problemas anteriormente mencionados.

Por lo tanto, en este trabajo se pre procesa la frecuencia cardiaca (HR) obteniendo la variable Delta HR, luego se analizan las variables de HR, Delta HR y temperatura corporal para estudiar su comportamiento tanto individualmente como en conjunto y por último se utiliza aprendizaje automático para detectar estrés en climas laborales.

1.2 Estrés.

En 1926 Hans Selye empezó a desarrollar su teoría respecto a la manera en que el estrés afecta a la capacidad de enfrentarse a lesiones o enfermedades. Por medio de este estudio Hans descubrió que los pacientes estudiados presentan

un grupo de síntomas similares, este conjunto de síntomas los nombro como “síndrome de estrés” o “síndrome de adaptación general” [5].

El síndrome de estrés puede dividirse en tres etapas:

- **Fase de alarma** [5]: *“Ante la percepción de una posible situación de estrés, el organismo empieza a desarrollar una serie de alteraciones de orden fisiológico y psicológico (ansiedad, inquietud, etc.) que lo predisponen para enfrentarse a la situación estresante. La aparición de estos síntomas está influida por factores como los parámetros físicos del estímulo ambiental (p.e. intensidad del ruido), factores de la persona, el grado de amenaza percibido y otros como el grado de control sobre el estímulo o la presencia de otros estímulos ambientales que influyen sobre la situación”.*
- **Fase de resistencia** [5]: *“Supone la fase de adaptación a la situación estresante. En ella se desarrollan un conjunto de procesos fisiológicos, cognitivos, emocionales y comportamentales destinados a “negociar” la situación de estrés de la manera menos lesiva para la persona. Si finalmente se produce una adaptación, esta no está exenta de costos, como: disminución de la resistencia general del organismo, disminución del rendimiento de la persona, menor tolerancia a la frustración o presencia de trastornos fisiológicos más o menos permanentes y también de carácter psicosomático”.*
- **Fase de agotamiento** [5]: *“Si la fase de resistencia fracasa, es decir, si los mecanismos de adaptación ambiental no resultan eficientes se entra*

en la fase de agotamiento donde los trastornos fisiológicos, psicológicos o psicosociales tienden a ser crónicos o irreversible”.

Actualmente el estrés puede considerarse como una sensación tanto de tensión física como emocional. Este en bajas cantidades es positivo, ya que ayuda a prepararse y evitar peligros. Pero si este dura grandes lapsus de tiempo puede dañar la salud.

El estrés al ser una respuesta ante estímulos externos es un sentimiento normal y este se puede clasificar principalmente de dos maneras:

- **Estrés agudo:** Este es a corto plazo. Se siente en momentos de tensión, como en discusiones, ante peligros al volante, entre otros. Gracias al estrés se puede controlar las situaciones peligrosas. También ocurre cuando se realizan actividades nuevas o emocionantes. Por lo tanto, es un sentimiento común.
- **Estrés crónico:** Este dura por períodos de tiempos prolongados, puede ser generado por problemas de dinero, un matrimonio infeliz o problemas en el trabajo. Cualquier tipo de estrés que continúa por semanas o meses es estrés crónico.

Si no existe un control en el estrés crónico, este empieza a generar problemas de salud [6], ya que no solo afecta anímicamente, si no también física y mentalmente influyendo a su vez a la conducta de la persona. Algunos de los problemas físicos presentes son dolores de cabeza, dolores en el pecho, fatiga,

a nivel anímico se presenta como ansiedad, agobio, fatiga y conductualmente se pueden presentar problemas como el comer en exceso, arranques de ira y abuso de drogas, en casos de niveles extremos puede provocar la muerte.

Un ejemplo de este último punto se presenta en Estados Unidos, donde Jeffrey Pfeffer, profesor de la Escuela de Postgrado de Negocios de la Universidad de Stanford indica que el estrés laboral está relacionado con la muerte de 120.000 trabajadores estadounidenses [7].

1.2.1 Tipos de detección de estrés

A. *Detección de estrés mediante encuestas*

Actualmente para poder detectar el estrés laboral se utilizan escalas para la percepción del estrés. Estas se usan para medir el estrés psicológico en el cual se encuentra la persona, para ello se han planteado diversas escalas. Entre las escalas más importante a nivel internacional se encuentra PSS y DASS [13].

PSS: Esta escala fue creada por Cohen Kamarck [8] en el año 1983. Es un cuestionario auto aplicable, las preguntas se centran en situaciones estresante de la vida diaria vividos durante el último mes. Existen tres formatos de esta encuesta:

- Formato original o PSS-14, en el cual se hacen 14 preguntas donde las preguntas (4,5,6,7,9,10 y 13) están realizadas de manera positiva, mientras que las restante de manera negativa y con el formato Likert [9] con cinco opciones por pregunta y se centran en los sentimientos y pensamientos vividos el último mes.

- El formato PSS-10 [10], donde Cohen y Williamson redujeron las preguntas a 10 y fue aplicada a 2.387 residentes de Estados Unidos. Posteriormente fue aplicada a alumnos universitarios también de Estados Unidos. Esta escala resulto ser muy útil para la medición de estrés en poblaciones no clínicas [8].
- El formato PSS-4, redefinido en su tercera versión realizada por Cohen [10], con cuatro preguntas y enfocada para realizarse como encuesta rápida.

En la actualidad se sigue usando esta escala (PSS) y ha sido traducida a 25 idiomas [12]. En el Anexo 7.1.1 se puede observar la PSS en sus tres versiones.

DASS: Esta escala fue creada por Covibonden en el año de 1995 [14], en un inicio se diseñó para evaluar síntomas de depresión y ansiedad, pero en pleno desarrollo de la escala, se pudo expandir a medición de estrés. El estrés se mide de acuerdo con que tan difícil es para el individuo estar relajado, también se mide la excitación nerviosa, su irritabilidad, agitación e impaciencia. La escala cuenta con 42 preguntas, donde las preguntas (1, 6, 8, 11, 12,14, 18, 22, 27, 29, 32, 33, 35 y 39) [15] son referentes al estrés.

Al igual que en el caso anterior, en el año de 1998 se hizo otra revisión logrando la versión DASS-21 a manos de Antony [16], para este caso las preguntas referentes al estrés son (1, 6, 8, 11, 12,14, 18).

Entre ambas versiones se utiliza más frecuentemente la DASS-21 [13], ya que cuenta con un menor número de preguntas. En Anexo 7.1.2 se puede observar las preguntas realizadas en DASS-21.

A nivel nacional existe el formulario SUSESO/ISTAS 21[17], el cual es validado y utilizado por la Superintendencia de Seguridad Social, este formulario está adaptado para los chilenos y evalúa los riesgos psicosociales. Este cuestionario tiene 5 dimensiones: Apoyo social en la empresa y calidad del liderazgo, Exigencias psicológicas en el trabajo, trabajo activo y desarrollo de habilidades, compensaciones y doble presencia. Este formulario existe en dos versiones la breve de 20 preguntas y la completa, con 142 preguntas. La versión breve permite determinar diferentes niveles de riesgo de estrés en los trabajadores de una empresa, en caso de obtener un nivel de riesgo alto, se debe complementar con la encuesta completa de 142 preguntas.

B. Detección de estrés mediante cortisol

Otra forma de medir el estrés es de manera biológica, ya que al presentar una situación estresante se liberan glucocorticoides (hormonas que regulan el metabolismo) a la sangre, como el cortisol [24][25]. El cortisol [26] es una hormona producida en las glándulas suprarrenales (ver *Figura 1-1*) y tiene una gran importancia para la mantención del cuerpo humano, para combatir infecciones, regular los niveles de azúcar en la sangre, regula el metabolismo, mantiene la presión arterial y ayuda a controlar el estrés en las personas. Los niveles de cortisol pueden medirse en la sangre, la orina y la saliva.




Figura 1-1 :Glándulas suprarrenales, productoras de cortisol [27]

Los niveles de cortisol son naturalmente altos durante la mañana, y tienden a disminuir con el transcurso del día, sin embargo, ante eventos de estrés, las glándulas suprarrenales liberan cortisol y adrenalina al torrente sanguíneo.

En el año 2001 Christian J. Cook [56] evaluó una forma de poder obtener muestras y medir de manera rápida la testosterona, insulina, 17- β estradiol, cortisol y glucosa obtenida por la saliva o de manera exudada transdermicamente (sudor). Para la prueba de saliva se depositó esta en cámaras de recolección para luego usar inmunosensor y poder medir las variables anteriormente mencionadas. Por otro lado, para la obtención de sudor se empleó un dispositivo basado en un ultrasonido comercial a este en su cabeza se le agrego una cámara plástica de 300 μ L. En dicha cámara se agregan unos compartimentos para los inmunosensores, después de estos compartimentos se monta una membrana de diálisis adaptada para este experimento, por último, se ensambla un O Ring el cual mantiene la membrana en su posición. En la Figura 1-2 se puede observar

el diagrama del sensor utilizado (a), por otro lado, en (b) se observa el sensor realizado real, ya construido y por último en (c) se observa un paciente.




Figura 1-2: (a) Esquemáticos del dispositivo, (b) el dispositivo adaptado para la obtención de muestras, (c) sujeto de prueba con el dispositivo [56].

En este caso se realizaron pruebas a 10 personas dando como resultado la detección de cortisol, testosterona, 17- β estradiol y glucosa, mientras que la insulina no. Mientras que con el sudor se pudo obtener cortisol, testosterona, 17- β estradiol, glucosa e insulina. Dando como resultado para el autor que la

segunda opción es mejor no solo en el ámbito de la cantidad de elementos, también tiene beneficios de portabilidad, no es invasivo y puede ser usado no solo en humanos, ya que, de esta manera se puede usar en animales.

El cortisol es influenciado por los ciclos de sueño [28] y por el estrés [25]. Su nivel más alto se manifiesta en la mañana cuando la persona se despierta y este empieza a bajar poco a poco al cabo de 30 a 60 minutos. Por lo mismo Wüst *et al.*[28] sugiere que el estrés crónico o la depresión se pueden medir en los niveles de cortisol encontrados en la saliva de la mañana. También, si existe variaciones de cortisol durante el día se podría decir que la persona se encuentra con estrés [29][30].

En el año 2014, M.J. Aguilar Cordero *et al.* [33], realizaron una revisión sistemática del cortisol salival como indicador de estrés fisiológico tanto para niños como adultos, para ello se evaluaron 57 artículos científicos, tanto en idioma inglés (41) como en español (16). Estos artículos se centraban en el uso de cortisol salival como un buen indicador del estrés fisiológico.

Los grupos etarios del estudio son en general grandes, ya que abarca tanto a niños, adultos y adultos mayores, pero en cada artículo por separado estos grupos son reducidos notoriamente, existiendo artículos en el cual se centra solo en niños y adolescentes, otros solo en mujeres adultas jóvenes, hombres adultos jóvenes o estudiantes universitarios, dando de esa manera grupos exactos para el estudio del cortisol salival. Por otro lado, los lugares geográficos estudiados se centran en el continente americano y en Europa.

Como conclusión de este artículo, se confirma que el cortisol salival si es un indicador de estrés y tiene relación con el diagnostico de problemas como depresión o ansiedad. De igual modo, se concluye que las evaluaciones psicológicas mediante test, como los vistos anteriormente en la presente propuesta, presentan una relación con los niveles de cortisol.

Uno de los avances importantes en la medición de cortisol para estrés se produce gracias a la investigación de Parlak *et al.* [31][32]. En este estudio se determina que el estrés aumenta la cantidad de cortisol y adrenalina en la sangre. Se establece además que el cortisol en el sudor varia en rangos óptimos entre 0.02 a 0.5 [μ M], y que niveles superiores a estos tiene un impacto sobre variables de procesos biológicos como la presión arterial, niveles de glucosa y metabolismo de carbohidratos.

Para poder medir los niveles de cortisol, los autores crearon un bio-sensor (*Figura 1-4*) de forma rectangular sobre una membrana que solamente reacciona con el cortisol. Esta membrana (*Figura 1-4*) absorbe a través de los micro capilares el sudor y lo almacena en una lámina de reservorio de sudor, la cual está cubierta por la membrana sensitiva al cortisol. Como el sudor también contiene iones cargados de sodio y potasio, la membrana sensitiva al cortisol permite su paso a otras capas del parche, a menos que estos iones se encuentren bloqueados por el cortisol. Este bloqueo genera un cambio de carga en los iones y el parche detecta este cambio de carga, no el cortisol propiamente.




Figura 1-3 Parche bio-sensor para cortisol propuesto por Parlak et al. [31]

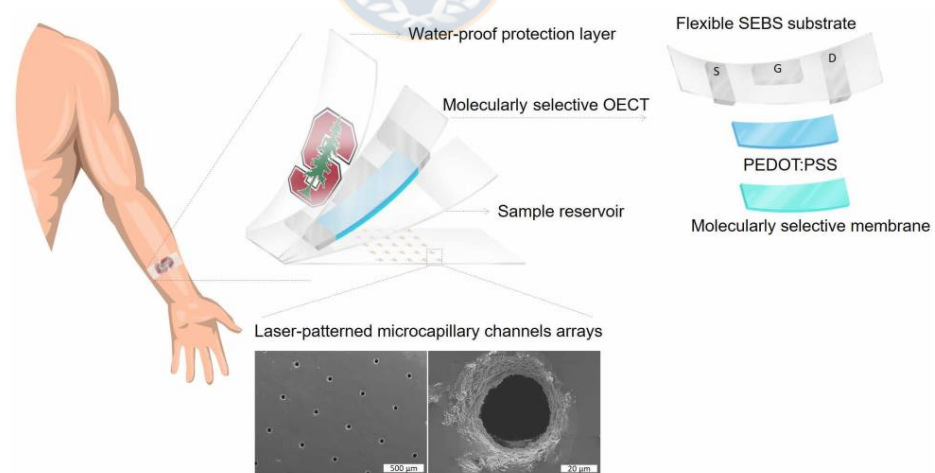


Figura 1-4: Esquema del parche bio-sensor de cortisol [31]

C. *Detección de estrés mediante variables fisiológicas y aprendizaje automático*

Por otro lado, actualmente se encuentran en investigación otros métodos para poder medir el estrés de una persona, los cuales se desarrollan a continuación.

Jennifer A. Healey *et al.* [18] presentan un estudio de recolección de datos fisiológicos a tiempo real para determinar los niveles de estrés en conductores.

Su objetivo es detectar cambios fisiológicos de los mismos por medio de 5 variables distintas: ECG, EMG, GSR, frecuencia respiratoria (a través de la cavidad torácica), y grabación del rostro en el vehículo. La disposición de los sensores utilizados se observa en Figura 1-5. El estudio fue realizado en 24

conductores por un período aproximado de conducción de 50 min, utilizando un recorrido predeterminado en la ciudad de Boston y diseñado especialmente para detectar cambios en los niveles de estrés, utilizando intervalos de descanso, conducción dentro de la ciudad y en autopista.




Figura 1-5 Disposición de los sensores para medir variables fisiológicas mientras se realizan las pruebas de detección de estrés [18]

Los datos obtenidos se emplean en dos análisis diferentes. En el primero, se utilizan intervalos de medición de 5 minutos para distinguir tres niveles distintos de estrés en todos los sensores. Esto va acompañado por una encuesta en la cual se les pide a los conductores clasificar sus niveles de estrés en distintos tramos del recorrido, y los cuales, una vez transformados en un set de datos, y mediante el método estadístico ANOVA y en conjunto con modelos de correlación desarrollan un algoritmo para poder detectar estrés con una exactitud general de 97,4%.

El segundo análisis es netamente estadístico y se complementa con la utilización de 4 cámaras de video instaladas dentro del vehículo, las cuales se encargan de grabar todo el experimento. Luego, se realiza su análisis segundo a segundo, de manera de detectar indicadores de estrés en el comportamiento del conductor, asignándole una nota a cada uno. Luego estas notas son transformadas en una métrica continua de medición de estrés, que es comparada nuevamente con los datos obtenidos por los distintos sensores, esta vez utilizando intervalos más pequeños de datos. Los resultados obtenidos por medio de la correlación entre la métrica y los datos obtenidos de cada sensor para cada conductor muestran que la medición a través de la conducción de la piel entregó resultados confiables, al igual que las mediciones de variación de ritmo cardíaco (HRV), ambos con una correlación mínima por sobre 0,49.

Otro ejemplo respecto a esta forma de medición es el estudio realizado por Keshan *et al.* [19] donde utilizaban algoritmos de detección de estrés en conjunto con métodos de Machine Learning en señales ECG de automovilistas bajo diversos niveles de estrés que se presentan en condiciones de manejo. Estas señales fueron obtenidas de MIT-BIH PhysioNet, donde a 17 sujetos de prueba se les midieron 8 variables ECG, EMG, GSR en el pie, GSR en la mano, HRV, presión sanguínea, temperatura corporal y frecuencia respiratoria. Estas fueron obtenidas de distintos sensores. Los datos fueron segmentados en 3 niveles de estrés bajo o Class 0 (en el descanso inicial y final, estrés moderado o Class 1 (en autopista) y estrés alto o Class 2 (ciudad).

En la Tabla 1-1 se encuentran las características extraídas de la señal ECG.

Tabla 1-1 : Características extraídas de la señal ECG [19]

| Características |
|--------------------------|
| Average QRS Interval |
| Average RR Interval |
| Average QQ Interval |
| Average SS Interval |
| Average QR Interval |
| Average RS Interval |
| Average Beats |
| Average Difference Beats |

Para la clasificación de las señales se usaron 10 algoritmos distintos los cuales son: Naive Bayes, Logistic Regression, Multilayer Perception, SMO, IB1, IBK, ZeroR, J48, RandomForest y RandomTree. Sus resultados indican que el mejor algoritmo a utilizar es Naive Bayes con un 100% de acierto utilizando la característica de “average difference beats” en estado de estrés bajo y estrés alto.

En esta misma línea se puede hablar sobre la investigación realizada por Javad Birjandtalab *et al.* [20], donde se realiza la recolección de datos fisiológicos de 20 estudiantes universitarios (16 hombres y 4 mujeres) a través del uso conjunto de dos pulseras inalámbricas; la primera de ellas detecta GSR, temperatura y la aceleración en los tres ejes, mientras que la segunda es un oxímetro, que recolecta datos de HR y SpO2. Ambas se conectan al mismo computador, para así sincronizarlas y recibir los datos al mismo tiempo. Los candidatos son expuestos a un circuito diseñado para detectar cambios en los estados de estrés, tanto a nivel físico, cognitivo y emocional, considerando pausas intermedias para relajación. Los datos obtenidos durante este estudio fueron utilizados como base de información para el desarrollo de la presente tesis, el detalle de las etapas se describe en el punto 4.2.

El diagrama del procesamiento de los datos mencionados anteriormente se observa en Figura 1-6. Los investigadores utilizan el modelo de mezcla gaussiano (GMM) no supervisado como método de agrupamiento de datos. Finalmente, para la visualización de los datos en 2D utilizan dos técnicas de reducción de

dimensión, PCA y t-SNE, obteniendo mejores resultados con la segunda ya que es capaz de distanciar los sets de datos de acuerdo con su grado de similitud.

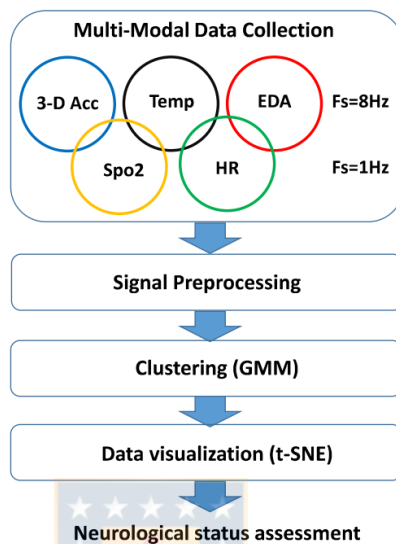


Figura 1-6 Diagrama del procesamiento de datos [20]

Los resultados obtenidos comprueban que el agrupamiento de datos por medio de GMM no supervisado es capaz de separar exitosamente los diferentes estados de estrés donde la detección de estrés físico lo detecta con 90.9 % de precisión, estrés emocional con 65.8% de precisión y estrés cognitivo con 87.3% de precisión. Logrando una precisión promedio de 84.6%

Otro ejemplo fue realizado en el año 2010 por F. Sun *et al.* [21], quienes utilizaron WEKA machine learning con clasificadores como SVM, Decision Tree, J48, Bayesian Network para detectar el estado de estrés de distintas personas. Se realizaron tres pruebas (sentado, de pie y caminando), las cuales consisten en una etapa de medición en condiciones sin estrés donde la persona escucha música de meditación, esta etapa es utilizada para determinar la línea basal del

estado normal. Una segunda etapa en la cual se les induce el estrés mediante una prueba de estrés mental, la cual consiste en Stroop test y cálculos aritméticos. Por último, se les realiza una etapa de relajación donde la persona debe estar sentada y escuchando música de meditación con los ojos cerrados. Cada una de estas etapas dura 10 minutos. Durante las pruebas se midieron las variables GSR y HRV, además se utilizó un acelerómetro en la cadera para monitorear los movimientos de cada persona en las distintas etapas. Para la adquisición de los datos se utilizaron 20 sujetos de prueba, 13 hombres y 7 mujeres.

En la Figura 1-7 se observan las pruebas de Stroop test y el test de matemática realizado para la inducción de estrés, mientras que en la Figura 1-8 las condiciones en las cuales fueron realizadas las distintas pruebas. Para esta investigación se obtuvo que el mejor clasificador es Decision Tree logrando una exactitud sobre el 80% en la detección de estrés.

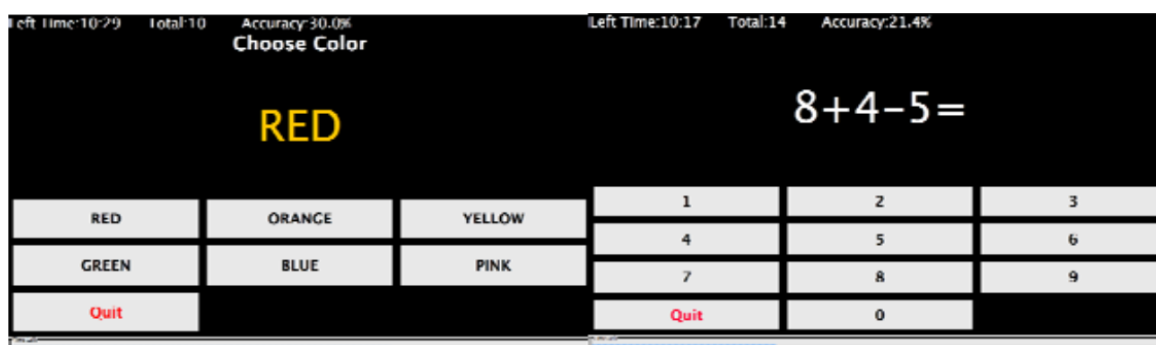


Figura 1-7 Screenshots de los test utilizados por F. Sun et al. [20]

| | | |
|--|---|---|
| Baseline Segment (Sitting Only) 10 min | Stressed Segment (Mental Task + Sitting) 10 min | Recovery Segment (Sitting) 10 min |
|--|---|---|

(a) Sitting condition

| | | |
|---|--|---|
| Baseline Segment (Standing Only) 10 min | Stressed Segment (Mental Task + Standing) 10 min | Recovery Segment (Sitting) 10 min |
|---|--|---|

(b) Standing condition

| | | |
|--|---|---|
| Baseline Segment (Walking Only) 10 min | Stressed Segment (Mental Task + Walking) 10 min | Recovery Segment (Sitting) 10 min |
|--|---|---|

(c) Walking condition

Figura 1-8 Condiciones experimentales realizados en la prueba de F. Sun et al. [20]

Por otro lado, a diferencia de otras investigaciones, M. Villarejo *et al.* [22] realizaron un sensor de estrés solo utilizando GSR y WEKA machine learning, con diferentes clasificadores como Bayesian Network, J48, SMO. Para ello, se realizaron diversas condiciones para verificar el comportamiento de la piel mediante el sensor GSR:

- Estado de relajación.
- Inducir el estado de nerviosismo.
- Respirando fuertemente.
- Operaciones matemáticas.
- Leer durante 90 segundos lo más rápido posible.
- Diversas imágenes que inducen distintos estados mentales.

Para dichas pruebas se arma un set-up (Figura 1-9) el cual consta del sensor GSR en los dedos índice y medio, los que envían de manera inalámbrica los datos obtenidos por el GSR, a una plataforma que pre procesa los datos para luego clasificarlos y de esa manera indicar el estado de estrés de la persona.

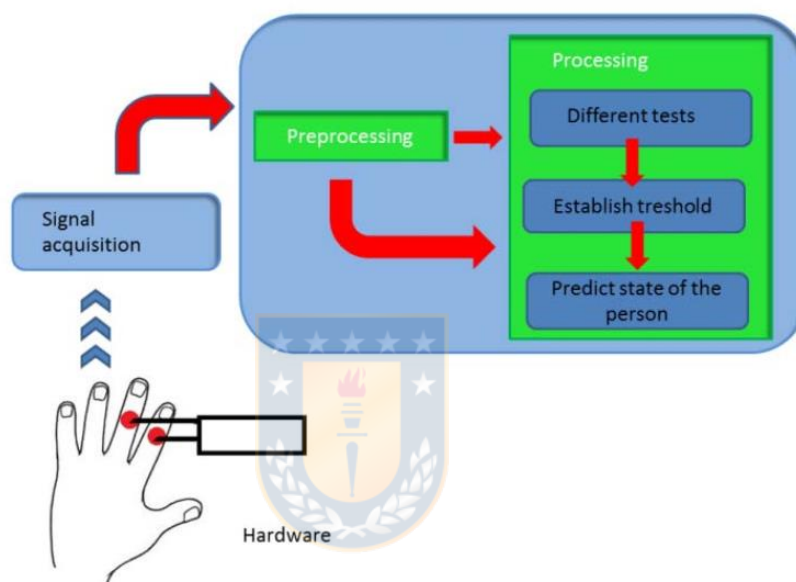


Figura 1-9 Diagrama General del sistema utilizado por M. Villarejo et al. [21]

Las pruebas se realizaron en 13 sujetos y como resultados obtuvieron que el mejor clasificador para detectar el estrés es SMO con un promedio de aciertos del 90,97%, luego sigue BayesNet con 90,37% y por último J48 con 89,3%.

Otro estudio al respecto es el realizado por Sritamprakash *et al.* [23] quienes proponen un modelo que detecta el estrés en trabajadores (Figura 3-10), en base a variables fisiológicas y aprendizaje automático. Las variables fisiológicas medidas en este modelo son ECG (específicamente HR y HRV) y GSR, el algoritmo clasificador a usar es SVM.

Como se puede observar en su modelo (Figura 1-10), los sujetos de prueba son expuestos a tres ambientes de estrés, estas señales se procesan y son clasificadas según el clasificador a usar, este clasificador da como resultado si el sujeto se encuentra en un estado “normal” o en un estado “estresado”.

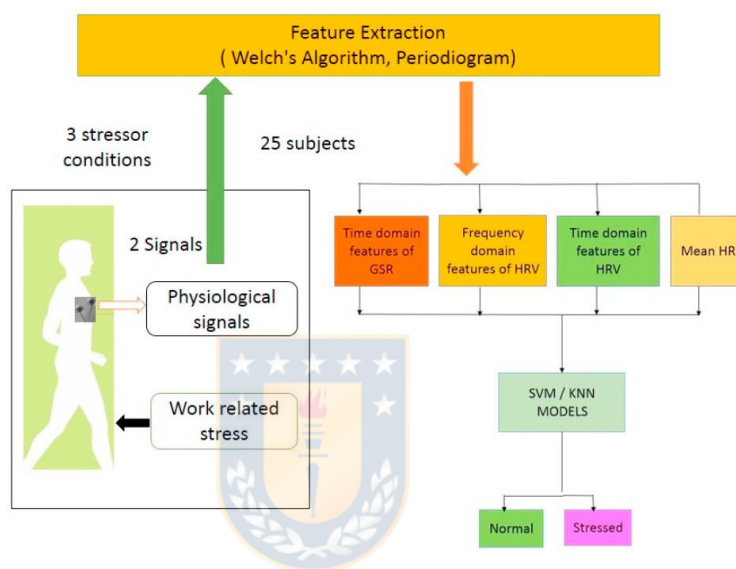


Figura 1-10: Modelo propuesto por Sritamprakash et al [23]

Las pruebas constan de tres condiciones diferentes, con intervalos de 45 minutos entre ellas, corresponde a las indicadas a continuación:

Generación de una señal en estado normal:

-Duración: 45 minutos.

-Tiempo de relajación: 6 minutos.

Envíos de email:

-Duración: 45 minutos.

-Tiempo de relajación: 6 minutos.

Estrés constante:

-Duración:30 minutos.

-Tiempo de relajación: 6 minutos.

Sus resultados indican que con su clasificador SVM se obtuvo la mayor exactitud, siendo de 92,75%. Gracias a esto se concluye que la utilización de GSR y ECG son variables correctas para usar en la predicción de estrés.

1.2.2 Relación entre HR y estrés

La relación del HR y es estrés es clara, existen diversos estudios los cuales explican su relación, uno de estos estudios es realizado por E. Sibolboro et. al [55], la cual realiza diversos experimentos para analizar las reacciones de las personas ante estrés. Centrándonos en uno de ellos, donde a un grupo de 31 personas, entre hombres y mujeres de diversas etnias y con una edad promedio de 34 ± 8 años se le realizaron dos pruebas las cuales generaban estado de estrés, la primera “Stroop Color-Word”, en la cual los sujetos debían identificar palabras que indicaban un color y la fuente también estaba escrita en algún color, cuando ambas coincidían debían apretar una tecla específica. La segunda prueba era aritmética mental, en la cual debían resolver sumas en intervalos de 7 segundos. La metodología de este experimento consistía en medir la línea base de su HR en estado de relajación, luego durante 5 minutos realizaron la prueba de “Stroop”, seguido de 5 minutos de relajación para continuar con 5 minutos de aritmética mental y finalmente 5 minutos de relajación.

Las personas al enfrentarse a momentos de estrés su HR aumentaba con respecto al HR basal medido, esto se puede observar en la siguiente figura.

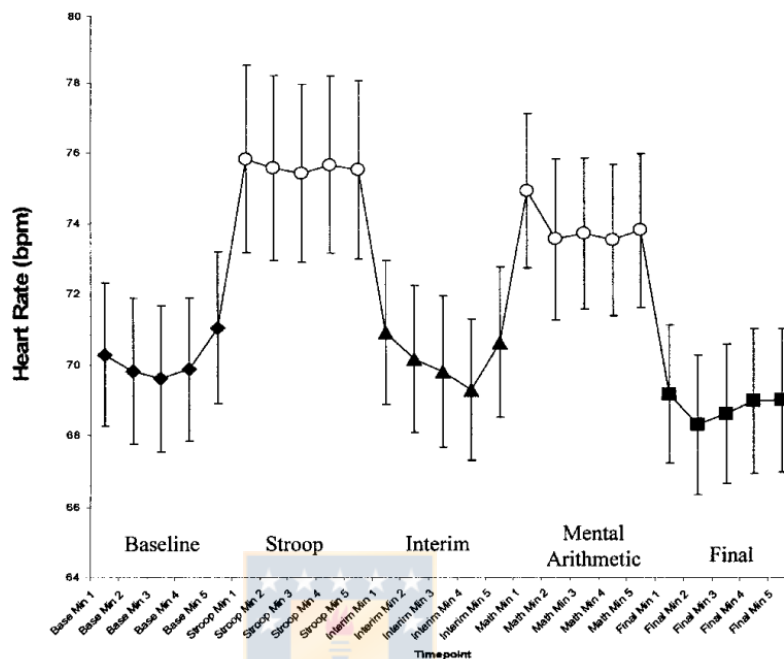


Figura 1-11 : Cambios de HR ante momentos de estrés realizado por E. Silbolboro [55]

1.3 Posicionamiento de electrodos para la medición de ECG

Para determinar el HR mediante ECG es de vital importancia analizar la posición de los electrodos en sistemas *wearables*, ya que una mala posición de estos puede llevar al mal cálculo o netamente a la imposibilidad de calcularlo. Para ello se realizó un estudio en dos ramas, la rama de investigación científica y la rama comercial.

Por la rama de investigación científica se estudió el artículo de G. Acar *et al.* [39], el cual es un *review* con diversas investigaciones centrado en la adquisición de bioseñales como ECG, siendo un factor común para la lectura de ECG el uso de

electrodos textiles en contacto con el cuerpo, específicamente el pecho, tanto en forma de polera como de cinturón.

Algunas de las investigaciones estudiadas por G. Acar *et al.* [39] se pueden observar en la Figura 1-12, donde se muestra una chaqueta para bebe (a) [40] la cual se fija en el cuerpo del bebe para que los electrodos no se muevan pero cuyo diseño permite la movilidad a este. En la sección (b) se observa un pilucho[41] el cual permite enviar datos de manera “inalámbrica” a través de un enlace inductivo. En las secciones (c) y (d) se presenta una cinta [42] la cual se coloca en la parte baja del pecho con un electrodo de referencia en el estómago, pero generando un problema importante debido es el movimiento, ya que la obtención de su ECG se pierde con el movimiento y un brazalete [43] ubicado en el brazo que permite la lectura de ECG respectivamente. Por último, se presenta en la sección (e), (f) y (g) una polera [44] que mide ECG, otra polera[45] que mide ECG y respiración, entre otras variables y emite alarmas y una tercera polera [46] que mide ECG mediante una placa flexible y de tamaño 27 x 27 mm respectivamente.



Figura 1-12 : Sistemas wearable con obtención de ECG [39]

Por la rama comercial existen muchos ejemplos, entre los cuales encontramos Hexoskinm, una polera que mide ECG, HRV (variabilidad del ritmo cardiaco), RPM (Respiraciones por minutos), entre otros. Como se puede observar en Figura 1-13 (a) [47], la posición de los electrodos se encuentra en la parte baja del pecho y a un costado del estómago, apegados a la piel. En noviembre Emglare lanzará Undershit⁴ Figura 1-13 (b) [48] una polera que mide ECG cuyos electrodos los tendrá solamente a nivel del pecho. La empresa ADInstruments (c)[49] diseño Equivital una especie de sostén deportivo que mide Respiración, ECG, entre otras variables y donde los electrodos de ECG se ubican en la parte baja del pecho. Otro ejemplo corresponde a QARDIOCORE (d) [50] que corresponde a un cinto fijado en la parte baja del pecho que mide ECG de grado médico y está conectado a una plataforma propia que permite compartir tus datos con tu médico. Por último, la polera de HeartBit (e) [51], la cual mide ECG,

actividad diaria, estados de recuperación y cuyos electrodos están ubicados en la parte inferior del pecho.



Figura 1-13 : Sistemas wearable comerciales que obtienen EMG

1.4 Discusión

Actualmente, no existen herramientas comerciales que realicen seguimiento del estado de estrés en trabajadores, solo se diagnostica una vez que la persona ya se encuentra con estrés crónico, como el examen de cortisol o los cuestionarios que se aplican en los trabajos como SUSESO/ISTAS 21 en Chile. El principal problema de diagnosticar el estrés crónico es que la persona ya puede estar con problemas derivado de este.

Por otro lado, existen estudios que avalan el uso de signos vitales para analizar los niveles de estrés de una persona con exactitudes que van desde el 70% hasta

el 100%, por lo cual se necesita llevar estos estudios a dispositivos *wearable* que tengan la capacidad de medir el estrés diariamente durante una jornada laboral y de esa manera poder anticipar problemas generados por el estrés. Esto permitiría contar con información suficiente para que los empleadores tomen mejores decisiones de gestión de salud y seguridad ocupacional, lo que aumentaría la productividad en las organizaciones y, además, mejoraría el clima laboral.



CAPÍTULO 2. HIPÓTESIS, OBJETIVOS Y METODOLOGÍA

2.1 Hipótesis

Mediante el monitoreo, extracción de características y procesamiento con algoritmos de aprendizaje automático de variables asociadas al ritmo cardiaco, se obtiene como resultado la detección de estrés en personas.

2.2 Objetivo General

Desarrollar un sistema wearable que, mediante la medición de variables fisiológicas como ritmo cardiaco (H.R) y herramientas de aprendizaje automático, permita detectar estrés en personas.

2.3 Objetivo Específicos

- Estudiar la relación entre estrés y las variables fisiológicas que lo definen.
- Estudiar herramientas de aprendizaje automático enfocado en análisis de variables que definen el estrés.
- Diseñar e implementar un dispositivo de bajo costo que adquiera señales de ECG mediante electrodos textiles.
- Desarrollar algoritmos de aprendizaje automático para estimación de estrés.
- Entrenar algoritmos de aprendizaje automático para detección de estrés.
- Evaluar el funcionamiento del algoritmo de aprendizaje automático para detección de estrés.

2.4 Alcances y limitaciones

En la ejecución de este proyecto de tesis se diseñará e implementará un prototipo funcional de un sistema wearable que mida distintas variables fisiológicas.

Debido a la pandemia generada por la enfermedad del coronavirus 2019 (COVID-19) y a la crisis sanitaria generada por esta enfermedad tanto a nivel nacional como mundial, el trabajo se limitará al desarrollo del algoritmo de detección offline y su entrenamiento. Su evaluación será mediante información disponibles en base de datos validadas (Physionet u otro de igual nivel) los cuales serán ECG, HR o variables obtenidas de estas.

2.5 Financiamiento

Para la ejecución de este proyecto de tesis se usan tantos fondos provenientes del programa Capital Semilla de CORFO (18CS-96220), fondos del laboratorio de Ingeniería Civil Biomédica como del proyecto Fondecyt 1201543.

2.6 Metodología

En primer lugar se estudiará el estado del arte referente a la medición de estrés. Posteriormente, se diseñará un prototipo a nivel de hardware con el objetivo de obtener las variables fisiológicas de la persona para luego diseñar un algoritmo que permita procesar y obtener las variables necesarias en el cálculo de estrés. De ocurrir errores o faltar variables necesarias se rediseñará tanto el hardware como el firmware.

Una vez diseñado el hardware se procederá a diseñar el interfaz hardware-persona el cual consiste en un sistema wearable. De tener problemas con la medición de señales se rediseñará dicho sistema.

Como se mencionó en los alcances y limitaciones, debido al COVID-19, la obtención de datos se realiza utilizando base de datos de un universo muestral de 20 personas sanas, basado en la base de datos obtenida por Physionet, ya que las pruebas se asemejan a lo descrito en la sección del estado del arte 1.2.1. Las pruebas para inducir el estrés constan de pruebas físicas, cognitivas y emocionales con una duración de 5 minutos cada uno y con periodos de descansos de 5 minutos. En base a esta información se asignan estados de estrés y relajación a cada uno de los pacientes. Durante las pruebas se miden los parámetros de: Temperatura, Heart Rate. Además, se incorpora información personal de los pacientes como: edad, sexo, altura, y peso.

Por último, se diseña el sistema con aprendizaje automático que procesa los datos obtenidos de las muestras anteriormente mencionadas considerando 16 pacientes para entrenamiento y validación del modelo y 4 pacientes para pruebas del modelo lo que permite detectar estrés. A diferencia de la forma de determinar el estrés actualmente tanto en Chile como en otras partes del mundo, a través de encuestas, este se calcula mediante la medición de las variables fisiológicas de una persona. De ser necesario se rediseñará el sistema.

Se realiza el estudio del arte de las técnicas machine learning utilizadas para la clasificación de estrés mediante variables fisiológicas, esto, sumado al hecho de que la clasificación del estado de estrés es binario (estresado o relajado) se define la utilización de 3 clasificadores: KNN, Support Vector Machine y Naive Bayes. Para determinar el rendimiento de los clasificadores se utilizan las siguientes métricas: Accuracy (exactitud), precisión (precisión) y recall (exhaustividad) y F1. Con esta información se determina el clasificador más adecuado para detectar estrés. Para esta tesis los algoritmos de aprendizaje automático serán utilizados mediante el framework Scikit-Learn para Python 3.



CAPÍTULO 3. DISEÑO Y DESARROLLO DE DISPOSITIVO DE MEDICIÓN DE VARIABLES FISIOLÓGICAS.

3.1 Introducción

En el presente capítulo se describe el diseño y desarrollo de un dispositivo *wearable*, el cual mide temperatura corporal, ECG y HR. En primer lugar, se estudia el ECG, para entender el tipo de señal que es y poder medirla, se estudian los electrodos, los cuales son los que miden el ECG y se utiliza textiles conductores para la construcción de los electrodos. Para la correcta obtención de la señal ECG es necesario analizar la posición en la cual los electrodos deben ser colocados en la persona y se determina que debe ser en la parte inferior del pecho.

El dispositivo se desarrolla en tres etapas:

- **Medición de ECG:** Esta etapa es la encargada de medir el ECG desde los electrodos hasta antes de ser digitalizado por el microcontrolador, la medición de ECG se realiza mediante el integrado AD8232, y dos filtros, uno pasa alto y un notch.
- **Medición de Temperatura:** En esta etapa se lee la temperatura y no requiere mayor procesamiento, ya que el sensor utilizado (MAX30205) entrega la temperatura ya digitalizada.
- **Procesamiento de variables fisiológicas:** En esta etapa se digitaliza el ECG y se procesa para el cálculo del HR, también lee la temperatura desde la etapa de medición de temperatura y por último envía las señales

procesadas ya sea vía Wi-Fi mediante el protocolo MQTT o vía serial para su utilización.

Una vez diseñado se implementa el dispositivo en una placa PCB de cobre de doble cara con 1,6 [mm] de grosor, los circuitos son encapsulados en una caja impresa en PLA. Se prueba mediante un emulador de paciente FLUKE PS420, el cual genera un ECG con diversas frecuencias cardiacas, verificando así el correcto funcionamiento del ECG. Para verificar el funcionamiento del sensor de temperatura se presiona con un dedo de la mano.

3.2 Variables fisiológicas

Las variables fisiológicas son los parámetros medibles que permiten el funcionamiento de un ser vivo, las principales variables fisiológicas son los signos vitales [34], los cuales representan a las funciones vitales básicas. Estas variables corresponden a: frecuencia cardiaca (HR), presión arterial, temperatura corporal (BT), frecuencia respiratoria (FR).

Para la presente tesis las principales variables fisiológicas utilizadas son el HR y la temperatura corporal. El HR se obtiene mediante el procesamiento de la señal de ECG, el cual, como se mencionó en el punto 1.2.1 está relacionado al estrés. Por otro lado, se mide la temperatura corporal para luego ser utilizado en la clasificación del estrés y analizar su utilidad en esta clasificación.

3.2.1 Electrocardiograma

El ECG es la representación gráfica de la actividad eléctrica del corazón. Este permite conocer el recorrido del impulso cardiaco gracias a la diferencia de potencial en las distintas partes del corazón.

Normalmente, en la forma de onda del ECG [35] se puede observar las ondas P, QRS, T y de los intervalos PR y ST (Figura 3-1).

- Onda P: Representa la despolarización que se extiende por las aurículas.
- Onda QRS: Esta corresponde a la despolarización de los ventrículos. Dura entre 0,06 y 0,1 segundos.
- Onda T: Se deriva de la repolarización de los ventrículos.
- Intervalo PR: Este intervalo corresponde al tiempo en que pasa el comienzo de la activación auricular hasta el tiempo que empieza la activación ventricular y su tiempo es normalmente de 0,12 y 0,2 segundos.
- Intervalo ST: Este intervalo representa la despolarización de todo el miocardio ventricular.




Figura 3-1: Ondas P, QRS, T e intervalos PR y ST [35]

La formación de las ondas y los intervalos antes mencionados se pueden observar en la siguiente figura.




Figura 3-2: Construcción del ECG a partir de la conducción de impulsos en el corazón [36], en (e) se observa la despolarización de los ventrículos, desde el interior hacia el exterior. Mientras que (g) los ventrículos se repolarizan.

La onda eléctrica medida por el ECG representa los vectores de la actividad eléctrica cardiaca [35], dependiendo de la zona en la cual se mide el ECG, se obtendrán variaciones en la forma de la onda, conocidas como derivaciones, las

cuales pueden ser bipolares o unipolares[36]. Las derivaciones bipolares dependen de dos electrodos de medición y uno de referencia, que pueden ubicarse en los brazos y/o piernas. Las posiciones son brazo derecho (RA), brazo izquierdo (LA), pierna derecha (RL) y pierna izquierda (LL). Existen tres tipos de derivaciones polares, la primera corresponde a la derivación I donde los electrodos se colocan en RA y LA, la segunda corresponde a la derivación II y la ubicación es en RA y LL, y por último la derivación III ubicados en LA y LL. Para los tres casos la referencia se localiza en RL.

Por otro lado, las derivaciones unipolares dependen de un solo electrodo de medición y una referencia, siendo su ubicación la indicada en Tabla 7-1. El resumen de las derivaciones se puede observar en la siguiente tabla.

Tabla 3-1 : Derivaciones ECG [36]

| <i>Nombre de la derivación</i> | <i>Colocación de los electrodos</i> |
|--|--|
| <i>Derivaciones bipolares de las extremidades</i> | |
| <i>I</i> | LA y RA |
| <i>II</i> | RA y LL |
| <i>III</i> | LA y LL |
| <i>Derivaciones unipolares de las extremidades</i> | |
| <i>AVR</i> | RA |
| <i>AVL</i> | LA |
| <i>AVG</i> | LL |
| <i>Derivaciones torácicas unipolares</i> | |
| <i>V₁</i> | Cuarto espacio intercostal a la derecha del esternón |
| <i>V₂</i> | Cuarto espacio intercostal a la izquierda del esternón |
| <i>V₃</i> | Quinto espacio intercostal a la izquierda del esternón |
| <i>V₄</i> | Quinto espacio intercostal a la línea medioclavicular |

| | |
|-------|--|
| V_5 | Quinto espacio intercostal a la izquierda V_4 |
| V_6 | Quinto espacio intercostal en la línea medioaxilar |

A. Electrodo

Para la medición del ECG se decidió el uso de electrodos textiles que, para el caso particular de esta tesis, corresponden a la tela conductora Med Tex P310, cuyo material está fabricado en base a nilón-plata. Los electrodos textiles permiten desarrollar un sistema *wearable* que no irrita la piel y es lavable, posibilitando su uso continuo en la vida diaria. Adicionalmente, según el fabricante del material del electrodo [37], indica que es antibacteriano y fungicida, de uso general, con un rango de temperatura de funcionamiento de entre $-30\text{ }^{\circ}\text{C}$ y $90\text{ }^{\circ}\text{C}$ y permitido para uso médico. Todas estas propiedades lo vuelven una opción para los electrodos.

Cabe destacar que, según el estudio elaborado por R. Castrillón *et al.* [38] donde se realiza una comparación respecto a la medición de ECG para distintos materiales, entre los cuales encontramos: algodón, algodón-poliéster, licra, nilón-plata y poliéster, dando como resultado que el material nilón-plata (Med Tex P130) es uno de los que menos se ve afectado por el ruido, lo cual es de vital importancia en ambientes de trabajo.

En el transcurso de la investigación para esta presente tesis, se realizaron dos diseños distintos de electrodos (Figura 3-3). El primero de tipo “almohada” (a) de dimensiones $6\text{ cm} \times 4\text{ cm} \times 1\text{ cm}$, rellenos de “espuma para relleno” para que sean

acolchados y a su vez fijarlos de mejor manera al cuerpo de la persona. El segundo es de tipo “cobertura” (b) de dimensiones 4,5 cm x 2,5 cm x 1cm, al igual que el anterior son rellenos con “espuma de relleno”, pero a diferencia del anterior estos van adosados a la cinta elástica.




Figura 3-3 : a) Electrodo de tipo "almohada" b) Electrodo de tipo “cobertura”

Al comparar el desempeño de ambos diseños, se determina el uso del diseño b), ya que esta mejora la vida de los electrodos, debido a que el diseño a) mantiene tenso el material en todo momento por lo que va desgastando la conductividad del mismo, lo que se traduce en pérdida de su capacidad de conducción rápidamente, esto se puede observar en Tabla 3-2, imposibilitando la lectura de ECG.

Tabla 3-2: Tiempo de vida útil de tipo de electrodos

| | <i>Tipo “almohada”</i> | <i>Tipo “cobertura”</i> |
|----------------------------|------------------------|-------------------------|
| <i>Tiempo de vida útil</i> | 1 semana | 5 meses |

B. Posición de electrodos

Para lo posición de los electrodos, se utilizó la derivada I. En una primera instancia los electrodos se implementaron en una polera, y esta tuvo problemas debido a que los electrodos se movían junto al movimiento natural del cuerpo. Esto provocó una distorsión de la señal al realizar cualquier movimiento provocando un ruido que, en casos extremos, imposibilitaba la medición de ECG. Por ello, en una segunda instancia y de acuerdo con lo analizado tanto comercialmente como en el ámbito de la investigación científica en el punto 1.3, se decide que la mejor posición para ubicar los electrodos es en la parte inferior del pecho (Figura 3-4), por lo que se diseña un cinto de algodón (Figura 3-5) con electrodos textiles, el cual se ajusta evitando mangas y secciones que se puedan mover debido a la interacción normal con el cuerpo humano, de esa forma se evita de mayor manera el ruido generado por movimiento.

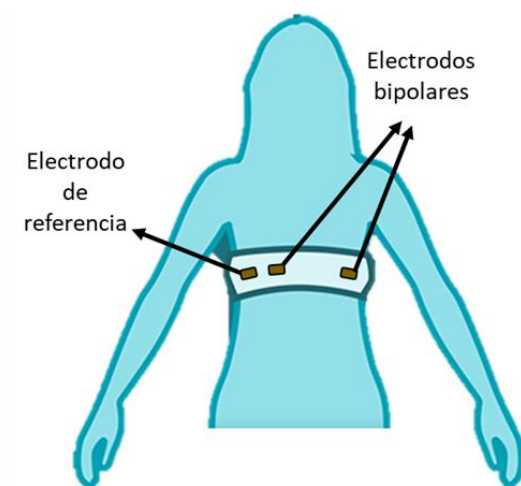


Figura 3-4 : Diagrama de posicionamiento de los electrodos



Figura 3-5 : Cinto medidor de ECG (elaboración propia)

C. *Frecuencia cardíaca*

Según lo analizado en el estado del arte, el HR es una de las principales variables para medir estrés y para cuya la medición es necesario saber el tiempo que existe entre ondas R, conocido como R-R o peak to peak (Figura 3-6), gracias a esta diferencia de tiempo es posible saber cuántos latidos por minuto produce el corazón de una persona.




Figura 3-6 : Intervalo R-R de un ECG

3.3 Diseño e implementación del Dispositivo

Se diseña un dispositivo instrumentado con sensores para medición de las variables fisiológicas: ECG, HR y BT. Para la presente investigación, el diseño del dispositivo se divide en tres etapas: Medición de ECG, Medición de Temperatura y Procesamiento de variables fisiológicas. En la Figura 3-7 se puede observar un esquema general del sistema, donde se mide el ECG de una persona mediante electrodos textiles los cuales van conectados al integrado AD8232, el cual está especializado en la medición de esta variable. Luego se filtra analógicamente la señal mediante dos filtros, uno pasa banda para filtrar el ruido por movimiento de la persona y un filtro Notch para filtrar el ruido generado por componentes eléctricos externos, esto se explica a mayor detalle en punto 3.3.1. Por otro lado, se mide la temperatura corporal de manera simple gracias al integrado MAX30205, ya que este integrado entrega la temperatura ya digitalizada mediante conexión I2C al microcontrolador. Ambas señales son procesadas mediante un Módulo ESP-32 de la empresa Esspresif [54] y gracias a este procesamiento es calculado el HR.

Por último, ambas señales ya procesadas pueden ser enviadas, ya sea, inalámbricamente vía Wi-Fi con el protocolo MQTT o de manera alámbrica mediante serial para su procesamiento. El diagrama general del sistema se puede apreciar en Figura 3-7.

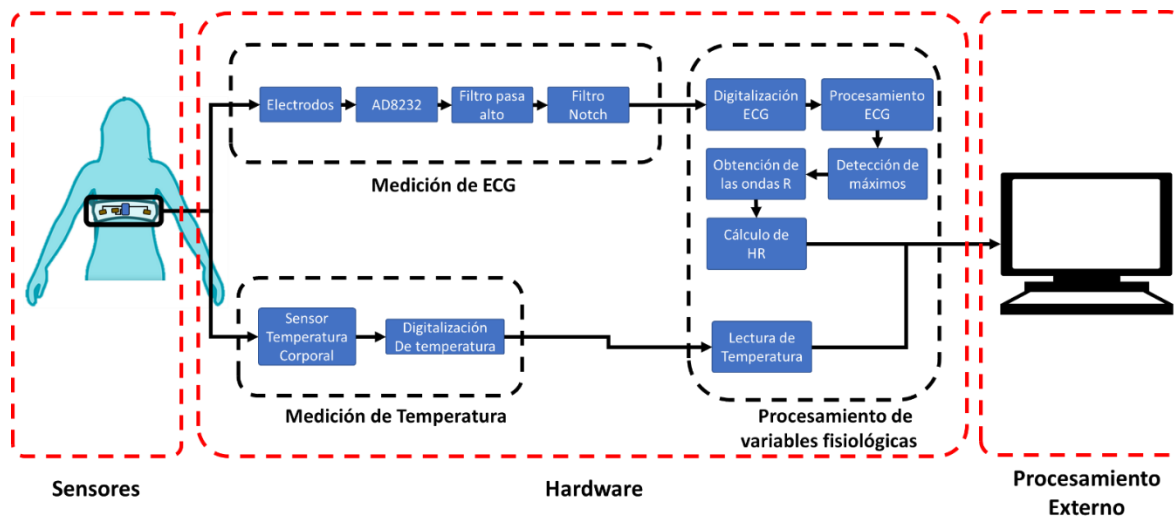


Figura 3-7 : Esquema general del sistema de medición

3.3.1 Diseño del Hardware

El objetivo principal del hardware es la obtención de ECG y BT, para ello es necesario digitalizar las señales, esto se logra mediante diversos sensores especializados en medición. El microcontrolador procesará estas señales para calcular las variables fisiológicas y ser enviadas inalámbricamente o alambriamente para su posterior análisis de ser necesario. El diseño del circuito se realiza gracias al software de Autodesk Eagle, utilizando su licencia free.

A. Medición de ECG

Para la obtención del ECG se diseña un circuito que consta de un circuito integrado front end ECG, un filtro pasa alto y un filtro Notch, Figura 3-8. El AD8232 es un integrado especializado en la medición de biopotenciales, que corresponde a AD8232 de Analog Devices [52] y tiene una corriente de consumo típica de $170 \mu\text{A}$, con una alimentación de 2.0 y 3.5 V, para el caso particular de esta tesis se alimenta con 3.3 V. Al integrado se conectan tres electrodos, estos

corresponden a los bipolares y al electrodo de referencia, para realizar la derivada

I. Cabe destacar que tanto la señal de entrada como la de salida es análoga.

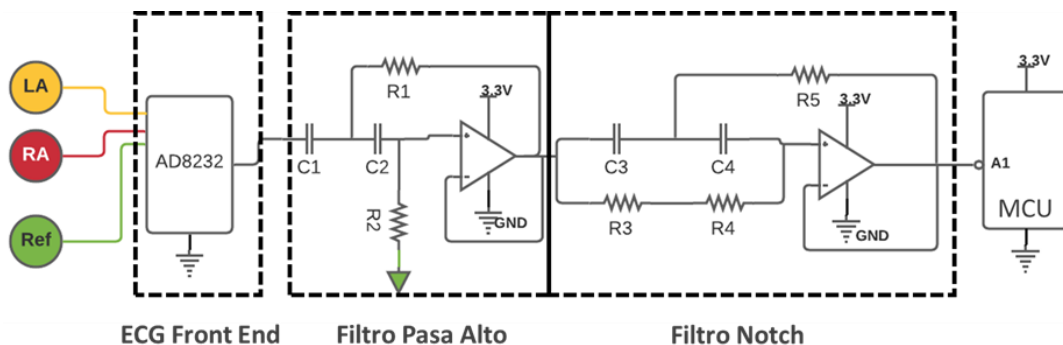


Figura 3-8 : Circuito esquemático de la obtención de ECG

El fabricante del integrado recomienda una configuración para utilizarlo como un monitor cardiaco (Figura 3-9) y esta configuración consta de 3 etapas. La primera elimina el offset de los electrodos, la segunda etapa implementa un filtro pasa alto basado en una topología Sallen-Key, este filtro es el encargado de filtrar frecuencias bajo 0.5 Hz. Por último, un filtro pasa bajo de igual manera con topología Sallen-Key, este filtra señales sobre los 40 Hz.

A pesar de la incorporación de filtros internos del integrado, se decide utilizar en la salida del integrado dos filtros más, un filtro pasa alto con configuración Sallen-Key de 2 Hz para eliminar cualquier ruido posible generado por la respiración y un filtro Notch de 50 Hz para filtrar el ruido generado por la red eléctrica. Una vez filtrada la señal, esta es enviada al microcontrolador ESP-32.

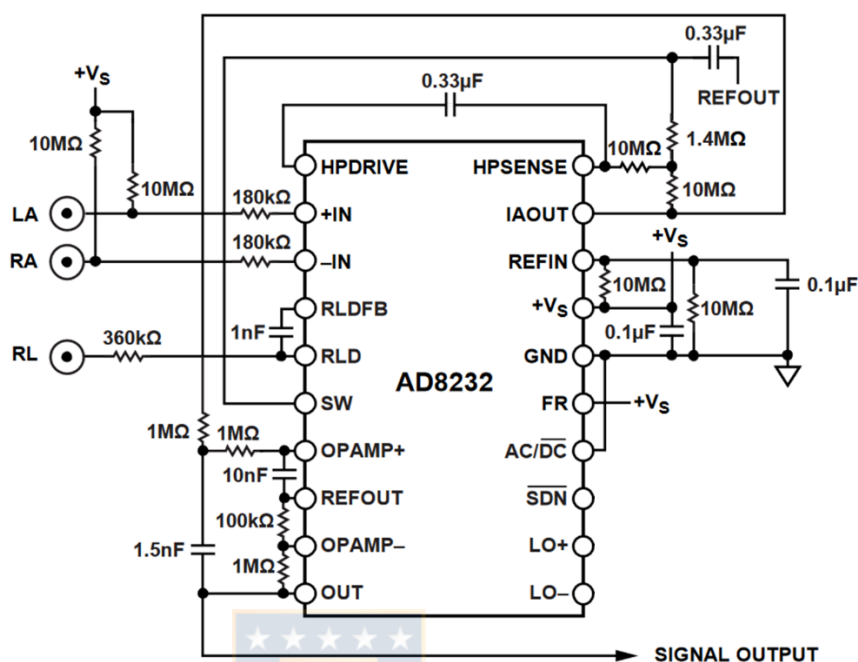


Figura 3-9 : Configuración recomendada para Monitor Cardíaco

La señal resultante fue generada mediante un emulador de pacientes FLUKE PS420, dicha señal se genera con ruido de 50 [Hz]. Como se observa en Figura 3-10, la señal obtenida por el microcontrolador es un ECG limpio, con el cual se puede calcular su HR.



Figura 3-10 : Señal obtenida del sensor de ECG

B. Medición de Temperatura

Para la medición de la temperatura corporal se decide utilizar también un circuito integrado especializado en la temperatura del cuerpo humano, en este caso se utiliza el MAX30205 [53] que cuenta con un conversor ADC de una resolución de 16-Bit, un error dependiente de la temperatura $\pm 0,1$ °C entre 37° y 39 °C. Su alimentación varía de los 2,7 V a los 3,3 V, siendo la utilizada para este caso de 3,3 V. Su consumo de corriente típico es de 600 μ A y su conexión a microcontrolador es a través de I2C.

C. Procesamiento de variables fisiológicas

Para el procesamiento de las variables fisiológicas se escoge el módulo ESP-32 [54] de Espressif debido a sus especificaciones. Este microcontrolador se alimenta con 3,3V, tiene capacidad de transmisión BLE, Wi-Fi y Bluetooth, cuenta con dos puertos I2C, 3 puertos UART y hasta 18 canales ADC de 12-bit de resolución con una frecuencia máxima de 200 kHz. A su vez es un microcontrolador con doble núcleo, lo que permite trabajar por separado y simultáneamente la transmisión de datos, la medición y procesamiento de estos. Por último, este microcontrolador tiene la capacidad de ser programado en diversos lenguajes como: Arduino, RTOS, Micropython.

La temperatura ya es entregada digitalizada mediante conexión I2C, por lo tanto, solo es necesario procesar el ECG. Una vez obtenido el ECG ya filtrado de la etapa de Medición de ECG mediante filtros pasa bajo, pasa alto y notch, es necesario procesar el ECG para la obtención del HR. Se digitaliza el ECG

mediante un pin de lectura análoga del ESP32 para luego ser filtrada en un filtro de media móvil de 10 datos, se calcula la derivada de la señal y se eleva al cuadrado para volver a ser filtrada por un filtro de media móvil de 10 datos.

Una vez filtrada completamente la señal se obtiene los máximos resultantes, al momento de calcular el máximo, este va disminuyendo en una tasa de 0,5% por muestra obtenida y así poder recalculer el máximo, que en este caso serían las ondas R del ECG. Para poder definir si son ondas R entre cualquier otro tipo de onda se decide por un trigger del 80% del máximo calculado, eso quiere decir que, si la onda supera ese trigger, nos encontramos con una onda R, de esa manera al calcular los tiempos entre R gracias a ese tiempo y a la siguiente formula se obtiene la frecuencia cardiaca.

$$HR = \frac{60}{\frac{\text{Tiempo}_{R-R}}{1000}}$$

Una vez procesadas ambas variables (temperatura y HR), estas son enviadas vía WiFi o Serial para que puedan ser procesadas externamente de ser necesario.

3.3.2 Implementación del Hardware

Para la implementación del hardware de adquisición de datos que se diseñó, se utilizaron dos placas de cobre doble capa. La placa número uno consiste en cuatro etapas:

- Procesamiento: Esta etapa es la encargada de procesar las señales tanto de ECG como de temperatura descrito en el punto 3.3.1 mediante el

módulo ESP-32. Luego de procesar las señales los datos de HR y temperatura corporal pueden ser enviadas vía Wi-Fi por protocolo MQTT3 o vía Serial de ser necesario. El circuito electrónico de esta etapa se encuentra en anexo 7.2.1.

- **Electrocardiograma:** En esta etapa se conectan los electrodos de la segunda placa a los pines de entrada de electrodos del integrado AD8232, luego se filtra la señal mediante los filtros integrados del AD8232 y se obtiene una señal ECG filtrada. Los filtros de esta etapa son descritos en el punto 3.3.1. El circuito electrónico de esta etapa se encuentra en anexo 7.2.2.
- **Filtros:** Esta etapa es la encargada de filtrar la señal ECG proveniente de la etapa de Electrocardiograma, en este caso agregan dos etapas de filtros más los cuales son un pasa bajo y un notch, el funcionamiento de estos filtros se encuentra en el punto 3.3.1 y el diagrama de su circuito electrónico se puede observar en la sección de anexo 7.2.3.
- **Energización:** Esta etapa es la encargada de alimentar el circuito completo tanto la placa 1 como la placa 2, ambas son alimentadas por una batería de litio de 3.7 V y 850 mAh. Esta batería es recargada mediante un puerto USB y su voltaje es controlado mediante un integrado gestor de carga (MCP73831). Por otro lado, la batería está conectada a un circuito regulador de voltaje, usando como integrado central el MCP1725-3302E,

desconectar el dispositivo del cinto con electrodos textiles. La placa desarrollada se observa en Figura 3-12. En blanco se encuentra el sensor de temperatura corporal, mientras que en amarillo se encuentran los snaps metálicos que realizan la interfaz persona-hardware.




Figura 3-12 : Placa número dos del dispositivo medidor de variables fisiológicas

El dispositivo completo se observa en Figura 3-13. En la sección a) observamos la placa uno, encargada de obtener, procesar y enviar los datos al exterior. En la sección b) se encuentra el sensor de temperatura y los snaps encargados de obtener el electrocardiograma proveniente del cinto. Por último, en la sección c) se observa el cinto o interfaz persona-hardware, el cual contiene los electrodos textiles que se ubicarían en la parte inferior del pecho.




Figura 3-13 : Sistema de medición: (a) Placa uno, pre procesa datos obtenidos, (b) placa dos, obtiene los datos de la interfaz, (c) interfaz persona-hardware

3.4 Firmware

El firmware programado consta de tres etapas. Para iniciar el setup se deben definir e inicializar las variables de estado y temporales, posteriormente le ejecuta el Setup, que corresponde a la primera etapa (Figura 3-14), donde se configuran los puertos de comunicación serial e I2C, luego se configura la lectura de temperatura y la lectura análoga para poder medir el ECG, se inicializan y conectan el Wi-Fi y la comunicación MQTT y por último, se configuran los núcleos 0 y 1, ambos núcleos funcionan continuamente en paralelo gracias al módulo ESP-32.

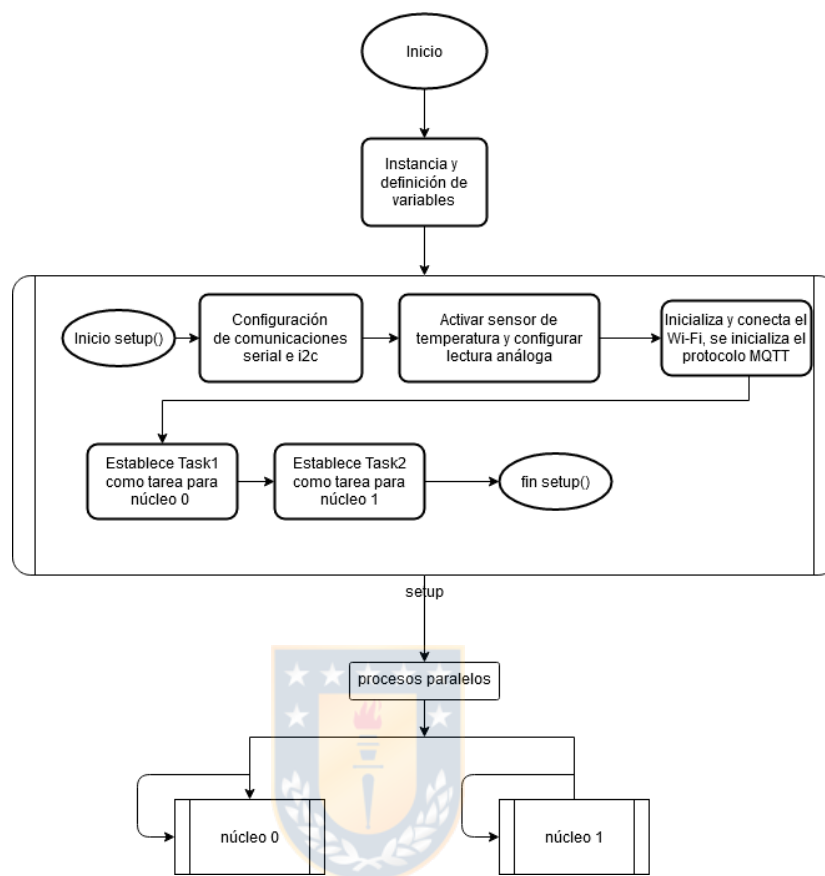


Figura 3-14 : Diagrama de flujo del Setup

En la segunda etapa, una vez inicializado el núcleo 0 y como se observa en Figura 3-15, se ingresa a un ciclo continuo donde verifica la conexión Wi-Fi y MQTT, de ser necesario reconecta las conexiones. Luego comprueba si ha pasado 1 segundo, de cumplirse dicha condición, realiza la lectura y el almacenamiento de la variable temperatura y la lectura de la variable HR y envía esta información mediante protocolo MQTT y vía serial, de no cumplirse vuelve al inicio del ciclo.

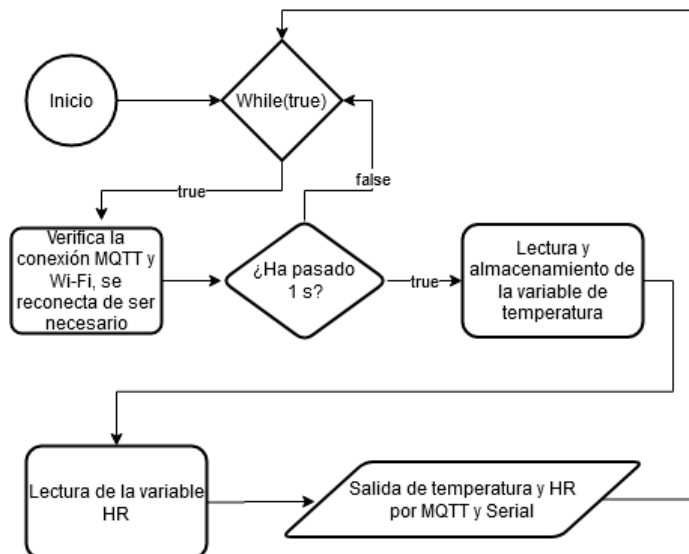


Figura 3-15 : Diagrama de flujo del núcleo 0

Para finalizar, durante la etapa tres, el segundo núcleo es el encargado del procesamiento de las señales ECG entrante (Figura 3-16). El núcleo se inicia con la definición de variables que se usan solamente en este núcleo (tiempo y estados). Posteriormente, realiza un ciclo continuo, luego evalúa si han transcurrido 5 ms, en caso de ser falso, vuelve a comprobar. En caso de ser cierto realiza la lectura y almacenamiento del dato en un vector. Una vez obtenido el dato, pasa por un filtro de media móvil 1, donde se promedian los últimos 10 datos del vector, para así reducir el ruido de la señal. A continuación, aplica un algoritmo de Pan–Tomkins, el cual se utiliza comúnmente para detectar el complejo QRS, en este caso en específico, se utiliza para detectar la señal R. Cabe mencionar que la etapa de filtros (pasa altos y pasa bajos) se realiza de manera análoga, por lo tanto, se programa las etapas restantes el algoritmo Pan-Tomkins. La señal

entrante, ya filtrada, es derivada y elevada al cuadrado para posteriormente aplicar un segundo filtro media móvil, el cual se utiliza para resaltar las ondas R. Seguidamente, se detecta si el dato entrante es superior al máximo, entonces, se actualiza el valor máximo, en caso de no serlo, continua hasta la siguiente parte. El valor máximo encontrado va disminuyendo continuamente 0,05% por cada muestra leída y, además, se establece un umbral del 85% del valor máximo. Si el dato procesado es mayor al umbral, detecta el tiempo de la señal R, la almacena y la resta con la anterior, lo que permite, según lo indicado en el punto 3.3.1 C, calcular y almacenar el HR. En caso contrario, vuelve al inicio del ciclo.



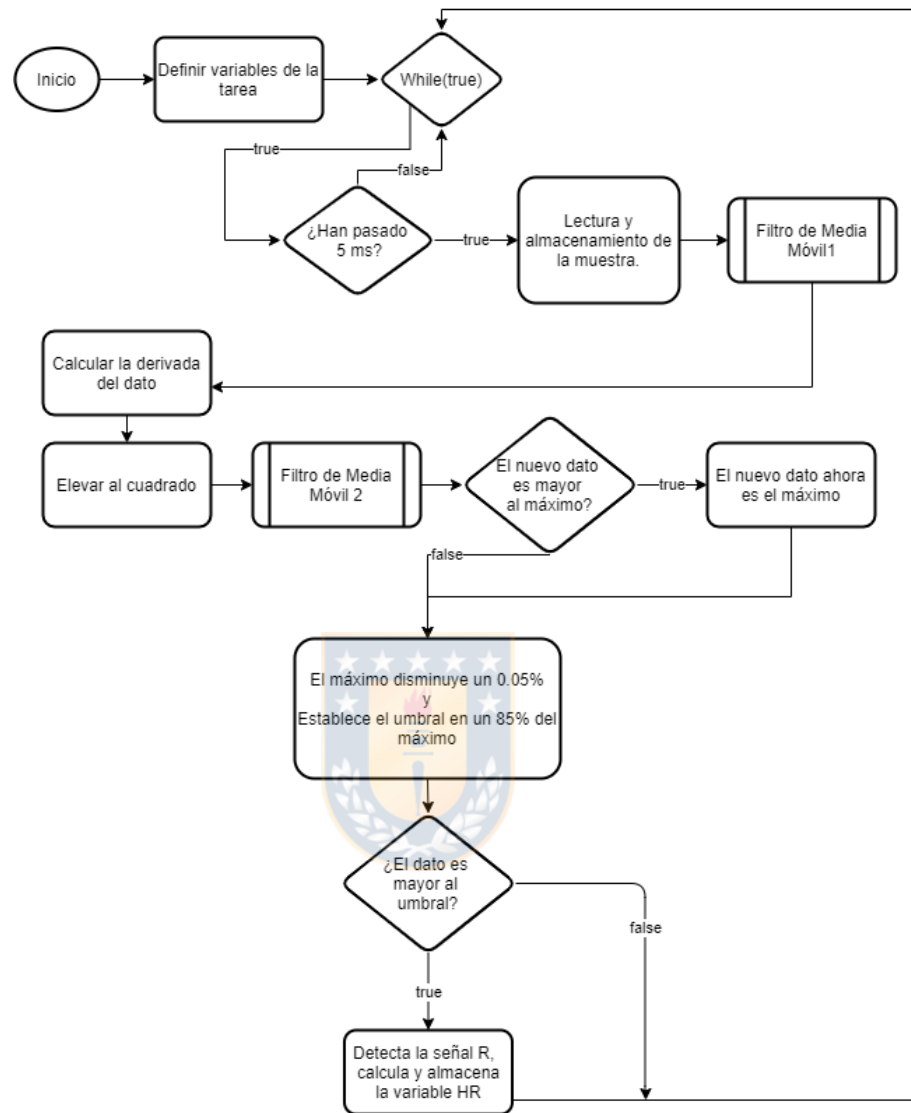


Figura 3-16 : Diagrama de flujo del núcleo 1

CAPÍTULO 4. ANALISIS DE DATOS, ALGORITMO PARA LA DETECCIÓN DE ESTRÉS Y RESULTADOS

4.1 Introducción

Debido a la situación de pandemia, que afecta tanto a nivel país como a nivel mundial, no fue posible realizar pruebas en personas como se esperaba al inicio del proyecto de tesis. Por lo tanto, se decidió utilizar una base de datos validada obtenida del sitio PhysioNet [57], una plataforma gestionada por los miembros del *MIT Laboratory for Computational Physiology*, establecida en 1999 bajo el auspicio de *National Institutes of Health (NIH)*, y que tiene como objetivo ofrecer acceso libre a grandes bancos de datos clínicos y fisiológicos. Uno de los principales criterios para escoger una base de datos sustitutas fue que las pruebas realizadas a las personas debían ser similares a las planteadas en la metodología original, y que principalmente consiste en etapas de descanso y etapas de estrés intercaladas entre ellas, donde cada una de estas etapas tiene una duración aproximada de 5 minutos. El otro criterio utilizar se relaciona con el tipo de datos medidos, los cuales deben corresponder a:

- a) Aceleración en los tres ejes
- b) Temperatura corporal
- c) G.S.R
- d) SpO2
- e) Ritmo cardíaco (HR)
- f) Edad

- g) Sexo
- h) Altura
- i) Peso

De estas variables, para esta tesis, se utilizarán edad, sexo, altura y peso, ya que son datos de cada persona y por otro lado, se considera HR y temperatura corporal, ya que, son las dos variables que se pueden obtener mediante el dispositivo *wearable* desarrollado en capítulo 3.

4.2 Obtención de datos

Como se mencionó en 4.1 los datos en los cuales se trabaja provienen de una base de datos obtenida de PhysioNet, específicamente de la base de datos *Non-EEG Dataset for Assessment of Neurological Status* [58]. La medición de la temperatura se realiza en el dedo índice, mientras que la obtención del HR se realiza mediante un oxímetro de pulso, lo cual difiere de la definición inicial de esta tesis que consistía en usar ECG para la medición de HR. Sin embargo, el oxímetro de pulso se considera igualmente válido para ejecutar esta medición, no generando variaciones importantes en el resultado.

Por otro lado, el dispositivo utilizado para la obtención referente a la base de datos mide la temperatura corporal desde el dedo de la mano, mientras que el dispositivo desarrollado en esta tesis lo mide desde el pecho. Esta variable se usa para monitorear los cambios de temperatura del cuerpo ante estrés, por lo cual, tanto en la mano como en el pecho se consideran zonas viables para su medición.

La base de datos cuenta con un universo de 20 personas sanas (14 hombres y 6 mujeres), a las cuales se les realiza pruebas de estrés físico, cognitivo y emocional, acompañado con pruebas de relajación. Cabe destacar que estas pruebas son utilizadas en diversas investigaciones como ya se mencionó en los puntos 1.2.1 C ([20]) y 1.2.2 de la presente tesis y permiten inducir estrés en los participantes sin ocasionar mayores complicaciones de salud a la persona.

Las etapas de estrés y relajación son siete y se describen a continuación:

1. Relajación: Se comienza con una etapa de 5 minutos de relajación.
2. Estrés físico: Se mantiene de pie a la persona por 1 minuto, luego se le hace caminar a la persona en una cinta de correr por 2 minutos a una velocidad de 1.6 [km/hr] y luego caminar por 2 minutos más a una velocidad de 4.8 [km/hr].
3. Relajación: Etapa de relajación de 5 minutos.
4. Estrés cognitivo: Se le hace contar hacia atrás desde el número 2.585 de 7 en 7 números por 3 minutos y luego se le realiza el *Stroop test*, el cual consiste en leer correctamente el color que este escrito con el mismo color. Al fallar en alguna de estas pruebas suena una bocina.
5. Relajación: Etapa de relajación de 5 minutos.
6. Estrés emocional: Se le menciona a la persona voluntaria que verá un clip de 5 minutos de una película de terror.
7. Relajación: Última etapa de relajación de 5 minutos.

Las etapas de relajación consisten en escuchar una porción de música binaural, la cual es usada comúnmente para la meditación.

La base de datos presenta la variable de estrés diferenciada en 3 tipos: estrés físico, estrés cognitivo y estrés emocional.

4.3 Preprocesamiento

Una vez obtenido los datos es necesario realizar un preprocesamiento antes de comenzar con el entrenamiento del clasificador, para ello en primer lugar se debe tener la misma escala de tiempo en ambas variables, para ello, y debido a que existen más mediciones para la temperatura que para el HR, es necesario ajustar las 8 muestras por segundo de la temperatura a la muestra por segundo del HR, para ellos se promediando los valores de temperatura cada segundo y así obtener una muestra por segundo en la temperatura. Esto se puede, ya que, casi no existe variación de temperatura entre segundos. Luego se acotaron los datos considerando un intervalo entre el primer minuto de monitoreo hasta el minuto 37 y 51 segundos, normalizando de esa manera la escala de tiempo de todas las personas. Posteriormente, se incorporaron los datos básicos de cada persona (edad, sexo, peso y altura), para después calcular el porcentaje de grasa de cada persona y el “delta HR”.

El cálculo de “delta HR” se realiza promediando el HR de la primera etapa de relajación, el cual corresponderá al HR basal sin estrés de la persona, luego a cada punto de la muestra se le resta el HR basal calculado y de esta diferencia se obtiene su valor absoluto.

En los Gráfico 4-1 y Gráfico 4-2 se observa que el comportamiento del HR y Delta HR cumple con lo indicado en el punto 1.2.2, ya que, estos aumentan en momentos de estrés.

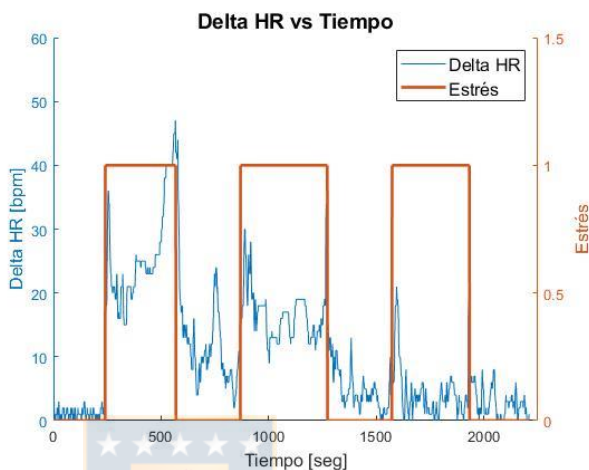


Gráfico 4-1 : Delta HR vs Estrés

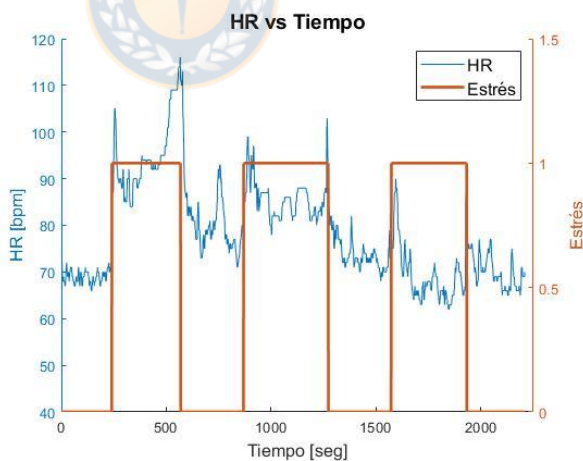


Gráfico 4-2 : HR vs Estrés

4.4 Análisis de datos

Se analizan las pruebas y los datos previamente procesados en los puntos 4.2 y 4.3 de 16 pacientes, que forman parte del grupo definido como entrenamiento y validación del algoritmo de aprendizaje automático, mientras que los 4 restantes

se usaran como prueba para verificar la validez del modelo entrenado. Como fue mencionado con anterioridad se usaron los siguientes datos: HR, delta HR, temperatura corporal, edad, sexo, peso, altura y porcentaje de grasa corporal para el entrenamiento y validación del sistema.

Respecto a la variable estrés, en la base de datos se consideran 3 tipos de estrés (físico, cognitivo y emocional), sin embargo, para el presente trabajo se considerará solamente si la persona se encuentra relajada o estresada, independiente de la causa, asociando 0 para el relajo y 1 si se encuentra estresado.

Para iniciar el análisis, es necesario comprobar que los datos están balanceados, en caso contrario, se revisan para balancearlos. Como se puede observar en Gráfico 4-3, los datos se encuentran balanceados, por lo tanto, nos aseguramos de que no tendremos resultados tendenciosos.

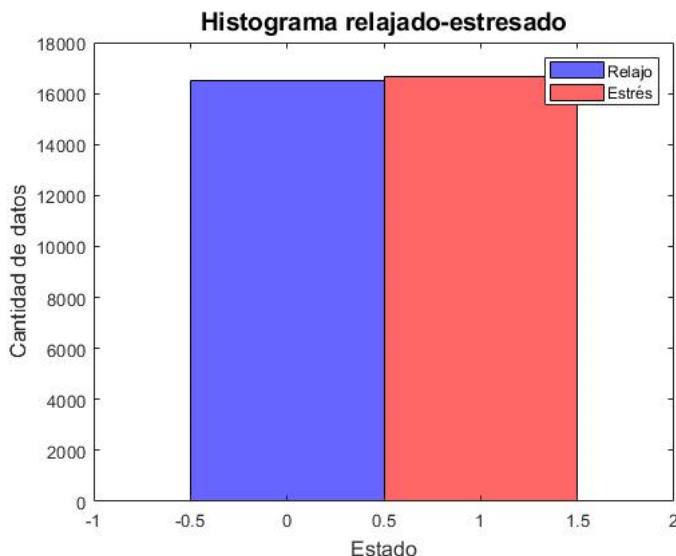


Gráfico 4-3: Histograma de estado

Posteriormente, se procede a analizar los datos que no son estáticos en el tiempo, esto quiere decir, que los datos personales como la edad, peso, altura, sexo y porcentaje de grasa no se analizan para la elección del clasificador, ya que no sufren alteración mientras se generan las pruebas mencionadas en 4.4. Por lo tanto, se analiza el comportamiento que tiene HR, delta HR y la temperatura, tanto de manera bidimensional, es decir, 1 versus 1 o tridimensional con las tres variables coexistiendo a la vez.

4.4.1 Análisis de distribución

Como se puede observar en Gráfico 4-4, el HR tiene una distribución asimétrica positiva, pudiendo ser aproximada a una distribución Gaussiana. Su asimetría es comprobable ya que, su moda (61) es menor a su mediana (75) y esta a su vez es menor a su media (77). Este análisis permite la factibilidad de utilización de

clasificadores compatibles con distribuciones gaussianas como Naive – Bayes y Support Vector Machine (Kernel Gaussiano).

Por otro lado, para el caso de “delta HR”, en Gráfico 4-5 se observa una distribución exponencial invertida evidenciando posibles problemas para la clasificación de estrés entre el delta HR ya que los datos se encuentran concentrados entre 0 y 10 aproximadamente, por ende, no es posible aproximarlos a una distribución normal.

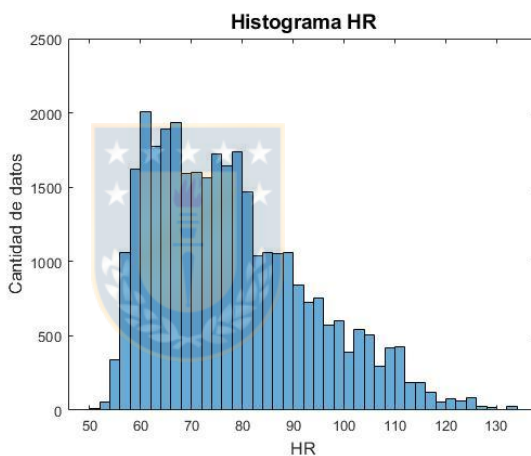


Gráfico 4-4 : Distribución del Heart Rate

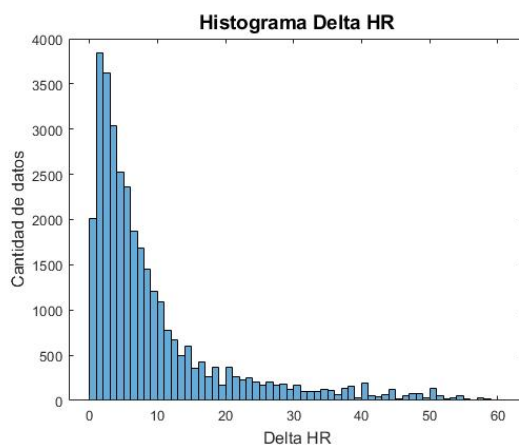


Gráfico 4-5 : Distribución del Delta Heart Rate

4.4.2 Análisis bidimensional

Este análisis se realiza para ver el comportamiento entre las variables y analizar si entre ellas se potencian o pueden ocasionar posibles alteraciones en el clasificador.

Como se puede observar en Gráfico 4-6, al analizar el comportamiento de las variables “delta HR” y temperatura, existe una concentración de datos entre 0 y 10 latidos por minutos, lo que genera una superposición de estados relajados y estresados, lo que puede ocasionar problemas al clasificar considerando estas variables.

De igual manera, al comparar el Heart Rate con la Temperatura se puede observar que existen superposición de estados relajados y estresados sobre los 29.5 [°C] y para rangos de Heart Rate entre 60 latidos por minuto y 100 latidos por minuto, impidiendo también una buena clasificación de estas variables.

Por último, entre Delta Heart Rate y Heart Rate ocurre la misma condición que el primer caso, ya que entre 0 y 10 latidos por minuto de la variable Delta Heart Rate y mayoritariamente debajo de 100 latidos por minuto para variable Heart Rate se generan una superposición de los estados estresado y relajado.

Por lo tanto, es posible deducir que al usar dos variables para clasificar el estado de estrés se podrían generar problemas para una correcta clasificación. Aun así, tanto en el primer como el último caso, es posible clasificar correctamente los datos que se ubican en aquellas regiones o zonas sin superposición de estados, sin embargo, el resto de las zonas podrían generar un error en su clasificación,

ya que como los datos fueron obtenidos desde personas sanas, su organismo, al estar expuesto a estrés, regula naturalmente su Heart Rate, evitando así complicaciones al organismo.

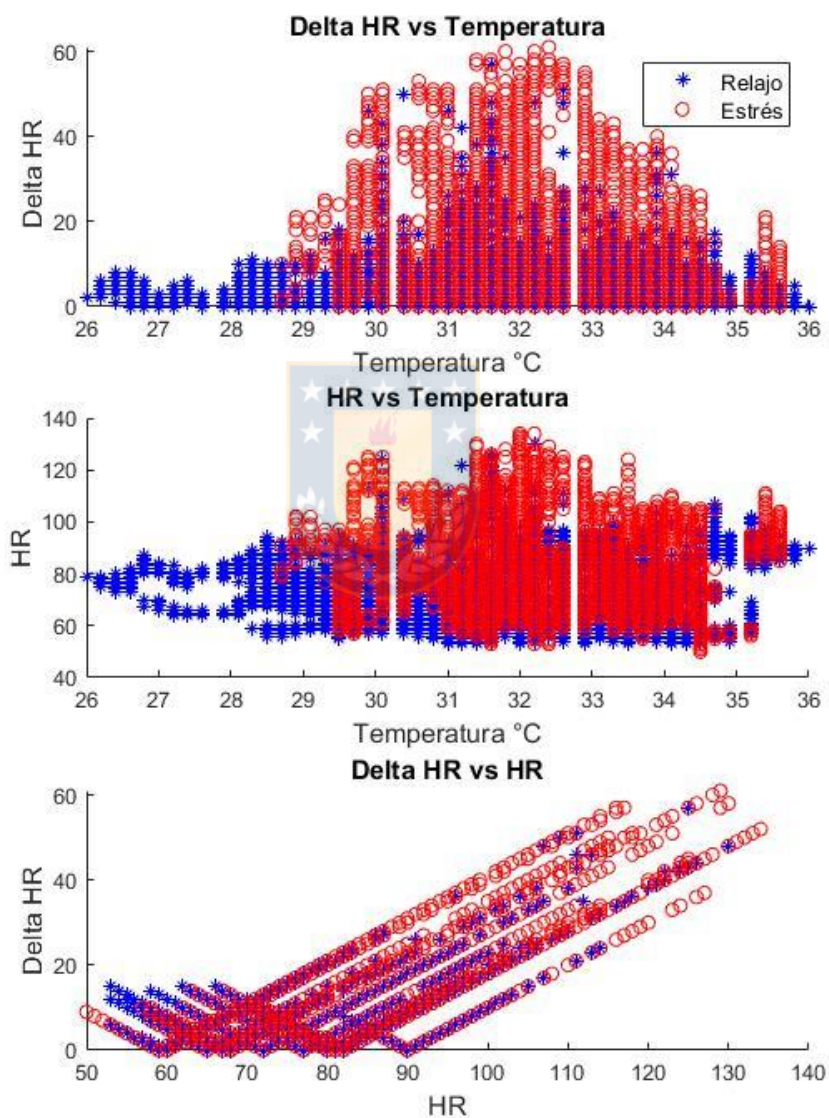


Gráfico 4-6 : Análisis Bidimensional, de arriba hacia abajo, 1) Comparación entre Delta Heart Rate vs Temperatura. 2) Heart Rate vs Temperatura. 3) Delta Heart Rate vs Heart Rate

4.4.3 Análisis tridimensional

Al analizar las tres variables en conjunto y como se observa en Gráfico 4-7, existe una clara diferencia entre estrés y relajación cuando el delta HR se encuentra sobre 10 latidos por minutos y el Heart Rate se encuentra sobre 100 latidos por minuto, mientras que cuando la temperatura está debajo de los 29°C y el delta HR se ubica debajo de 10 latidos por minutos, pero en el resto de las zonas se puede generar un problema de clasificación. Por ende, cuando los datos no se encuentran en esta zona problemática, detectar el estado de estrés se puede realizar con facilidad. El análisis tridimensional le permite al clasificador automático, poder determinar el estado del individuo utilizando tanto una clasificación por zona dando como una evaluación punto a punto dependiendo de la señal entrante.

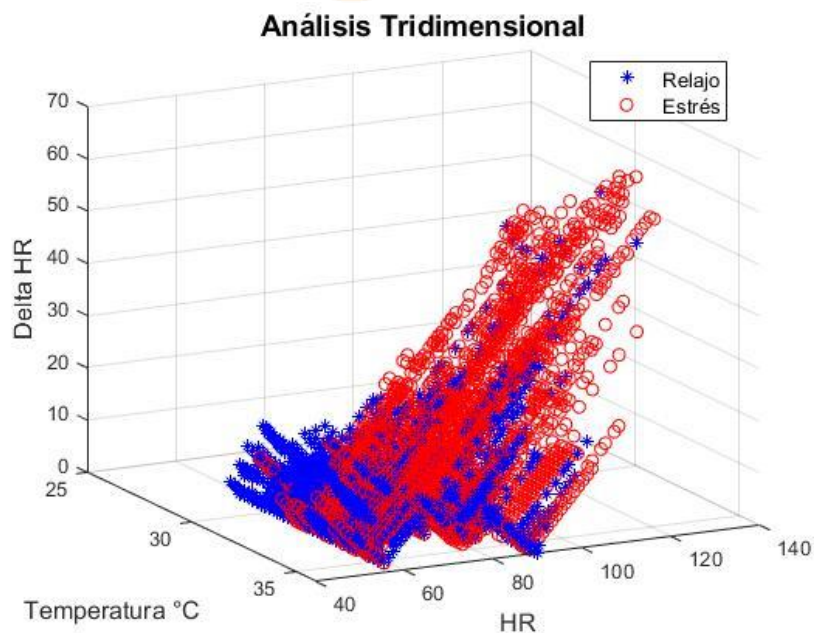


Gráfico 4-7 : Delta Heart Rate vs Heart Rate vs Temperatura

4.5 Algoritmo de detección de estrés

Al realizar el análisis de los datos obtenidos, y basados en la cantidad de variables de entrada, se opta por utilizar algoritmos de aprendizaje automático supervisado. Los estados de estrés y relajación se encuentran etiquetados en la base de datos, las cuales fueron clasificadas a partir de las pruebas de estrés y relajación realizadas a las personas.

Para el entrenamiento del algoritmo se utilizan los datos de 16 de las 20 personas voluntarias, cabe señalar que las cuatro personas restantes nunca fueron incluidas en el entrenamiento del algoritmo, ya que se usará para la comprobación del mismo. Las pruebas de comprobación se realizan ingresando secuencialmente persona por persona y así utilizar el modelo entrenado de tal forma que simule su uso final. En otras palabras, se ingresan los datos de una persona x se valida y luego se analiza la de la siguiente persona, y así sucesivamente.

Como se indicó en el punto **4.4** la salida del algoritmo solo será de dos estados, estresado (1) y relajado (0), centrándose netamente en el estado de estrés, ya que es el estado de mayor interés para esta tesis.

De acuerdo con el análisis previo realizado en el punto **4.4**, se utilizan los clasificadores Naive Bayes, esto es debido a la distribución de datos del HR, y a su vez se utilizan K-Nearest Neighbors y Support Vector Machine, debido a la distribución de los datos. Estos algoritmos de aprendizaje automático se definen a continuación:

- **KNN o K- Nearest Neighbors:** KNN o K- vecinos más cercanos es uno de los algoritmos de aprendizaje automático más simples, pero de igual manera con buenos resultados. Esta clase de algoritmo es de tipo supervisado. Como su principio consiste en la selección de un valor K, y de acuerdo con este valor K al ingresar un nuevo valor lo clasifica según sus K vecinos más cercanos ya existentes. Este proceso no hace ningún tipo de suposición con respecto a la distribución de las variables predictoras.

A diferencia del resto de clasificadores, el entrenamiento de este es mínimo, por el hecho que este en su entrenamiento solo almacena todos los vectores característicos y etiquetas de las clases de los datos de entrenamiento. Luego calcula la distancia entre los datos almacenados y los datos entrantes, donde selecciona los K ejemplos más cercanos. La distancia de clasificación más utilizada es la euclidiana, la cual es la trayectoria más corta entre los puntos.

Entre sus ventajas se encuentra la simplicidad del algoritmo, su insensibilidad con respecto a valores atípicos al sistema, el hecho de no realizar suposiciones sobre la forma funcional de los datos, entre otras.

Entre sus desventajas encontramos lo costoso a nivel computacional que es usarlo, ya que este almacena los datos de entrenamiento y en vez de aprender un modelo es necesario utilizar todos los datos para realizar la predicción de un dato entrante.

- **Support Vector Machine o SVM:** Es una herramienta de aprendizaje automático el cual analiza datos y reconoce patrones, este es usado normalmente en clasificadores o en análisis de regresión. Dicha herramienta, encuentra hiperplanos en un espacio multidimensional y separa los datos en diversas clases, el número de dimensiones es conocido como vector de características. Para mejorar esta diferenciación entre los datos se utilizan vectores de soporte, de ahí su nombre, estos vectores son los más cercanos al hiperplano.

Entre las principales ventajas que tiene esta herramienta se encuentra su eficiencia para conjuntos de datos tanto pequeños como grandes, esto es debido a que en un inicio fue usado para decisiones binarios, pero al ver el poder de esta herramienta se fue mejorando, otra de sus ventajas son la robustez de sus resultados, esto es gracias al tener entradas de grandes dimensiones. SVM se usa en diversos campos, como filtros de spam, detección facial, categorización de textos, bioinformática, entre otros.

Uno de sus principales problemas recae en el ajuste de parámetros, ya que, estos deben ajustarse específicamente para cada situación.

- **Naive Bayes:** Es un algoritmo clasificador probabilístico, basado en el teorema de Bayes donde se infiere la probabilidad de un suceso en base a conocimientos anteriores y asume la independencia entre los datos, de acuerdo con esa probabilidad clasifica el suceso. De esa manera, para calcular la probabilidad que ocurra un suceso o clasifique de acuerdo los

datos entregados, este calcula la probabilidad existente a las etiquetas de acuerdo con clases, luego determina la probabilidad con cada atributo por cada clase, luego y gracias al teorema de Bayes calcula la probabilidad de que ocurra el suceso y por último clasificar en una clase de acuerdo con las probabilidades anteriormente calculadas.

Entre las principales ventajas es la baja cantidad de información de entrenamiento para el cálculo de los parámetros a predecir, a su vez calcula rápidamente la clase del conjunto de acuerdo con los datos ya obtenidos previamente y funciona de manera multiclase.

Entre sus principales desventajas, es la asignación de probabilidad 0 y la no predicción de los datos al no observar la pertenencia del dato en una categoría ya entrenada, otra de sus principales desventajas es usar cada variable como independiente, ya que, en ejemplos reales es casi imposible obtener datos completamente independientes entre ellos.

Entre los principales usos de Naive Bayes se encuentra el análisis de textos, motores de recomendación, entre otros.

Para esta tesis los algoritmos de aprendizaje automático serán utilizados mediante el framework scikit-learn para Python 3.

4.6 Resultados

Una vez realizada el análisis de los datos obtenidos de la base de datos [58], donde los datos ya fueron previamente etiquetados mediante las pruebas de

inducción de estrés que fueron explicadas en el punto **4.2**, donde su etiqueta es 1 al estar estresado y 0 en estado relajado. Posteriormente se define algoritmos de aprendizaje automático a utilizar, estos son KNN, SVM, Naive Bayes.

Para la detección de estrés se utiliza KNN con K igual a 11, esto se determinó de manera experimental utilizando K desde 1 hasta 40, SVM lineal y Naive Bayes con estimación automática. Como se menciona en los puntos **4.4 y 4.5**, el espacio muestral consiste en 20 pacientes con un total de 131.660 datos que se reparten equitativamente entre las tres variables estudiadas (temperatura, Delta HR, HR). Este universo, 4 de ellos serán utilizados de manera independiente como prueba, los cuales corresponden a 26.532 datos, los cuales se reparten equitativamente entre las variables estudiadas. Por último, los restantes 16 pacientes, los cuales corresponden 106.128 datos, se reparten equitativamente en las variables anteriormente mencionadas. Por otro lado, se incluirán datos personales del paciente, donde encontramos edad, peso, estatura, sexo y porcentaje de grasa. Las pruebas realizadas para la presente tesis consisten en solo HR, solo Delta HR, HR y temperatura, Delta HR y temperatura, Delta HR, HR y temperatura y por último estas tres variables junto con los datos personales del paciente. Cabe destacar que no se realizaron prueba con la temperatura por sí sola, debido que este dato podría generar una variación de los resultados de las otras variables, tanto positivamente como negativamente. Por último, la presente tesis tiene como finalidad centrarse en variables cardiacas o derivadas de ellas mismas, por sobre la temperatura en sí.

4.6.1 Rendimiento de HR para clasificación de estrés

En la **Tabla 4-1** se presenta el rendimiento de HR según los diferentes clasificadores utilizados. Los clasificadores KNN, SVM lineal y Naive Bayes obtuvieron una accuracy promedio de 63.75%, 62.75% y 61.25% respectivamente, siendo el de mejor desempeño SVM, que si bien tiene un valor menor de accuracy promedio que KNN, tiene el F1 más alto (67.59%).

Tabla 4-1 : Rendimiento de HR

| <i>Clasificador</i> | <i>Accuracy promedio [%]</i> | <i>Recall [%]</i> | <i>Precision [%]</i> | <i>F1[%]</i> |
|--|------------------------------|-------------------|----------------------|--------------|
| <i>Clasificador KNN</i> | 63.75 | 56.75 | 67.5 | 61.76 |
| <i>Clasificador SVM lineal</i> | 62.75 | 63.5 | 72.25 | 67.59 |
| <i>Clasificador Naive Bayes Automático</i> | 61.25 | 55.5 | 72.5 | 62.87 |

4.6.2 Rendimiento de Delta HR para clasificación de estrés

En la **Tabla 4-2** se presenta el rendimiento de Delta HR según los diferentes clasificadores utilizados. Los clasificadores KNN, SVM lineal y Naive Bayes obtuvieron una accuracy promedio de 70.25%, 71.75% y 70.5% respectivamente, siendo el de mejor desempeño es KNN, que si bien tiene una accuracy levemente inferior a SVM, su valor de F1 es el más alto (70.04%).

Tabla 4-2 : Rendimiento de Delta HR

| Clasificador | Accuracy promedio [%] | Recall [%] | Precision [%] | F1 [%] |
|--|------------------------------|-------------------|----------------------|---------------|
| <i>Clasificador KNN</i> | 70.25 | 71.5 | 70 | 70.74 |
| <i>Clasificador SVM lineal</i> | 71.75 | 62.25 | 76.5 | 68.64 |
| <i>Clasificador Naive Bayes Automático</i> | 70.5 | 54.75 | 77.75 | 64.25 |

4.6.3 Rendimiento de Delta HR y HR para clasificación de estrés

En la Tabla 4-3 se presenta el rendimiento de Delta HR y HR según los diferentes clasificadores utilizados. Los clasificadores KNN, SVM lineal y Naive Bayes obtuvieron una accuracy promedio de 69.5%, 69.75% y 74.5% respectivamente, siendo el de mejor desempeño KNN, ya que si bien si accuracy promedio es levemente menor que SVM, su F1 es el más alto (70.8%).

Tabla 4-3 Rendimiento de Delta HR y HR

| Clasificador | Accuracy promedio [%] | Recall [%] | Precision [%] | F1 [%] |
|--|------------------------------|-------------------|----------------------|---------------|
| <i>Clasificador KNN</i> | 69.5 | 72.75 | 69 | 70.8 |
| <i>Clasificador SVM lineal</i> | 69.75 | 63.5 | 72.5 | 67.7 |
| <i>Clasificador Naive Bayes Automático</i> | 74.5 | 51.75 | 69 | 59.14 |

4.6.4 Rendimiento de HR y Temperatura para clasificación de estrés

En la Tabla 4-4 se presenta el rendimiento de HR y Temperatura según los diferentes clasificadores utilizados. Los clasificadores KNN, SVM lineal y Naive

Bayes obtuvieron una accuracy promedio de 63.25%, 62.25% y 60% respectivamente, siendo el de mejor desempeño SVM, ya que, si bien su accuracy promedio es un punto porcentual más bajo que KNN, su F1 es 8 puntos porcentuales el más alto (69.34%).

Tabla 4-4: Rendimiento de HR y Temperatura

| <i>Clasificador</i> | <i>Accuracy promedio [%]</i> | <i>Recall [%]</i> | <i>Precision [%]</i> | <i>F1 [%]</i> |
|--|------------------------------|-------------------|----------------------|---------------|
| <i>Clasificador KNN</i> | 63.25 | 61.75 | 62.5 | 62.12 |
| <i>Clasificador SVM lineal</i> | 62.25 | 71 | 67.75 | 69.34 |
| <i>Clasificador Naive Bayes Automático</i> | 60 | 63.5 | 65.75 | 64.61 |

4.6.5 Rendimiento de Delta HR y Temperatura para clasificación de estrés

En la Tabla 4-5 se presenta el rendimiento de HR y Temperatura según los diferentes clasificadores utilizados. Los clasificadores KNN, SVM lineal y Naive Bayes obtuvieron una accuracy promedio de 63.25%, 62.25% y 60% respectivamente, siendo el de mejor desempeño SMV, cuyo F1 es levemente menor que KNN, pero manteniendo un accuracy promedio más alto que ese clasificador.

Tabla 4-5: Rendimiento de Delta HR y Temperatura

| Clasificador | Accuracy promedio [%] | Recall [%] | Precision [%] | F1 [%] |
|--|------------------------------|-------------------|----------------------|---------------|
| <i>Clasificador KNN</i> | 68.5 | 73.5 | 66 | 69.55 |
| <i>Clasificador SVM lineal</i> | 70.75 | 65.25 | 74 | 69.35 |
| <i>Clasificador Naive Bayes Automático</i> | 64.5 | 60.5 | 74.75 | 66.87 |

4.6.6 Rendimiento de HR, Delta HR, Temperatura para clasificación de estrés

En la Tabla 4-6 se presenta el rendimiento de HR, Delta HR y Temperatura según los diferentes clasificadores utilizados. Los clasificadores KNN, SVM lineal y Naive Bayes obtuvieron una accuracy promedio de 67.3%, 68.5% y 69% respectivamente, siendo el de mejor desempeño KNN, que si bien tiene el valor más bajo de accuracy, se ubica a menos de 3 puntos porcentuales del valor más alto (de Naive Bayes), sin embargo, su F1 es el más alto (70.31%), siendo cercano a 5 puntos porcentuales más alto que el de Naive Bayes.

Tabla 4-6: Rendimiento de HR, Delta HR y Temperatura

| Clasificador | Accuracy promedio [%] | Recall [%] | Precision [%] | F1 [%] |
|--|------------------------------|-------------------|----------------------|---------------|
| <i>Clasificador KNN</i> | 67.3 | 79.3 | 63 | 70.31 |
| <i>Clasificador SVM lineal</i> | 68.5 | 66 | 71.5 | 68.64 |
| <i>Clasificador Naive Bayes Automático</i> | 69 | 59 | 74 | 65.48 |

4.6.7 Rendimiento de HR, Delta HR, Temperatura y datos del paciente para clasificación de estrés

En la Tabla 4-7 se presenta el rendimiento de HR, Delta HR, Temperatura, edad, peso, sexo, estatura y porcentaje de grasa corporal. Los clasificadores KNN, SVM lineal y Naive Bayes obtuvieron una accuracy promedio de 75.4%, 68.5% y 67.75% respectivamente, siendo el de mejor desempeño KNN ya que si bien una accuracy 1.5 puntos porcentuales más bajo que SVM, su F1 es el más alto, (73.47%).

Tabla 4-7: Rendimiento de HR, Delta HR, Temperatura y datos del paciente

| <i>Clasificador</i> | <i>Accuracy promedio [%]</i> | <i>Recall [%]</i> | <i>Precision [%]</i> | <i>F1 [%]</i> |
|--|------------------------------|-------------------|----------------------|---------------|
| <i>Clasificador KNN</i> | 68.5 | 75 | 72 | 73.47 |
| <i>Clasificador SVM lineal</i> | 70 | 65.5 | 71.25 | 67.86 |
| <i>Clasificador Naive Bayes Automático</i> | 67.75 | 58.25 | 74.75 | 65.48 |

A modo resumen, se presenta en el **Gráfico 4-8** la comparación de todos los datos de métricas para todos los casos estudiados, donde se observa que los mejores resultados se presentan para KNN, en primer lugar, para el uso de todas las variables, y en segundo lugar, para el uso de Delta HR.

El gráfico además muestra que si bien, el porcentaje de precisión obtenido en los clasificadores SVM y Naive Bayes es habitualmente más alto que KNN, su accuracy como F1 son iguales o más bajos y con un recall también más bajo.

Además, para ambos casos se puede apreciar la segregación de los datos de estas 3 métricas.

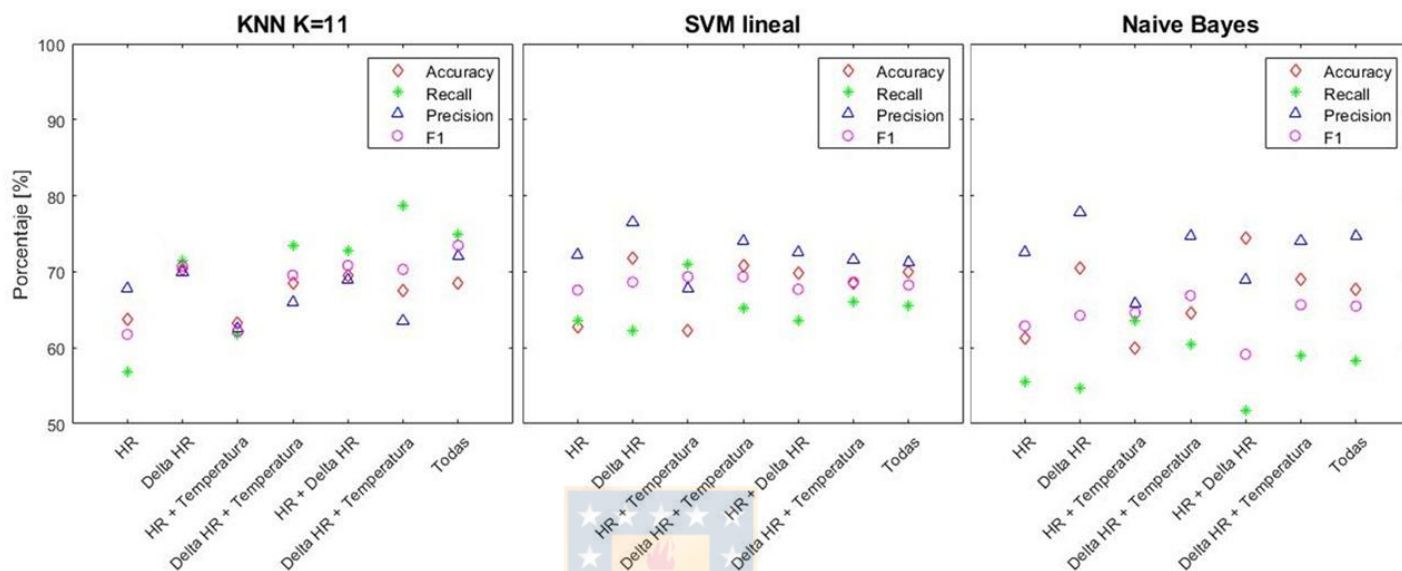


Gráfico 4-8: Resumen de las pruebas realizadas

4.7 Conclusión

Para el desarrollo de este capítulo se decidió utilizar una base de datos obtenida del sitio PhysionNet, específicamente “*Non-EEG Dataset for assessment of Neurological Status*” [58], los principales criterios para escoger esta base de datos fue, en primer lugar, por las pruebas realizadas, las cuales son similares a la metodología original y por otro lado las variables medidas, específicamente para esta tesis se utiliza la edad, sexo, altura, peso, HR y temperatura corporal.

Estos datos son preprocesados, para ello en primer lugar se normalizan las escalas de tiempo, fijando el tiempo de muestreo en un segundo por muestra. Luego se fijó el tiempo desde el primer minuto hasta el minuto 37 con 51 segundos y de esa manera mantener la escala temporal uniforme en todos los pacientes. Por último, se calcula la variable “delta HR” basado en la variable HR obtenida desde la base de datos.

Una vez obtenido los datos, estos son analizados para la elección de los algoritmos de máquinas de aprendizaje automático. En primer lugar se analiza la distribución de los datos, donde se observa que, según el HR, la mejor opción posible sería el uso de los clasificadores de Naive Bayes y Support Vector Machine, ya que su forma de distribución es aproximada a una distribución Gaussiana. Por otro lado, al analizar solamente el Delta HR se observa una concentración de datos entre los 0 y 10 latidos por minuto.

Posteriormente se analizó el comportamiento entre las variables y, debido a sus distribuciones, existen zonas donde se concentran los datos de estrés, lo que permite la utilización del clasificador KNN. Por último, se realiza un análisis tridimensional donde reafirma la utilización del clasificador KNN al observar zonas claramente definidas para el estado de estrés.

De lo anteriormente mencionado y en conjunto con lo visto en el estado del arte, la elección de los clasificadores son los siguientes: KNN, SVM y Naive Bayes.

Una vez escogido los clasificadores, se procede a realizar las pruebas de validación de los modelos donde se utiliza 80% de los datos para entrenamiento y verificación y 20% para pruebas, en conjunto con las métricas de rendimiento accuracy, recall, precisión y F-1, donde esta métrica consolida los valores de recall y precisión.

Los principales resultados obtenidos de las pruebas realizadas indican que el escenario menos favorable ocurre con HR utilizando el clasificador Naive Bayes, donde su accuracy promedio corresponde a 61.25 [%] y su F1 a 62.87[%], con una gran diferencia entre Recall y Precisión. Mientras que los mejores resultados se obtienen con Delta HR, con un accuracy promedio de 70,25[%] y F1 de 70,74[%]. Se considera este resultado como el mejor, no solo porque el accuracy se ubica entre los valores más altos obtenidos en las pruebas, sino también porque tanto recall como precisión presentan valores muy cercanos al 70%, lo que permite inferir que el resultado será poco tendencioso.

Por lo anteriormente dicho se puede concluir que el Delta HR es una variable fisiológica que por sí sola pudiera permitir la detección de cuadros de estrés.

CAPÍTULO 5. CONCLUSIÓN Y DISCUSIÓN

5.1 Discusión

Se desarrolló tanto un dispositivo electrónico *wearable* como un clasificador de estados de estrés y relajación mediante herramientas de aprendizaje automático. El dispositivo mide las señales de ECG incluso ante variaciones de HR, y realiza el cálculo del HR mediante el procesamiento del ECG a través del microcontrolador del dispositivo. La verificación del funcionamiento de este dispositivo se realiza a través de pruebas de laboratorio mediante un emulador de paciente el cual genera una señal ECG a distintos valores de HR.

Por otro lado, se diseñan dos tipos de electrodos textiles, la primera versión de estos tiene una vida útil de 1 semana, mientras que la segunda versión logra aumentar su vida útil a 5 meses, esto se debe a la mejora realizada del diseño de los electrodos (ver 3.2 A), gracias a la cual se reduce la pérdida de conducción de la tela. Los dos diseños realizados se pueden observar en la Figura 3-3.

Del análisis de variables de HR, Delta HR y Temperatura corporal, tanto por histograma como por análisis bidimensional y tridimensional, se escoge el uso de los clasificadores KNN, SVM y Naive Bayes. Estos clasificadores se entrenaron con los datos de 16 pacientes de la base de datos y se hicieron pruebas con los 4 restantes.

De los resultados obtenidos en 4.6 el mejor rendimiento se logra con el clasificador KNN, siendo la prueba de mejor desempeño aquella que incorpora todas las variables estudiadas (4.6.7) con un accuracy promedio de 68.5% y un

F1 de 73,47% y la prueba donde se utilizó solamente la variable Delta HR (4.6.2) con un accuracy promedio de 70.25% y un F1 de 70.74%. En comparación con otros estudios realizados, se logra una eficacia similar a aquellos que usan dos variables [59].

El uso de la variable Delta HR, sin importar el algoritmo utilizado, es más efectiva que Heart Rate para detectar el estrés con rangos de accuracy promedio que varían hasta un 10% de diferencia. Estos resultados discrepan de otros estudios realizados en los cuales se utilizar el Heart Rate en desmedro del Delta Heart Rate.

Estos resultados son sumamente relevantes, ya que, gracias a este método se puede detectar estrés de manera temprana y gracias a esto se puede ir realizando seguimiento tanto a personas como a zonas de trabajos y así evitar que el estrés generado en el trabajo pase a ser crónico.

5.2 Conclusión

En esta tesis, se diseña y desarrolla un dispositivo wearable que mide las variables fisiológicas de ECG, Heart Rate y temperatura, obteniendo resultados satisfactorios en cuanto a la lectura de ECG, de temperatura corporal y al cálculo. Este dispositivo procesa los datos anteriormente mencionados y la entrega de forma serial vía Wi-Fi con protocolo MQTT.

A pesar del buen funcionamiento del dispositivo diseñado, no fue posible utilizarlo debido a la situación de pandemia global y nacional, por lo cual, se optó por el uso de una base de datos proveniente de Physionet.

La base de datos cumple con todos los criterios definidos para su selección, lo que permitió obtener datos de 20 pacientes como: temperatura, H.R., edad, sexo, estatura y peso y estado de estrés. Además, se calculó el delta HR y el porcentaje de grasa. Los datos de 16 pacientes fueron utilizados para entrenar un algoritmo de aprendizaje automático y posteriormente realizar pruebas con los datos de 4 pacientes mediante tres clasificadores.

Del análisis previo realizado en el punto 4.4, donde se indica la temperatura como una variable a considerar, se comprobó con los resultados obtenidos que esta no favorece la detección de estrés en las personas, por lo cual se descarta su uso.

A pesar del buen desempeño de los clasificadores, el accuracy en ningún caso fue superior al 80%, esto se debe a que, al trabajar como pacientes sanos, su organismo naturalmente tiende a disminuir los niveles de Heart Rate ante estrés, lo que impacta negativamente en el clasificador. En caso de que los pacientes presenten estrés crónico el Heart Rate no se autorregula, esto permitiría al modelo poder clasificar los estados de estrés de manera más exacta y precisa.

Otro aspecto que podría apoyar en el mejoramiento del clasificador sería el uso de una mayor cantidad de pacientes sanos y pacientes con estrés crónico.

El uso de una sola variable (Delta Heart Rate) para una buena detección de estrés, permite reducir la cantidad de datos a manejar y almacenar, lo que facilita su implementación en las organizaciones. Esta información puede almacenarse por periodos largos de tiempo (1 o 2 años) según estime conveniente la empresa,

permitiendo evaluar la mejora o deterioro de cuadros de estrés en los trabajadores asociado a mejoras organizacionales.

Los algoritmos probados entregan la posibilidad de detección de estrés mediante variables fisiológicas y debido a que los resultados de accuracy promedio y F1 son cercanos al 70% se podría lograr monitorear de manera continua y permanente a los empleados de una empresa, detectando los niveles de estrés, no una sola vez al año como lo señala la normativa chilena (Ley 16.744 Sobre accidentes del trabajo y enfermedades profesionales), sino más bien durante toda su jornada y durante largos periodos de tiempo, pudiendo identificar aquellos trabajadores que presentan estrés de manera constante, dejando la subjetividad de las encuestas, por un mecanismo mucho más objetivo como lo son las variables fisiológicas. Esto permitiría focalizar los esfuerzos de diagnóstico y gestión de estrés en la empresa.

5.3 Trabajos futuros

Dentro de los trabajos futuros, se debe realizar un protocolo de bioética para la realización de pruebas con 30 personas tanto sanas como con estrés crónico (repartidas equitativamente), lo que permitirá mejorar el desempeño del clasificador, obteniendo así resultados más exactos. Además, se pueden estudiar otras variables fisiológicas como GSR, la frecuencia respiratoria, $SP0_2$, Presión arterial, por mencionar algunas. Igualmente, se deberá diseñar y desarrollar una interfaz gráfica que permita visualizar los resultados del clasificador para facilitar el seguimiento y control del estrés. Con estos cambios incorporados se espera

realizar una prueba piloto en ambientes laborales para poner a prueba el algoritmo en situaciones reales.

También, se pueden desarrollar investigaciones relacionadas a la clasificación de los tipos de estrés (físico, cognitivo y emocional), lo que permitirá facilitar la gestión organizacional de los trabajadores.



CAPÍTULO 6. BIBLIOGRAFIA

- [1] GfK, M. d. (Octubre de 2016). Estudio Mutual de Seguridad CChC + GfK: Mirada Generacional a la Seguridad y Salud en el Trabajo.
- [2] Superintendencia de salud (2017), Noticias Superintendencia. (Noviembre de 2020).. Obtenido de <http://www.supersalud.gob.cl/prensa/672/w3-article-16264.html>
- [3] Superintendencia de salud (2018), Análisis de licencias medicas y gastos en subsidios por incapacidad laboral en el sistema Isapres Año 2016
- [4] Mutuales, A. (2016). El silencioso avance de las enfermedades mentales en Chile.
- [5] Valera, S. (fecha revisión: 20 de Julio 2019). El modelo de Selye . Universitat de Barcelona.
- [6] Clinic, M. (Noviembre de 2018). Síntomas de estrés: consecuencias en tu cuerpo y en tu conducta. Obtenido de <https://www.mayoclinic.org/es-es/healthy-lifestyle/stress-management/in-depth/stress-symptoms/art-20050987>
- [7] Cecilia Barría. (Marzo de 2019). "El trabajo está matando a la gente y a nadie le importa". Obtenido de <https://www.bbc.com/mundo/noticias-47656050>
- [8] Cohen S, Karmarck T, Mermelstein R. A Global Measure of Perceived Stress. J Health Social Behav. 1983;24(4):385-396.

- [9] Sánchez, F. y otros (1993). *Psicología social*. Madrid: McGraw-Hill.
- [10] Cohen S, Williamson G. Perceived stress in a probability sample of the United States. IN: S. Scapan & S. Oskamp (eds). *The social psychology of health*: Claremont
- [11] Symposium on applied social psychology. Newbury park, CA, pp: 31-67.
- Remor E. Psychometric properties of a European Spanish version of the Perceived Stress Scale (PSS). *Spanish Journal of Psychology*. 2006;9(1):86-93.
- [12] Eun-Hyun L. Review of the psychometric evidence of the perceived stress scale. *Asian Nursing Research*. 2012;6:121-127.
- [13] Salgado-Madrid Marlon, Mo-Carrascal Joulen, Monterrosa-Castro Álvaro, "Escalas para estudiar percepción de estrés psicológico en el climaterio". *Revista Ciencias Biomedicas*, 2013;4(2):318-326.
- [14] Lovibond PF & Lovibond SH. The structure negative emotional states: comparison of the depression anxiety stress scale (DASS) with the beck depression and anxiety inventories. *Behavior Research and therapy*. 1995;33:335-343
- [15] Osman A, Wong JL, Bagge CL, Freedenthal S, Gutierrez PM, Lozano G. The Depression Anxiety Stress Scales—21 (DASS-21): Further

Examination of Dimensions, Scale Reliability, and Correlates. *J Clin Psychol.* 2012; 68(12):1322-1338.

- [16] Antony M, Cox B, Enns M, Bieling P, Swinson R. Psychometric properties of the 42-item and 21-item versions of the Depression Anxiety Stress Scales in clinical groups and a community sample. *Psychological Assessment.* 1998; 10(2):176-181.
- [17] Superintendencia de Seguridad Social (Revisión: Junio de 2019). Cuestionario de evaluación de riesgos psicosociales en el trabajo SUSESO/ISTAS21. Obtenido de <https://www.suseso.cl/606/w3-article-19640.html>
- [18] Jennifer A. Healey y Rosalinda W. Picard, « Detecting Stress During Real-World Driving Tasks Using Physiological Sensors», *IEEE Transactions on Intelligent Transportation Systems*, Vol.6 No. 2, June 2005.
- [19] N. Keshan, P. Parimi, e I. Bichindaritz. Machine Learning for Stress Detection from ECG Signals in Automobile Drivers. 2015 IEEE International Conference on Big Data (Big Data).
- [20] J. Birjandtalab, D. Cogan, M. Baran Pouyan, M. Nourani , « A non-EEG Biosignals Dataset for Assessment and Visualization of Neurological Status »,IEEE Workshop on Signal Processing System, 2016
- [21] Sun F. et. al. Activity-aware Mental Stress Detection Using

Physiological Sensors. CMU. 2010.
http://repository.cmu.edu/cgi/viewcontent.cgi?article=1011&context=silicon_valley

[22] Villarejo M. et. al. A Stress Sensor Based on Galvanic Skin Response (GSR) Controlled by ZigBee. 2012.
<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3386730/>

[23] S. Sriramprakash, Vadana D Prasanna, O.V. Ramana Murthy, «Stress Detection in Working People», Procedia Computer Science, Volume 115, 2017, Pages 359-366, ISSN 1877-0509.

[24] Deak T, Nguyen KT, Cotter CS, Fleshner M, Watkins LR, Maier SF, Spencer RL. Long-term changes in mineralocorticoid and glucocorticoid receptor occupancy following exposure to an acute stressor. Brain Research 1999; 847: 211-220.

[25] Garcia A, Marti O, Valles A, Dal-Zotto S, Armario A. Recovery of the hypothalamic-pituitary-adrenal response to stress. Effect of stress intensity, stress duration and previous stress exposure. Neuroendocrinology 2000; 72: 114-125.

[26] Clínica Mayo. (Julio de 2018). Prueba de cortisol. Obtenido de <https://medlineplus.gov/spanish/pruebas-de-laboratorio/prueba-de-cortisol/>

[27] Johns Hopkins Medicine [Internet]. Johns Hopkins Medicine; Health Library: Adrenal Glands. Obtenido de:

http://www.hopkinsmedicine.org/healthlibrary/conditions/adult/endocrinology/adrenal_glands_85,p00399

- [28] Wüst S, Federenko I, Hellhammer DH, Kirschbaum C. Genetic factors, perceived chronic stress, and the free cortisol response to awakening. *Psychoneuroendocrinology* 2000; 25: 707-720
- [29] Kirkcaldy BD, Shepard RJ, Furnham AF. The influence of typ A behaviour and locus of control upon job satisfaction and occupational health. *Personality and Individual Differences* 2002; 33: 1361-1371.
- [30] García de la Banda G, Martínez-Abascal MA, Riesco M, Pérez G. La respuesta de cortisol ante un examen y su relación con otros acontecimientos estresantes y con algunas características de personalidad. *Psicothema* 2004; 16(2): 294-298.
- [31] Parlak, O., Keene, S. T., Marais, A., Curto, V. F., & Salleo, A. (2018). Molecularly selective nanoporous membrane-based wearable organic electrochemical device for noninvasive cortisol sensing. *Science Advances*.
- [32] Kubota, T. (July de 2018). Wearable device from Stanford measures cortisol in sweat. Obtenido de Stanford News: <https://news.stanford.edu/2018/07/20/wearable-device-measures-cortisol-sweat/>
- [33] Aguilar Cordero, M. J., Sánchez López, A. M., Mur Villar, N., García García, I., Rodríguez López, M. A., Ortegón Piñero, A., & Cortes Castell,

- E. (2014). Cortisol salival como indicador de estrés fisiológico en niños y adultos. *Nutrición Hospitalaria*, 960-968.
- [34] Md. Dario Cobo, Md. Paola Daza, "Signos Vitales en Pediatría", *Revista Gastronhup*, Vol.13 no. 1, Suplemento1: S58-S70, Colombia, 2010.
- [35] B. Koeppen, B. Stanton, "Berne y Levy Fisiología", Sexta Edición, Elsevier, pp 310 – 316, 2009.
- [36] S. Fox, "Fisiología Humana", Doceava Edición, Mc Graw Hill Educación, pp. 425 – 426, 2011.
- [37] Technical Textiles Inc., Technical Application Guide Shieldex® Medtex P130, Palmyra, NY, 2018.
- [38] Castrillón, R., Pérez, J.J., & Andrade-Caicedo, H. (2018). Electrical performance of PEDOT:PSS-based textile electrodes for wearable ECG monitoring: a comparative study. *Biomedical engineering online*.
- [39] Acar Gizem, Ozturk Ozberk, Golparvar J. Ata, Elboshra, A. Tamador, Böhringerm Karl, Yapici, K. Murat. Wearable and Flexible Textile Electrodes for Biopotential Signal Monitoring: A review, *Electronics* 2019; Vol. 8. Issue 5.
- [40] Bouwstra, S.; Chen, W.; Feijs, L.; Oetomo, S.B. Smart jacket design for neonatal monitoring with wearable sensors. In *Proceedings of the Sixth International Workshop on Wearable and Implantable Body Sensor Networks*, Berkeley, CA, USA, 3–5 June 2009; pp. 162–167.

- [41] Coosemans, J.; Hermans, B.; Puers, R.J.S.; Physical, A.A. Integrating wireless ECG monitoring in textiles. *Sens. Actuators A Phys.* 2006, 130, 48–53.
- [42] Weder, M.; Hegemann, D.; Amberg, M.; Hess, M.; Boesel, L.; Abächerli, R.; Meyer, V.; Rossi, R. Embroidered Electrode with Silver/Titanium Coating for Long-Term ECG Monitoring. *Sensors* 2015, 15, 1750–1759.
- [43] Acar, G.; Ozturk, O.; Yapici, M.K. Wearable Graphene Nanotextile Embedded Smart Armband for Cardiac Monitoring. In Proceedings of the 2018 IEEE SENSORS, New Delhi, India, 28–31 October 2018.
- [44] Ottenbacher, J.; Romer, S.; Kunze, C.; Großmann, U.; Stork, W. Integration of a bluetooth based ECG System into clothing. In Proceedings of the Eighth International Symposium on Wearable Computers, Arlington, VA, USA, 31 October–3 November 2004.
- [45] Zheng, J.; Zhang, Z.; Wu, T.; Zhang, Y. A wearable mobihealth care system supporting real-time diagnosis and alarm. *Med. Biol. Eng. Comput.* 2007, 45, 877–885.
- [46] Linz, T.; Kallmayer, C.; Aschenbrenner, R.; Reichl, H. Fully untegrated EKG shirt based on embroidered electrical interconnections with conductive yarn and miniaturized flexible electronics. In Proceedings of the International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06), Cambridge, MA, USA, 3–5 April 2006.

- [47] HEXOSKIN, «Hexoskin Health sensors & AI,» HEXOSKIN, [En línea]. Available: <https://cdn.shopify.com/s/files/1/0284/7802/files/Hexoskin.pdf?15303810385753780610>. [Último acceso: Julio 2019].
- [48] Emglare, «Undershirt,» [En línea]. Available: <https://emglare.com/products/undershirt>. [Último acceso: Agosto 2019].
- [49] AdInstruments, Equivital Wearable ECG Starter Pack, [En línea]. Available: <https://www.adinstruments.com/products/equivital-starter-pack-single>[Último acceso: Agosto 2019].
- [50] QARDIO, QARDIOCORE, [En línea]. Available: <https://www.getqardio.com/es/qardiocore-wearable-ecg-ekg-monitor-iphone/> [Último acceso: Agosto 2019].
- [51] HeartBit, Technology, [En línea]. Available: <https://theheartbit.com/technology/> [Último acceso: Agosto 2019].
- [52] Analog Devices, AD8232, Norwood, MA, 2013.
- [53] Maxim Integrated, MAX30205, 2016.
- [54] Espressif Systems, ESP32 Datasheet V3.1, 2019.
- [55] Sibolboro E, Kelsey R, Katkin E, Sloan R. Vagal rebound and recovery from psychological stress. *Psychosomatic medicine* 2001;63:650-7
- [56] C.J. Cook, Rapid noninvasive measurement of hormones in transdermal exudate and saliva, *Physiol. Behav.* 75 (2002) 169–181.

- [57] PhysioNet, [En línea]. Available: <https://physionet.org/> [Último acceso: Noviembre 2019].
- [58] Non-EEG Dataset for Assessment of Neurological Status, PhysioNet, [En línea]. Available: <https://archive.physionet.org/cgi-bin/atm/ATM> [Último acceso: Noviembre 2019].
- [59] Cogan D, Pouyan MB, Nourani M, Harvey J. A wrist-worn biosensor system for assessment of neurological status. *Annu Int Conf IEEE Eng Med Biol Soc.* 2014;2014:5748-51. doi: 10.1109/EMBC.2014.6944933. PMID: 25571301.



CAPÍTULO 7. ANEXOS

7.1 Encuestas para la detección de estrés

7.1.1 PSS en sus tres versiones [13]

| Escala de estrés percibido (PSS) - Tres versiones | | | | | | | | |
|---|-------|------|---|-------|------------|------------------|----------|--------------|
| PSS14 | PSS10 | PSS4 | En el último mes | Nunca | Casi nunca | De vez en cuando | A menudo | Muy a menudo |
| Enumeración de preguntas | | | | | | | | |
| 1 | 1 | | ¿Con que frecuencia ha estado afectado por algo que ha ocurrido inesperadamente? | 0 | 1 | 2 | 3 | 4 |
| 2 | 2 | 1 | ¿Con que frecuencia se ha sentido incapaz de controlar las cosas importantes en su vida? | 0 | 1 | 2 | 3 | 4 |
| 3 | 3 | | ¿Con que frecuencia se ha sentido nervioso o estresado? | 0 | 1 | 2 | 3 | 4 |
| 4 | | | ¿Con que frecuencia ha manejado con éxito los pequeños problemas irritantes de la vida? | 4 | 3 | 2 | 1 | 0 |
| 5 | | | ¿Con que frecuencia ha sentido que ha afrontado efectivamente los cambios importantes que han estado ocurriendo en su vida? | 4 | 3 | 2 | 1 | 0 |
| 6 | 4 | 2 | ¿Con que frecuencia ha estado seguro sobre su capacidad | 4 | 3 | 2 | 1 | 0 |

| | | | | | | | | |
|----|----|---|--|---|---|---|---|---|
| | | | para manejar sus problemas personales? | | | | | |
| 7 | 5 | 3 | ¿Con que frecuencia ha sentido que las cosas le van bien? | 4 | 3 | 2 | 1 | 0 |
| 8 | 6 | | ¿Con que frecuencia ha sentido que no podía afrontar todas las cosas que tenía que hacer? | 0 | 1 | 2 | 3 | 4 |
| 9 | 7 | | ¿Con que frecuencia ha podido controlar las dificultades de su vida? | 4 | 3 | 2 | 1 | 0 |
| 10 | 8 | | ¿Con que frecuencia se ha sentido que tenía todo bajo control? | 4 | 3 | 2 | 1 | 0 |
| 11 | 9 | | ¿Con que frecuencia ha estado enfadado porque las cosas que le han ocurrido estaban fuera de su control? | 0 | 1 | 2 | 3 | 4 |
| 12 | | | ¿Con que frecuencia ha pensado sobre las cosas que le quedan por lograr? | 0 | 1 | 2 | 3 | 4 |
| 13 | | | ¿Con que frecuencia ha podido controlar la forma de pasar el tiempo? | 4 | 3 | 2 | 1 | 0 |
| 14 | 10 | 4 | ¿Con que frecuencia ha sentido que las dificultades se acumulaban tanto que no puede superarlas? | 0 | 1 | 2 | 3 | 4 |

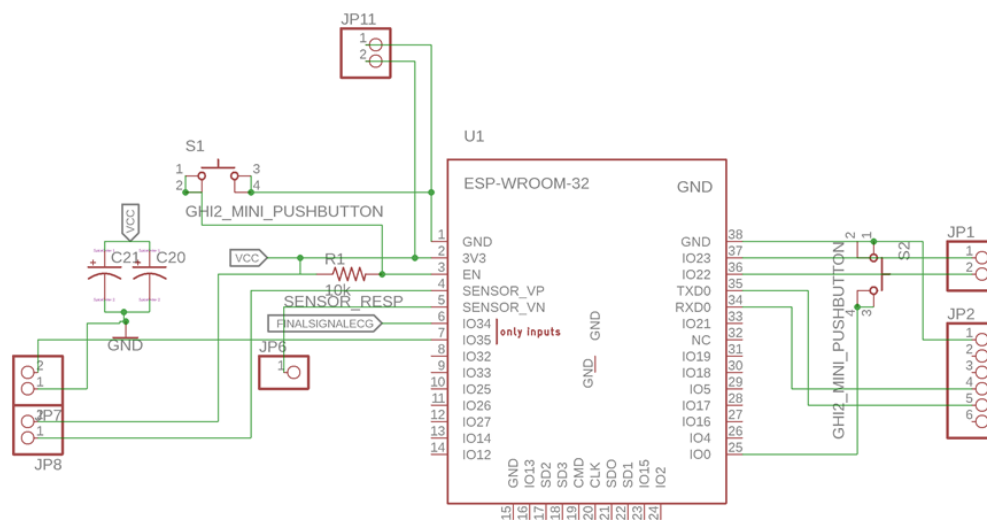
7.1.2 DASS en su versión de 21 preguntas o DASS-21[13]

| Escala de depresión, ansiedad y estrés (DASS-21) | | | | | |
|--|--|-----------------------------|---|---|-----------------------|
| En el último mes | | No se aplica a mí, absoluto | | | Si aplica a mí, mucho |
| 1 | Me costó mucho relajarme | 0 | 1 | 2 | 3 |
| 2 | Me di cuenta que tenía la boca seca | 0 | 1 | 2 | 3 |
| 3 | No podía sentir ningún sentimiento positivo | 0 | 1 | 2 | 3 |
| 4 | Se me hizo difícil respirar | 0 | 1 | 2 | 3 |
| 5 | Se me hizo difícil tomar la iniciativa para hacer cosas | 0 | 1 | 2 | 3 |
| 6 | Reaccioné exageradamente en ciertas situaciones | 0 | 1 | 2 | 3 |
| 7 | Sentí que mis manos temblaban | 0 | 1 | 2 | 3 |
| 8 | Sentí que tenía muchos nervios | 0 | 1 | 2 | 3 |
| 9 | Estaba preocupado por las situaciones en las cuales podía tener pánico o en las que podría hacer el ridículo | 0 | 1 | 2 | 3 |
| 10 | Sentí que no tenía nada por qué vivir | 0 | 1 | 2 | 3 |
| 11 | Note que me agitaba | 0 | 1 | 2 | 3 |
| 12 | Se me hizo difícil relajarme | 0 | 1 | 2 | 3 |
| 13 | Me sentí triste y deprimido | 0 | 1 | 2 | 3 |

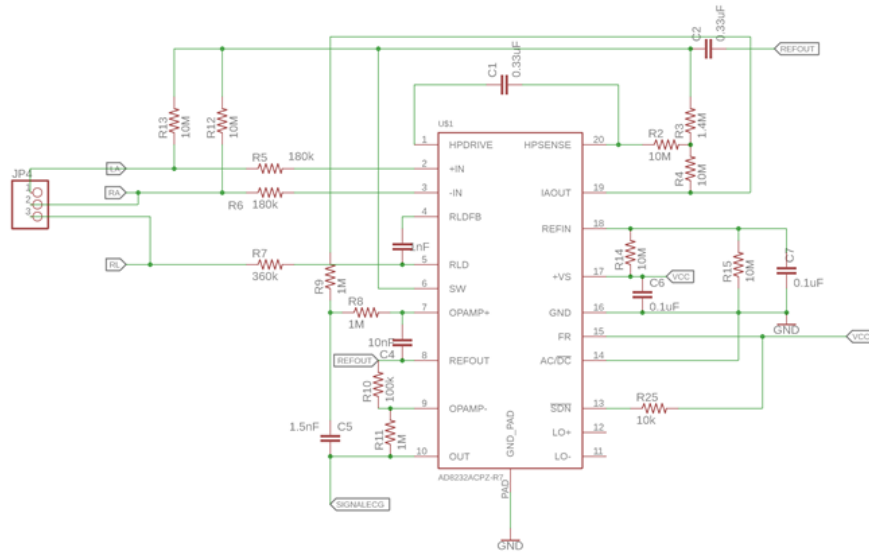
| | | | | | |
|----|--|---|---|---|---|
| 14 | No tolere nada que no me permitiera continuar con lo que estaba haciendo | 0 | 1 | 2 | 3 |
| 15 | Sentí que estaba a punto de pánico | 0 | 1 | 2 | 3 |
| 16 | No me pude entusiasmar por nada | 0 | 1 | 2 | 3 |
| 17 | Sentí que valía muy poco como persona | 0 | 1 | 2 | 3 |
| 18 | Sentí que estaba muy irritable | 0 | 1 | 2 | 3 |
| 19 | Sentí los latidos de mi corazón a pesar de no haber hecho ningún esfuerzo físico | 0 | 1 | 2 | 3 |
| 20 | Tuve miedo sin razón | 0 | 1 | 2 | 3 |
| 21 | Sentí que la vida no tenía ningún sentido | 0 | 1 | 2 | 3 |

7.2 Circuitos electrónicos

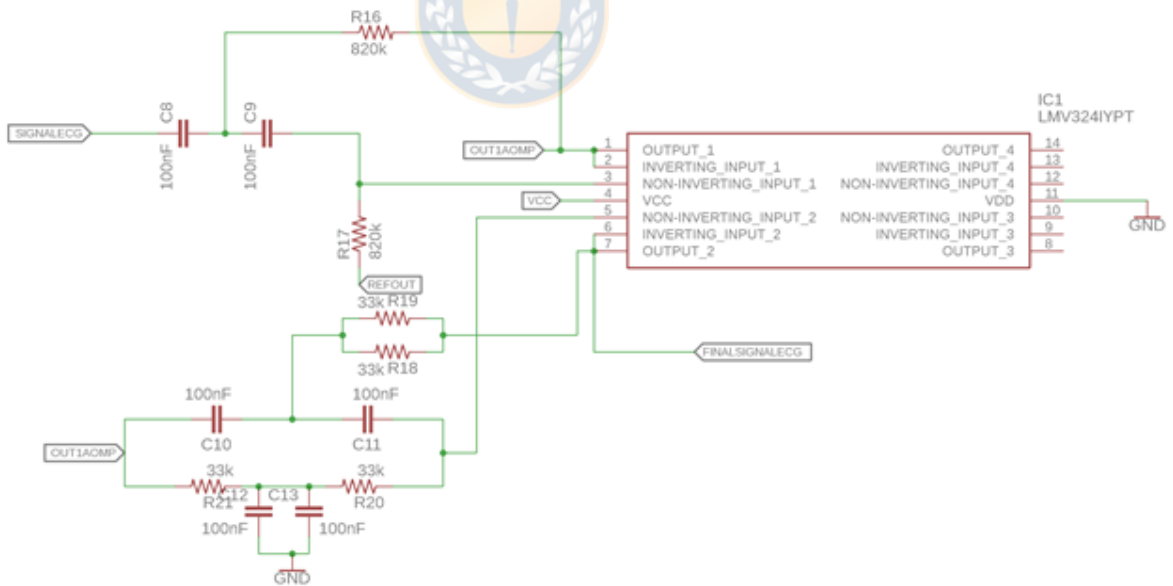
7.2.1 Etapa Procesamiento



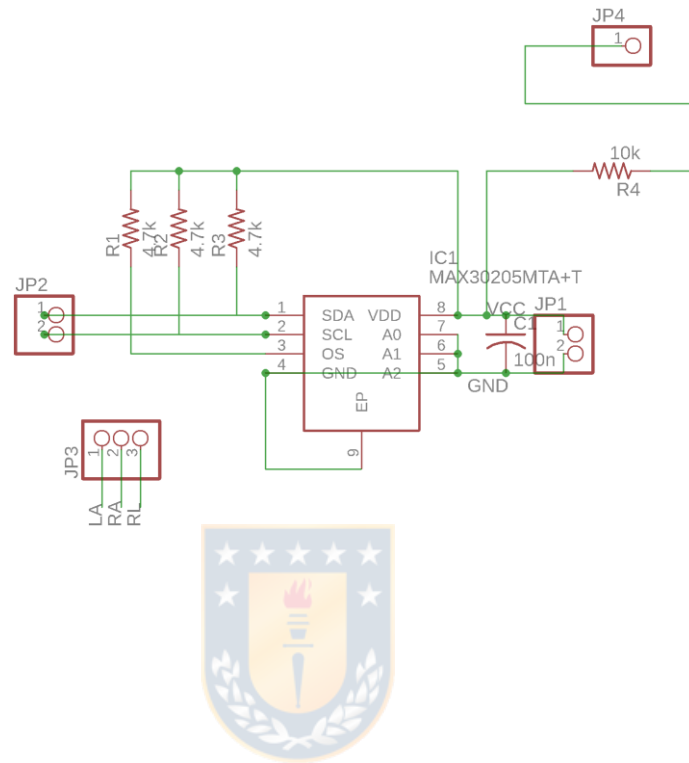
7.2.2 Etapa Electrocardiograma



7.2.3 Etapa Filtros



7.2.4 Temperatura corporal



7.2.5 Etapa Energización

