



BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA

FACULTAD DE CIENCIAS DE LA ELECTRÓNICA

MAESTRÍA EN CIENCIAS DE LA ELECTRÓNICA
OPCIÓN EN AUTOMATIZACIÓN

**“Implementación de algoritmos de clasificación
basados en aprendizaje automático para la detección
de eventos de ansiedad”**

T E S I S

Presentada para obtener el título de:
Maestro en Ciencias de la Electrónica Opción en Automatización

Presenta:

Alfonso Andrade Gonzalez*

Directores:

Dra. Amparo Dora Palomino Merino (FCE-BUAP)

Dra. María Monserrat Morín Castillo (FCE-BUAP)

Dra. Alina Santillán Guzmán (BAM-UPAEP)

Puebla, México

Julio 2023

* Becario CONACYT

BUAP®

Agradecimientos

Agradezco profundamente a mi madre, Gloria del Rosario González Gastelum, y a mi hermana, Emma Gloria Andrade González, por brindarme el apoyo y el cariño que me ha ayudado a perseguir mis metas y no rendirme ante las adversidades.

A mis asesoras de tesis, la Dra. María Monserrat Morín Castillo, la Dra. Amparo Dora Palomino Merino y la Dra. Alina Santillán Guzmán, por permitirme formar parte de este equipo de trabajo. Gracias por su guía y por acompañarme durante todo este proceso.

Al comité revisor, la Dra. María del Carmen Cortés Sánchez, el Dr. Luis Abraham Sánchez Gaspariano y el Dr. Carlos Leopoldo Pando Lambruschini, por sus consejos y observaciones que ayudaron a mejorar este trabajo y alcanzar los objetivos planteados.

A la Benemérita Universidad Autónoma de Puebla (BUAP), y a todos los docentes por transmitirme los conocimientos que me permitieron desarrollar este proyecto.

Finalmente, agradecer a CONAHCYT por el apoyo económico brindado que me permitió llevar a cabo mis estudios de maestría.

Resumen

Se presenta el trabajo de tesis correspondiente al desarrollo de un algoritmo para la detección de eventos de ansiedad. Se comienza por el estudio de los tipos de trastornos de ansiedad en conjunto con sus síntomas característicos con el objetivo de identificar las señales fisiológicas necesarias para la detección de un evento de ansiedad. Posteriormente, se utiliza una base de datos extraída de pacientes diagnosticados con trastorno de ansiedad para la caracterización de las señales, tanto en el dominio del tiempo, como en el de la frecuencia, implementando un algoritmo de procesamiento desarrollado en lenguaje de programación Python. Se hace la comparación de las señales de los pacientes durante un evento de ansiedad y en estado de reposo para seleccionar aquellos atributos útiles para identificar correctamente las señales correspondientes a un evento de ansiedad. Se implementan algoritmos de clasificación basados en aprendizaje automático en conjunto con los atributos seleccionados para identificar los periodos de tiempo en los que el paciente sufrió de un evento de ansiedad. Al finalizar el algoritmo, se pone a prueba y se ajustan los parámetros de clasificación para alcanzar una mejor precisión. Se publican los resultados obtenidos y se escribe el trabajo de tesis simultáneamente.

Índice general

Agradecimientos	III
Resumen	V
Introducción	IX
Objetivos	XIV
1. Preliminares de investigación	1
1.1. El trastorno de ansiedad	1
1.2. Tipos de trastornos de ansiedad	3
1.3. Señales biomédicas	5
1.4. Identificación de las señales de mayor interés	6
2. El electrocardiograma y la respuesta galvánica de la piel	7
2.1. Electrocardiograma	7
2.1.1. Frecuencia cardíaca	10
2.1.2. Alteraciones en la frecuencia cardíaca	10
2.2. Respuesta galvánica de la piel	12
2.2.1. Parámetros en la respuesta galvánica de la piel	12
2.2.2. La hiperhidrosis	13

3. Procesamiento y caracterización de las señales fisiológicas	14
3.1. La base de datos	14
3.1.1. Descripción del experimento	14
3.1.2. Criterios de exclusión y requisitos	15
3.1.3. Tamaño de la muestra	16
3.1.4. Mediciones realizadas	16
3.1.5. Sesión de exposición	17
3.2. Procesamiento de la base de datos	18
3.2.1. Extracción	18
3.2.2. Segmentación	19
3.2.3. Procesamiento	20
3.3. Caracterización de las señales fisiológicas obtenidas	24
3.3.1. Caracterización de las señales ECG	27
3.3.2. Caracterización de las señales GSR	28
4. Análisis de las señales en el dominio del tiempo	30
4.1. Atributos para las señales de Electrocardiograma	30
4.1.1. Algoritmo de Pan-Tompkins	30
4.1.2. Atributos seleccionados	32
4.2. Atributos para las señales de respuesta galvánica de la piel	33
4.2.1. Procedimiento de extracción de atributos GSR	34
4.2.2. Atributos seleccionados	35
5. Análisis de las señales en el dominio de la frecuencia	40
5.1. Análisis espectral	40
5.1.1. Densidad de la potencia espectral	41
5.2. Atributos para las señales de electrocardiograma	43

5.2.1. Procedimiento de extracción de atributos ECG	43
5.2.2. Atributos seleccionados	43
5.3. Atributos para las señales de Respuesta Galvánica de la Piel	44
5.3.1. Procedimiento de extracción de atributos GSR	45
5.3.2. Atributos seleccionados	47
6. Clasificación de las señales con ansiedad	48
6.1. Etiquetado de las señales	48
6.2. Clasificadores seleccionados	49
6.2.1. Bosques aleatorios	49
6.2.2. Máquina de vectores de soporte	50
6.2.3. K-Vecinos más cercanos	52
6.2.4. Redes neuronales	53
6.2.5. Selector de atributos	55
6.3. Selección de atributos y validación	56
6.3.1. Validación del modelo	56
7. Resultados de clasificación	58
7.1. Cálculo de la precisión de clasificación	58
7.2. Precisión de clasificación de cada algoritmo	58
7.3. Matriz de confusión	60
7.4. Comparación con investigaciones previas	61
7.4.1. Tabla de comparación	61
7.4.2. Figura de mérito	62
Conclusiones	66
Bibliografía	69

Introducción

Antecedentes

Existen diversas herramientas e instrumentos para detectar los niveles de ansiedad de un sujeto, manuales de diagnóstico y herramientas psicométricas son utilizadas con mayor frecuencia por profesionales de la salud para la detección y estimación de los niveles de ansiedad. Actualmente, esfuerzos de la ciencia se han enfocado en desarrollar algoritmos computacionales que, por medio de la medición de variables fisiológicas y la implementación de estrategias de aprendizaje automático, detectan los instantes de tiempo en los que el sujeto está sufriendo un evento de ansiedad. En esta sección se explican algunas investigaciones que comparten este enfoque.

Physiological detection of anxiety

Durante la investigación [1], se hace uso de variables derivadas de señales de electrocardiograma (ECG) extraídas de 15 pacientes para la detección de señales con ansiedad. La metodología implementada consiste en el uso del algoritmo de Pan-Tompkins [2] para la detección de las ondas R de las señales de ECG, las cuales representan un latido del corazón del paciente, y con esta información calcula variables estadísticas de los intervalos RR, los cuales representan la variación de tiempo en que ocurren 2 latidos consecutivos. Las variables estadísticas calculadas en este caso fueron: intervalo RR promedio, intervalo RR mínimo e intervalo RR máximo.

Las características extraídas de las señales fisiológicas fueron utilizadas en conjunto con 2 algoritmos de aprendizaje automático: máquina de vectores de soporte (MVS) y filtros de Kalman. Para el caso de la máquina de vectores de soporte, se utilizaron 7 muestras para entrenar el algoritmo y 3 muestras para poner a prueba su precisión.

En el caso del filtro de Kalman, al ser un algoritmo no supervisado, no requiere de entrenamiento.

La precisión reportada por esta investigación fue del 71.1 % para el clasificador basado en máquina de vectores de soporte y 69.35 % con el clasificador basado en filtros de Kalman.

Toward constructing a real-time social anxiety evaluation system: exploring effective heart rate features

El trabajo [3] presenta un algoritmo para la detección de ansiedad utilizando solamente atributos derivados de las señales ECG. El experimento fue enfocado a estudiar el trastorno de ansiedad de tipo fobia social, por lo que se reclutaron 57 sujetos que sufrían de esta condición. Para detonar su ansiedad y poder medir sus señales fisiológicas, los sujetos tuvieron que presentar una plática frente a un público, a la vez que sus señales ECG eran monitoreadas y almacenadas. Otro experimento realizado con el objetivo de probar la eficiencia del algoritmo desarrollado fue adquirir las señales fisiológicas de estudiantes que presentaban su defensa de tesis.

Fueron propuestos una gran cantidad de atributos de las señales ECG, en conjunto con diversos algoritmos de clasificación basados en aprendizaje automático, por lo que se implementó una herramienta selectora de atributos que permite seleccionar aquellas que garantizan la mayor precisión de clasificación para cada algoritmo. Las conclusiones de la investigación definieron que el algoritmo con mayor precisión en la detección de ansiedad fue la maquina de vectores de soporte, utilizando atributos relacionados con la variabilidad de la frecuencia cardíaca (VFC) y realizando un análisis de la potencia en la banda de frecuencias de 0.15 Hz a 0.4 Hz. La mejor precisión obtenida durante esta investigación fue del 97.2 % en los pacientes que realizaron la plática frente a un público, mientras que el algoritmo tuvo una precisión del 81.8 % en la detección de ansiedad de los estudiantes que estaban realizando su defensa de tesis.

On-line anxiety level detection from biosignals: machine learning based on a randomized controlled trial with spider fearful individuals

El enfoque de la investigación [4] fue desarrollar un algoritmo para la detección de distintos niveles de ansiedad implementando herramientas de aprendizaje automático supervisado. El experimento consistió en aplicar una terapia de exposición a 80 pacientes

con trastorno de ansiedad de fobia específica hacia las arañas, donde se les presentaron 16 videos extraídos de documentales de televisión que mostraban imágenes detalladas de arañas, lo que causaba un aumento en los niveles de ansiedad del paciente. Durante la terapia de exposición se recopilaron 3 tipos de señales fisiológicas: ECG, Respuesta Galvánica de la Piel (GSR) y frecuencia de respiración. Al finalizar la visualización de los 16 videos, los pacientes tuvieron una etapa de reposo de 5 minutos, en los cuales sus señales fisiológicas seguían siendo recolectadas. A partir de estas señales fisiológicas, se extrajeron distintos atributos que posteriormente fueron utilizados en conjunto con algoritmos de aprendizaje automático supervisado para clasificar las muestras. La clasificación se realizó en 2 modalidades: 2 niveles y 3 niveles. La clasificación en 2 niveles consiste en definir si la señal presenta ansiedad o no. La clasificación en 3 niveles habla de una escala en la que se define si el nivel de ansiedad es nulo, moderado o alto.

Para realizar la detección de ansiedad, se pusieron a prueba distintos algoritmos de aprendizaje automático supervisado: MVS, K-vecinos más cercanos (K-VMC), árboles de decisión, análisis discriminante (lineal y cuadrático), Naïve Bayes y árboles anidados. Al final de la investigación, el algoritmo que demostró mayor precisión de clasificación fue el de árboles anidados, con una precisión del 89.8 % en la clasificación de 2 niveles y 74.4 % en la clasificación de 3 niveles.

A neural network approach for anxiety detection based on ECG

En la investigación mostrada en [5] se hace uso de atributos extraídos de señales ECG derivados de la variabilidad de la frecuencia cardíaca extraídos de ventanas de tiempo de 60 segundos. En este caso fueron estudiados 57 sujetos con fobia a las arañas sometidos a terapia de exposición mientras sus señales fisiológicas eran recolectadas. Al finalizar la terapia de exposición, los sujetos comenzaban la etapa de reposo en la que las señales fisiológicas seguían siendo adquiridas.

Los atributos seleccionados se utilizaron en conjunto con una red neuronal convolucional de una dimensión para hacer la clasificación de las muestras con ansiedad. El atributo seleccionado de la VFC para realizar la detección fue la raíz del cuadrado de las diferencias sucesivas promedio (RCDSP). La precisión alcanzada por esta propuesta fue de 83.2 % en las muestras de validación y del 77.1 % en las muestras de prueba.

Planteamiento del problema

En la actualidad no existe un estudio médico enfocado directamente a la detección de trastornos de ansiedad, lo que en ocasiones genera diagnósticos erróneos y desvíos en la búsqueda de la verdadera causa de los padecimientos del paciente. En el momento de la consulta, el médico depende únicamente de la memoria del paciente como fuente de información acerca de los eventos de ansiedad que este ha presentado, por lo tanto, no existe un registro de datos que sean completamente objetivos para que el médico pueda conocer el impacto del tratamiento indicado al paciente.

Justificación

Los trastornos de ansiedad, trastorno del espectro autista (TEA), así como otras manifestaciones similares como el estrés y la depresión, han aumentado en los últimos años. Según el Senado de la república mexicana, aproximadamente el 14.3% de la población mexicana padece trastornos de ansiedad generalizada, siendo la enfermedad de salud mental más común en el país, seguido por la depresión y adicciones, ambas en un porcentaje del 9% [6]. De acuerdo con la Organización Mundial de la Salud (OMS) se calcula que uno de cada 10 pacientes con un trastorno de ansiedad se atienden diariamente en el mundo [7]. En muchos de los casos no es posible detectar a tiempo un padecimiento de ansiedad, e incluso puede llegar a confundirse el diagnóstico. Actualmente con la situación que se vive a nivel mundial por la pandemia generada por el COVID 19, no ha sido posible dar seguimiento a pacientes que ya padecían un trastorno de ansiedad y han aparecido muchos pacientes potenciales que están a la espera de un diagnóstico. La tecnología ha ofrecido nuevas posibilidades para tratar este tipo de padecimientos, mejorando la calidad de vida de las personas. Una de las formas que se ha ofrecido es a través de consultas en línea, algunas aplicaciones en el celular, comando de voz, entre otros.

Propuesta de solución del problema

Las personas que sufren alteraciones de ansiedad presentan síntomas o manifestaciones físicas como fatiga, trastornos del sueño, tensión muscular, nerviosismo, sudoración e irritabilidad [7], e incluso hay ocasiones en las que los síntomas de un paciente que pade-

ce de un trastorno de ansiedad no son detectados fácilmente, aún para los profesionales de la salud, por lo que la problemática que se afronta es identificar aquellas manifestaciones fisiológicas que permitan caracterizar e identificar un evento de ansiedad. Esto hace necesaria la implementación de tecnologías computacionales capaces de detectar los instantes de tiempo en los que el paciente sufre un evento de ansiedad por medio del monitoreo y caracterización de sus señales fisiológicas. Esta solución ayudaría a corroborar el diagnóstico de trastornos de ansiedad, aseguraría la detección temprana de este padecimiento, brindaría información objetiva acerca del impacto que está generando el tratamiento en el paciente y así se evitarían efectos secundarios de los trastornos de ansiedad.

Objetivos

Los objetivos general y específicos de este trabajo de tesis se enuncian a continuación.

Objetivo general

Desarrollar un algoritmo para la detección de eventos de ansiedad a partir de la caracterización de algunas señales fisiológicas presentadas por un paciente diagnosticado con un trastorno de ansiedad.

Objetivos particulares

Los objetivos particulares de este trabajo se enumeran a continuación:

1. Investigación e identificación de señales fisiológicas presentadas por personas que padecen de un trastorno de ansiedad.
 2. Búsqueda de una base de datos y/o adquisición de señales fisiológicas de personas sanas y con un trastorno de ansiedad.
 3. Caracterización de las señales o manifestaciones de personas con trastorno de ansiedad.
 4. Elaborar un algoritmo para la detección de eventos de ansiedad.
-

Capítulo 1

Preliminares de investigación

1.1. El trastorno de ansiedad

La ansiedad es una respuesta común del cuerpo frente a situaciones determinadas. El concepto de ansiedad suele confundirse con el sentimiento del miedo. La ansiedad es una señal de alerta; advierte de un peligro inminente y permite al individuo adoptar medidas para afrontar una amenaza. El miedo es una señal de alerta análoga, pero debe diferenciarse de la ansiedad: el primero es una respuesta a una amenaza conocida, externa, definida o no conflictiva; la segunda es una respuesta a una amenaza desconocida, interna, vaga o conflictiva [8].

La ansiedad es una emoción normal que cumple una función adaptativa en numerosas situaciones. Todo organismo viviente necesita contar con algún mecanismo de vigilancia que permita su supervivencia, y la ansiedad cumple ese papel en numerosas situaciones. Así, es normal, y deseable, que el ser humano tenga miedo cuando se acerca un peligro real. El organismo está preparado para aprender a sentir miedo y ansiedad en determinadas circunstancias como una forma de prevenir consecuencias mayores [9]. Sin embargo, existen ocasiones en que estos mecanismos de defensa dejan de funcionar adecuadamente y activan el estado de alarma frente a situaciones o estímulos inofensivos. Es aquí donde puede considerarse la presencia de un trastorno de ansiedad.

Los trastornos de ansiedad se caracterizan por tener a la ansiedad o el miedo como elementos principales del sufrimiento humano. Cada trastorno se refiere a un conjunto característico de síntomas y sensaciones que suelen aparecer en la misma persona [9]. Los síntomas más comunes que puede presentar una persona con trastorno de ansiedad son [8]:

- Epigastralgia: dolor en epigastrio, siendo esta la región situada anterior, superior y
-

central del abdomen.

- **Diarrea:** se conoce como diarrea a las heces acuosas o blandas. Se puede decir que una persona padece de diarrea si evacua heces sueltas tres o más veces al día.
 - **Hiperhidrosis:** es la sudoración anormal o excesiva que no está asociada con el calor o el ejercicio físico.
 - **Hiperreflexia:** es una reacción anormal y exagerada del sistema nervioso autónomo frente a una estimulación. Esto puede incluir cambio de la frecuencia cardíaca, sudoración excesiva, hipertensión arterial, espasmos musculares, cambios en el color de la piel.
 - **Inquietud:** estar en constante movimiento, por ejemplo caminar de un lado a otro sin motivo aparente.
 - **Midriasis:** consiste en la dilatación de la pupila del ojo.
 - **Palpitaciones:** sensación de que el corazón está latiendo más rápido de lo normal y golpea fuertemente.
 - **Parestesias de las extremidades:** sensibilidad de tipo irritativo que se manifiesta en la persona con sensaciones anormales sin previo estímulo, por ejemplo el conocido hormigueo.
 - **Polaquiuria:** es la necesidad de orinar muchas veces durante el día y la noche, en ocasiones en volúmenes normales o inferiores a lo normal.
 - **Síncope:** es una pérdida espontánea y temporal de la conciencia y de la postura. Esta tiene una duración breve y recuperación al instante. Se produce por una disminución transitoria del flujo sanguíneo hacia el cerebro.
 - **Taquicardia:** es un término médico para referirse a una frecuencia cardíaca mayor a 100 latidos por minuto.
 - **Temblores:** movimiento rítmico involuntario de sacudidas en una o más partes del cuerpo. Se produce a consecuencia de las contracciones musculares.
 - **Vértigo:** es una sensación comúnmente descrita como mareo. Las personas con vértigo sienten que están girando, o que el mundo está girando a su alrededor.
-

La experiencia de la ansiedad tiene dos componentes: las sensaciones fisiológicas (por ejemplo, palpitaciones) y la de estar nervioso o asustado. Un sentimiento de vergüenza puede aumentar la ansiedad. Además de los efectos fisiológicos, la ansiedad afecta al pensamiento, a la percepción y al aprendizaje. Tiende a producir confusión y distorsiones de la percepción, no solo del tiempo y del espacio, sino también de los individuos y del significado de los acontecimientos. Estas distorsiones pueden interferir con el aprendizaje y deteriorar la concentración y la memoria [8].

Los niveles de ansiedad resultan de la suma de las respuestas fisiológicas y conductuales ante los eventos externos o internos que activan el sistema cerebral, lo que da paso a los síntomas característicos del trastorno de ansiedad (expresión facial, cambio de postura, variación del tono de la voz, sudoración, aumento del ritmo cardíaco, la frecuencia respiratoria entre otros) [10]. Al aumento de los niveles de ansiedad es a lo que se denominará un evento de ansiedad, y la detección de su presencia será el objetivo principal del trabajo actual.

1.2. Tipos de trastornos de ansiedad

Los trastornos de ansiedad son considerados como una familia de trastornos mentales distintos, pero que están relacionados entre si, que incluyen los siguientes [8]:

1. Trastorno de pánico
2. Agorafobia
3. Fobia específica
4. Trastorno de ansiedad social o fobia social
5. Trastorno de ansiedad generalizada

A continuación se explican brevemente cada uno de los 5 trastornos enunciados anteriormente basados el libro “Sinopsis de la psiquiatría” [8]:

El trastorno de pánico está caracterizado por la presencia de eventos en los que el sujeto tiene sensación de crisis intensa acompañada por catástrofe inminente. Este tipo de ansiedad tiene la característica de presentarse en periodos discretos de pánico intenso que pueden ir de varias crisis en un solo día o una presencia aleatoria de sucesos durante 1 año.

La agorafobia se refiere al miedo o ansiedad a los lugares de los que se puede creer que son difíciles de escapar. De las fobias que son consideradas parte de los trastornos de

ansiedad, se considera la que puede causar mayor incapacidad en la vida diaria del individuo, ya que puede interferir significativamente con la capacidad funcional del individuo fuera de su hogar, como lo puede ser en el ámbito laboral y social. Se cree que el miedo de padecer un ataque de pánico en un sitio público del que sea difícil escapar constituye la causa de la agorafobia. Aunque la agorafobia a menudo coexiste con el trastorno de pánico.

Se habla de fobia específica cuando el sujeto presenta miedo excesivo a un objeto, circunstancia o situación específicos. El diagnóstico de fobia específica requiere la aparición de una ansiedad intensa, hasta llegar al pánico, cuando se expone el paciente al objeto o situación temidos. Los individuos con fobia específica pueden anticipar el daño, o pueden presentar angustia con el miedo a perder el control o que los controle el pánico; por ejemplo, si tienen miedo a utilizar un ascensor, también pueden preocuparse por si se desmayarán después de cerrarse las puertas.

El trastorno de ansiedad social, también conocido como fobia social, implica el miedo a situaciones sociales, principalmente situaciones que involucran la interacción con sujetos desconocidos. Las personas con trastorno de ansiedad social tienen miedo de sentir vergüenza en situaciones sociales, por lo que en ocasiones se excluyen ellos mismos del resto. Tienen un miedo específico a realizar actividades específicas como comer o hablar ante otras personas, o pueden sufrir un miedo sin sentido a pasar vergüenza.

El trastorno de ansiedad generalizada es el más relacionado a la respuesta biológica que presenta un individuo frente a una situación de peligro. La ansiedad se define como una respuesta normal y adaptativa a la amenaza que prepara al organismo para la lucha o la huida. Sin embargo, cuando el individuo presenta esta ansiedad adaptativa casi todo el tiempo reciben el diagnóstico de trastorno de ansiedad generalizada. Este trastorno se define como una ansiedad y preocupación excesivas sobre diversos acontecimientos o actividades durante la mayor parte del día, comportamiento que suele extenderse a lo largo de un periodo de 6 meses como mínimo. La preocupación que presentan es difícil de controlar y se asocia a síntomas somáticos como tensión muscular, irritabilidad, trastornos del sueño e inquietud. La ansiedad no se centra en características de otro trastorno, no está causada por el consumo de una sustancia ni una afección orgánica, y no se produce solo durante un trastorno del estado de ánimo o psiquiátrico.

1.3. Señales biomédicas

Las señales biomédicas son utilizadas en el campo de la biomedicina para extraer información acerca del cuerpo biológico investigado. El método de adquisición de estas señales puede variar en dificultad ya que en ocasiones no es suficiente con una etapa de adquisición, también es necesaria una etapa de procesamiento que separe la señal de interés de una señal de origen, es decir, filtrar toda la información que no es requerida para obtener solamente la necesaria. Existen diferentes fuentes de origen para las señales biomédicas, a continuación se presenta una breve descripción de ellas [11]:

- **Bioeléctricas:** son producidas por las células nerviosas y musculares. Su fuente es el potencial de la membrana celular la cual es excitada para generar un potencial de acción, considerada como la señal biomédica.
 - **Bioimpedancia:** es la impedancia generada por los tejidos del cuerpo, esta puede otorgar información como su composición, volumen sanguíneo, distribución sanguínea, actividad y composición endocrina, actividad del sistema nervioso autónomo y demás información. Para obtener la respuesta se inyectan señales sinusoidales de baja corriente con dos electrodos y se utilizan otros dos electrodos para realizar la medición de la impedancia.
 - **Bioacústicas:** son señales de sonido producidas por el cuerpo humano. Como ejemplo de estas se tienen los sonidos generados por el flujo sanguíneo hacia el corazón, sonidos generados por la respiración, en el tracto digestivo o contracturas musculares. Estas señales son adquiridas por medio de transductores acústicos como micrófonos o acelerómetros.
 - **Biomagnéticas:** es la lectura de la señal generada por el campo magnético de algunos órganos. Son señales que requieren de mucha precaución para ser adquiridas
 - **Biomecánicas:** señales generadas a partir de funciones mecánicas de los cuerpos biológicos. En este tipo están incluidas las señales de desplazamiento, presión y tensión, señales de flujo, entre otras. El método de adquisición de estas señales es por medio de transductores.
 - **Bioquímicas:** son el resultado de mediciones químicas del tejido vivo, ya sea medido directamente o a partir de una muestra en un laboratorio clínico. Se mide la concentración de iones dentro y fuera de las células por medio de electrodos muy específicos. Usualmente las mediciones de estas señales son de corriente directa.
-

- Bioópticas: son el resultado de funciones ópticas del sistema biológico, las cuales pueden ocurrir naturalmente o inducidas para propósitos de medición.

1.4. Identificación de las señales de mayor interés

El objetivo de la presente investigación es el desarrollo de un algoritmo para la detección de eventos de ansiedad, considerando que en un futuro pueda implementarse en un dispositivo vestible. Anteriormente se habló de los síntomas que presenta un paciente con trastorno de ansiedad, de aquí se pueden descartar algunos síntomas como la diarrea o la polaquiuria, ya que son síntomas que no producen señales biomédicas. Tomando en cuenta estos criterios y en base a los síntomas presentados en el libro de “Sinopsis de la psiquiatría” [8] en conjunto con el método de diagnóstico presentado en el “Manual Diagnóstico y Estadístico de los Trastornos Mentales” [12], fueron elegidos los siguientes síntomas para detectar un evento de ansiedad:

1. Hiperhidrosis
2. Taquicardia y palpitaciones

Una vez seleccionados los síntomas a resaltar de los pacientes con trastorno de ansiedad, se procede con la investigación e identificación de las señales que se ven alteradas en presencia de dichos síntomas.

Capítulo 2

El electrocardiograma y la respuesta galvánica de la piel

2.1. Electrocardiograma

El electrocardiograma (ECG) es un registro utilizado para analizar la función del corazón. Este estudio médico se inscribe sobre una tira de papel y constituye a un registro permanente de la actividad cardíaca del paciente. La información registrada por el ECG representa los impulsos eléctricos del corazón que corresponden a las distintas etapas de su estimulación. Cuando el músculo cardíaco se estimula eléctricamente, el corazón se contrae, esto ocurre debido a que las células cardíacas en reposo se encuentran cargadas o polarizadas, pero la estimulación eléctrica las despolariza y provocan la contracción del corazón. El interior de la célula miocárdica se encuentra cargado negativamente, pero se vuelve positivo cuando la célula recibe el estímulo eléctrico de contracción. A este procedimiento de estimulación eléctrica de las células musculares especializadas para su contracción se le conoce como "despolarización", y puede considerarse como una onda progresiva de cargas positivas dentro de las células. Este estímulo eléctrico de despolarización produce la contracción progresiva de las células del miocardio a medida que la onda de cargas positivas penetra a las células [13].

Los eventos de despolarización (carga positiva en el interior de las células) y de repolarización (las células regresan a su carga negativa) pueden visualizarse en el ECG por las ondas mostradas en la Figura 2.1.




Figura 2.1: Ondas de polarización y despolarización en el ECG.

Cuando esta actividad eléctrica recorre el corazón, se pueden utilizar electrodos externos colocados sobre la piel que registran la actividad eléctrica y dar lugar al ECG. Entonces, cuando la onda positiva de despolarización de las células cardíacas se acerca a uno de los electrodos positivos colocados sobre la piel, el ECG registrará una deflexión positiva que va hacia arriba.

Las ondas que se pueden encontrar en un ECG producidas por la actividad eléctrica del corazón se muestran en la Figura 2.2, y estas son [13]:

- Onda P: la onda P representa la actividad eléctrica de la contracción de ambas aurículas.
- Complejo QRS: el complejo QRS es la representación de la actividad eléctrica de la estimulación de los ventrículos que provocan su contracción. Este segmento comienza por la onda Q, que es una deflexión hacia abajo, seguida de la onda R que va hacia arriba y finalmente la onda S, con una deflexión hacia abajo.
- Onda T: existe una pausa después del complejo QRS que da lugar a la onda T, a esta pausa se le conoce como segmento ST. La onda T representa la repolarización de los ventrículos para que se les vuelva a estimular.

Entonces un ciclo cardíaco completo está compuesto por la onda P, el complejo QRS y la onda T. La aurícula tiene también una onda de repolarización pero esta es enmascarada por el complejo QRS y no se distingue en la señal ECG. Además de las ondas en una señal ECG, existen otros parámetros que ayudan a la detección de anomalías en la señal, tal es el caso de los intervalos y segmentos electrocardiográficos. Un segmento electrocardiográfico es una línea que une una onda del ECG con otra, sin incluir ningún

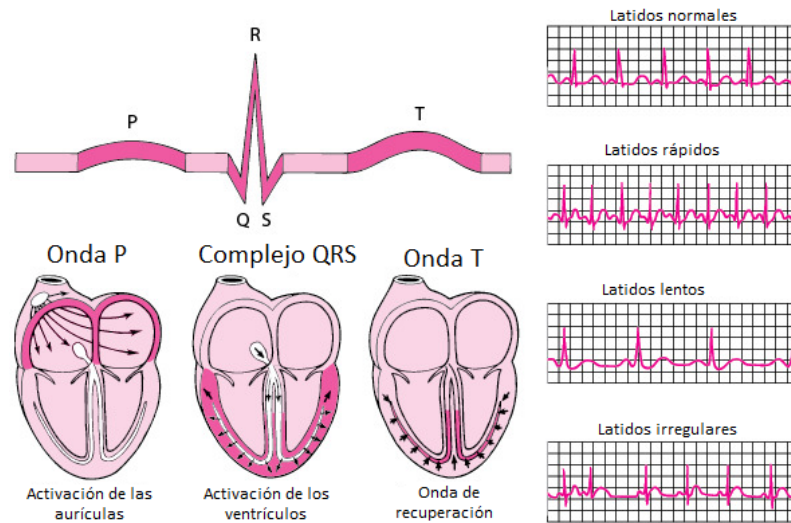


Figura 2.2: Ondas que componen al ECG y algunos posibles comportamientos [14].

tipo de onda dentro de ella [15]. Un intervalo electrocardiográfico es una porción del ECG que incluye dentro de ella a una o más ondas, además de un segmento, este intervalo puede ir desde el inicio de una onda hasta el inicio de otra [15]. Algunos de los intervalos y segmentos característicos del ECG son [15]:

- Intervalo R-R: es la distancia que hay entre 2 ondas R de los complejos QRS. En el ritmo sinusal (normal), esta distancia debe permanecer constante. Se mide desde el inicio de una onda R hasta el inicio de la siguiente.
- Intervalo P-R: este intervalo se mide desde el inicio de una onda P hasta el inicio del complejo QRS (inicio de Q). En ritmo sinusal, su valor normal es de 0.12 a 0.20 segundos. Este intervalo representa el tiempo transcurrido al generarse la señal de despolarización auricular y el retraso fisiológico que sufre al pasar por el nodo AV (nodo auriculoventricular).
- Intervalo QRS: este intervalo se mide desde el comienzo de la onda Q o la onda R, y termina al final de la onda S, de no presentarse la onda S en el ECG, se mide del inicio de Q al final de R. Este intervalo representa el tiempo total de la despolarización ventricular.
- Intervalo Q-T: la duración de tiempo de este intervalo varía en función de la frecuencia cardíaca, por lo que generalmente se ajusta su valor a la frecuencia cardíaca. Este intervalo representa el tiempo de despolarización y polarización de los ventrículos.

- Segmento S-T: este segmento se mide desde el final del complejo QRS hasta el inicio de la onda T y representa el inicio de la repolarización ventricular.

2.1.1. Frecuencia cardíaca

La frecuencia cardíaca es el número de veces que el corazón se contrae en un periodo de tiempo determinado, generalmente se mide en ciclos por minuto, donde un ciclo corresponde a una contracción o latido. Normalmente, la frecuencia de los latidos cardíacos depende del nodo SA (nodo seno-auricular), ubicado en la pared posterior de la aurícula derecha y este cumple con el papel del marcapaso natural del corazón. Su valor de frecuencia normal se encuentra entre 60 y 100 latidos por minuto y se conoce como ritmo sinusal normal. Haciendo referencia a las señales ECG, la onda R corresponde a la señal de mayor amplitud positiva y puede ser utilizada para medir un ciclo cardíaco iniciando desde una onda R y terminando en la siguiente, de esta manera se puede realizar la medición de tiempo entre cada una de las ondas R y obtener la estimación de la frecuencia cardíaca medida en ciclos por minuto [13].

Otro método para calcular la frecuencia cardíaca es contar el número de ondas R que se muestran en un minuto del ECG, esto solo se puede realizar si se tiene la señal ECG con duración de tiempo suficiente para completar un minuto completo. Este método puede realizarse mediante la implementación de software que sea capaz de detectar las ondas R (que pueden ser identificados como picos de la señal ECG con mayor amplitud positiva comparada con el resto de la señal) y contarlas en un intervalo de un minuto para obtener la frecuencia cardíaca.

2.1.2. Alteraciones en la frecuencia cardíaca

El nodo SA es el marca pasos natural del corazón, pero este puede presentar problemas en los que se ve alterada la frecuencia normal del corazón y llega a valores muy elevados o muy reducidos. A este trastorno de la frecuencia cardíaca se le divide en 2 categorías principales: taquicardia sinusal o bradicardia sinusal [13]. En la Figura 2.3, se muestra un ECG con frecuencia sinusal (normal).

Una frecuencia rápida, con un ritmo normal, que tiene un valor mayor a 100 ciclos por minuto constituye a una taquicardia sinusal. Cuando se habla de un ritmo normal, se hace referencia a un ritmo regular iniciado de forma normal en el nodo SA; entonces cada ciclo sucesivo dura el mismo tiempo, lo que da como resultado una frecuencia continua estable. Entonces se habla de taquicardia sinusal siempre y cuando esta se genere en el

nodo SA [13]. En la Figura 2.4 se muestra un ECG que con taquicardia sinusal, ya que tiene una frecuencia cardíaca de 136 latidos por minuto.

En la bradicardia sinusal ocurre el caso contrario, esta se refiere a un ritmo muy lento originado por el nodo SA inferior a 60 ciclos por minuto, cuando el ritmo es normal. En el caso del ECG, este fenómeno se visualiza como una prolongación en la separación de los ciclos, pero las ondas P, QRS y T siguen cerca unas de otras [13]. En la Figura 2.5 se muestra un ECG con bradicardia sinusal, ya que tiene una frecuencia de 48 latidos por minuto.



Figura 2.3: ECG normal con frecuencia de 75 latidos por minuto [16].




Figura 2.4: ECG con taquicardia sinusal de 136 latidos por minuto [17].




Figura 2.5: ECG con bradicardia sinusal de 48 latidos por minuto [17].

2.2. Respuesta galvánica de la piel

La piel es un órgano importante para la supervivencia del ser humano. Es el tejido externo que cubre al cuerpo y permite la comunicación y percepción con el mundo externo. Es el órgano con mayor extensión, ya que tiene una superficie de aproximadamente $1.6m^2$ y un peso de 4 kg, que corresponde al 6 % del peso total del cuerpo. Funciona para proteger a los órganos internos, pero también trabaja como protección de agentes externos como los rayos UV, ya que estos pueden traer consigo enfermedades. Ayuda también para la restricción de la entrada de sustancias perjudiciales y a la termorregulación [18].

La respuesta galvánica de la piel (GSR, por sus siglas en inglés), también conocida como actividad electrodérmica es un estudio y registro de la actividad eléctrica de la piel. Los cambios en la respuesta galvánica de la piel dependen de la secreción de las glándulas sudoríparas, específicamente con las glándulas ecrinas y otros elementos que conforman a la piel los cuales originan cambios en las propiedades electroquímicas por variaciones en la permeabilidad de las membranas celulares [19]. La respuesta galvánica de la piel constituye a uno de los índices psicofisiológicos más importantes por su relación con las emociones y la atención. Su variación representa una evidencia de los cambios en el estado cognitivo y/o emocional del sujeto que otorga información valiosa del sistema nervioso autónomo [19].

2.2.1. Parámetros en la respuesta galvánica de la piel

Existen diversos parámetros que permiten interpretar los resultados obtenidos a partir del estudio de la respuesta galvánica de la piel, los cuales se presentan a continuación [19]:

1. Frecuencia: la frecuencia de la respuesta galvánica de la piel se expresa en relación con un intervalo de tiempo constante, comúnmente 1 minuto para registros individuales.
 2. Amplitud: la amplitud sirve para medir la diferencia entre el nivel de origen hasta el punto en donde la respuesta galvánica de la piel llega a su mayor altura. Sus unidades dependen del procedimiento de registro, ya sea resistencia o potencial.
 3. Características temporales: esta se describe a partir de 4 parámetros:
 - La latencia de aparición: es el tiempo que transcurre entre el inicio de la estimulación y el inicio de la respuesta.
-

- La duración total de la respuesta: se obtiene calculando el tiempo transcurrido entre el momento de inicio de la respuesta hasta el momento donde se recupera el valor base.
- El tiempo de subida de la respuesta: es el intervalo de tiempo entre el inicio de la señal y el punto donde se registra la mayor amplitud de la misma.
- El tiempo de recuperación de la respuesta: es el registro de tiempo en que la señal recupera su valor base, comenzando desde el punto de mayor amplitud, hasta llegar a la mitad del tiempo de recuperación (mitad de tiempo entre la amplitud más alta y la recuperación del valor base).

2.2.2. La hiperhidrosis

El concepto de hiperhidrosis se refiere a la excesiva sudoración que produce el organismo en respuesta al calor o a estímulos emocionales. Cuando un sujeto sufre de hiperhidrosis la sudoración es apreciable incluso cuando este se encuentra en reposo y en un cuarto con buena refrigeración, lo que puede conducir a grandes disfunciones psicológicas, sociales y profesionales. La hiperhidrosis está relacionada con una respuesta a una sobreestimulación de las glándulas ecrinas a través de un recorrido neurológico anormal, consecuencia de diversos estímulos desproporcionados que elevan el nivel de la secreción de sudor, como lo puede ser el estrés emocional. Es posible detectar esta manifestación haciendo uso de las señales GSR [20]. La hiperhidrosis es uno de los síntomas característicos de los trastornos de ansiedad [12], por lo que midiendo los cambios en la sudoración del sujeto podrá detectarse la presencia de un evento de ansiedad en conjunto con otras variables fisiológicas, como puede ser la frecuencia cardíaca.

Capítulo 3

Procesamiento y caracterización de las señales fisiológicas

3.1. La base de datos

Para el análisis y caracterización de las señales fisiológicas de un paciente que está sufriendo un evento de ansiedad se hizo uso de la información proporcionada por la base de datos generada durante el experimento realizado por Shäfter et al. en [21]. Se llegó a esta base de datos gracias al portal Physionet [22]. Para la selección de la base de datos se toman en cuenta las manifestaciones identificadas para la detección de un evento de ansiedad, conformadas por la taquicardia y la hiperhidrosis. La detección de la taquicardia es registrada por las señales ECG, mientras que la hiperhidrosis puede ser identificada por medio de la GSR. Entonces la base de datos a escoger debía de ofrecer un banco de señales ECG y GSR de pacientes diagnosticados con algún tipo de trastorno de ansiedad, recordando que todos los trastornos de ansiedad están relacionados entre sí. Teniendo esto en cuenta se seleccionó la base de datos del experimento mencionado, ya que proporciona el registro de señales ECG y GSR de pacientes con el trastorno de ansiedad de fobia específica a las arañas. A lo largo de esta sección, se describen los elementos importantes de la base de datos seleccionada para este trabajo de tesis.

3.1.1. Descripción del experimento

La fobia específica es el trastorno más común de la familia de trastornos de ansiedad, y una metodología que ha mostrado buenos resultados en el tratamiento de este trastorno es la terapia de exposición, aún así, no todos los pacientes responden igual a este tipo de tratamientos, es por esto que recientes investigaciones han enfocado sus esfuerzos

en agregar técnicas y mejoras para consolidar y aumentar la efectividad de la terapia de exposición. Un agregado importante a este tratamiento es la biorretroalimentación para aumentar la VFC. Un estudio reciente ha mostrado alta efectividad de la biorretroalimentación del VFC para combatir el estrés y la ansiedad. Entonces, el objetivo de esta investigación fue evaluar los efectos de la biorretroalimentación de la VFC, que se practicará antes y durante una sesión de exposición en personas con fobia específica hacia las arañas [21].

En este estudio participaron 80 sujetos con fobia a las arañas y todos recibieron una sesión de entrenamiento donde practicaron por 6 días en casa la biorretroalimentación de la VFC y una variante de esta técnica llamada pseudo-biorretroalimentación motriz. Una semana después, durante la terapia de exposición, los participantes visualizarán 16 videos de arañas con duración de 1 minuto. Los participantes del estudio se dividieron en 4 grupos distintos [21]:

- Grupo 1: recibieron entrenamiento de biorretroalimentación de la VFC y pseudo-biorretroalimentación motriz. Aplicaron la biorretroalimentación de la VFC durante la terapia de exposición.
- Grupo 2: recibieron el mismo entrenamiento que el grupo 1, pero aplicaron la pseudo-biorretroalimentación motriz durante la sesión de exposición.
- Grupo 3: entrenan 2 tipos de pseudo-biorretroalimentación motriz y aplican uno de ellos durante la terapia de exposición.
- Grupo 4: reciben el mismo entrenamiento del grupo 3 pero no aplican ninguna técnica de biorretroalimentación durante la terapia de exposición.

Se realizó la medición de la cantidad de miedo experimentado por el paciente por medio de cuestionarios que analizan variables psicométricas que cuantifican este sentimiento.

3.1.2. Criterios de exclusión y requisitos

Los participantes son hombres y mujeres diagnosticados con fobia a las arañas con edades entre 18 y 40 años. Para determinar y asegurar que el participante tiene un trastorno de fobia específica a las arañas deben de obtener un puntaje de 14 en el “*German Spider Anxiety Screening*” (SAS). Además, deben de obtener un puntaje mayor o igual a 50 puntos en el “*Fear of Spiders Questionnaire*” (FSQ, versión Alemana).

Adicionalmente, los sujetos con fobia a las arañas deberán alcanzar un puntaje mínimo de 4 en miedo y un puntaje mínimo de 3 en rechazo en la sección “*Specific Phobias*” en la entrevista estructurada para trastornos mentales (ADIS, por sus siglas en inglés, versión Alemana) [21].

Los criterios de exclusión para el estudio son [21]:

- Presencia de algún otro trastorno mental diferente a fobia específica a las arañas juzgado con el “*Patient Health Questionnaire D*” (PHQ-D) y el “*Beck Depression Inventory*” (BDI-II; versión Alemana).
- Padecimiento de algún problema cardiovascular.

El reclutamiento de los participantes se llevó a cabo en la Universidad del Sarre, por medio de redes sociales y prensa local, y fueron contactados individualmente por el equipo de investigación para que firmen una carta de consentimiento informado [21].

3.1.3. Tamaño de la muestra

El tamaño de la muestra fue calculado con el software G*Power 3.1 utilizando un análisis de poder estadístico de tipo “A priori”. Un análisis de poder estadístico permite determinar el mínimo número de sujetos necesarios para la muestra con los que se podrá detectar el efecto que tiene una prueba con el nivel deseado de significancia. Los parámetros seleccionados para el estudio fueron $\alpha = 0.5$ y $1 - \beta = 0.85$, donde α es la probabilidad de error y $1 - \beta$ es la potencia. Estos parámetros fueron elegidos basándose en el estudio realizado por Goessl et al. en [23]. Este estudio resultó en un tamaño de muestra de 80 participantes, donde cada 20 participantes formarán parte de uno de los cuatro grupos definidos [21].

3.1.4. Mediciones realizadas

En la investigación se realizaron 2 tipos de mediciones: psicológicas y fisiológicas. Para las mediciones psicológicas se utilizaron los cuestionarios previamente mencionados y pruebas de aproximación a las arañas. Para propósitos del actual trabajo de tesis, solo se tomaron en cuenta los datos fisiológicos adquiridos durante la terapia de exposición. Las señales fisiológicas fueron registradas utilizando el *Biofeedback System* (BFS) desarrollado por el Instituto Fraunhofer de Ingeniería Biomédica. Este sistema es compatible con sensores vestibles y comunicación inalámbrica para asegurar la comodidad del sujeto estudiado [21].

Las señales GSR, ECG y frecuencia de respiración (RSP) fueron adquiridas utilizando el dispositivo BITalino (desarrollado por la empresa PLUX [24]), con una frecuencia de muestreo de 100 Hz en cada canal, lo que es suficiente para obtener una buena respuesta en las señales ECG. Para la disposición de los electrodos del ECG se seleccionó la configuración para la obtención de la derivación 2 del miembro, donde el electrodo positivo está ubicado en la pierna izquierda y el electrodo negativo en el brazo derecho (y la toma de tierra sobre la pierna derecha) [13]. Para la medición de la GSR se colocan 2 electrodos sobre la palma de la mano no dominante del sujeto. Para el registro de la RSP se utilizó un sensor de BITalino en forma de correa que se coloca alrededor del pecho del sujeto. La biorretroalimentación de la VFC se registró utilizando la banda de brazo Rhythm+ (creado por la empresa Scosche Industries [25]) con frecuencia de 1 Hz. La información de estos sensores fue transmitida de forma inalámbrica hacia una computadora personal utilizando un teléfono celular con las interfaces BLE (Bluetooth Low Energy) y WLAN (Wireless Local Area Network). El software para la adquisición y visualización de los datos fue desarrollado en C# en forma de una aplicación para el sistema operativo Windows. Esta aplicación graficaba en tiempo real y generaba un archivo de texto con la información de amplitud y tiempos de disparo de las señales fisiológicas adquiridas [21].

3.1.5. Sesión de exposición

Antes de comenzar la sesión de exposición, los participantes fueron previamente informados acerca del procedimiento completo. La metodología seguida para la sesión de exposición está basada en los principios establecidos en el tratamiento de una sesión de exposición desarrollado por Öst en [26]. Al inicio de la exposición a cada clip se realizó una pregunta acerca del contenido del video a visualizar con el objetivo de conseguir completo enfoque cognitivo por parte del sujeto sobre el video próximo a visualizar (Por ejemplo, ¿Cuántas arañas aparecen en el siguiente video?). Los videos seleccionados para la sesión de exposición fueron extraídos de documentales de televisión y muestran imágenes detalladas de arañas. Fueron 16 videos con duración de 1 minuto. Al final de cada clip se recuerda la pregunta y se pide que elijan la respuesta correcta entre 4 opciones, si contestan correctamente son felicitados y prosiguen con los videos, de lo contrario se les solicita que pongan más atención a los videos con el objetivo de reducir el miedo y aumentar la concentración. Después de 8 de los 16 videos, las preguntas pasan de ser retos cognitivos a preguntas emocionalmente positivas para cambiar la actitud del sujeto hacia las arañas [21].

3.2. Procesamiento de la base de datos

Una vez identificados todos los aspectos importantes de la base de datos para validar su utilidad en el trabajo actual, se prosigue con el procesamiento de las señales fisiológicas, dividido en las siguientes etapas:

- Extracción
- Segmentación
- Procesamiento

Toda la información de la base de datos fue procesada utilizando el software MATLAB [27].

3.2.1. Extracción

Como se mencionó en secciones anteriores, las señales fisiológicas fueron adquiridas por una aplicación de Windows creada en C#, en la cual se registraban los valores de inicio y fin de cada estudio y la amplitud de las señales para cada instante de tiempo registrado. Toda la información fue almacenada en archivos de texto, por lo que en el programa se requiere una sección en la que la información sea extraída de estos archivos de texto y transformada en vectores para facilitar su manipulación en el programa.

La información de la tabla de datos estaba dividida en 3 columnas, donde la primera corresponde a valores de amplitud, la segunda al tiempo y la tercera solo contiene la etiqueta “RAW” para indicar que la información estaba siendo obtenida sin ningún tipo de procesamiento previo. Para el caso de la amplitud en las señales ECG, el rango de valores va desde -1.5 mV a 1.5 mV (milivolts) y el tiempo transcurre en milisegundos. En el caso de la amplitud en las señales GSR, el rango de valores va desde -12.6 μ S a 41 μ S (microsiemens) y el tiempo transcurre en milisegundos.

Esta sección comienza por el llamado del archivo con la información de amplitud y tiempo que tiene la extensión .txt, por la disposición de la información en columnas, MATLAB reconoce que hay 3 vectores de información, por lo que se almacenan en un vector los valores de amplitud ubicados en la primera columna de la tabla y en un segundo vector los valores de tiempo ubicados en la segunda columna de la tabla.

Una vez almacenados los datos de amplitud y tiempo, se hace uso de los tiempos de disparo que indican el inicio y fin de cada clip que permiten dividir la información en los minutos correspondientes a cada clip. Esta información está almacenada en una tabla

con 3 columnas, la primera de ella contiene el título de la señal de disparo (por ejemplo clip 1, clip 2, etc.), la segunda de ellas el tiempo de inicio y la tercera el tiempo final. La extensión del documento que contiene esta información es nuevamente de tipo .txt, y se manda a llamar en el programa de la misma manera que la información de amplitud y tiempo. A diferencia del caso anterior, donde solo se asignaba el valor de cada columna a un vector correspondiente, aquí se tienen valores de tipo texto (el título ubicado en la primera columna), entonces se debe incluir en el algoritmo una sección que lea el título de cada fila y almacene sus valores de inicio y fin correspondientes. De esta manera se tienen los valores de tiempo de inicio y fin de cada clip, con una duración de 1 minuto cada uno. Este procedimiento es el mismo tanto para el programa de las señales ECG como el de las señales GSR.

3.2.2. Segmentación

Se cuenta con 16 videos de 1 minuto, el inicio y fin de cada minuto correspondiente a la duración de cada video está registrada en el documento de tiempos de disparo, entonces, con ayuda de los tiempos de disparo es posible recuperar las señales fisiológicas generadas durante la visualización de cada video. La división de la información en periodos de 1 minuto permitirá identificar los cambios en las señales fisiológicas del paciente a medida que transcurren los videos; además, en el caso de las señales ECG, facilitará el cálculo de la frecuencia cardíaca en ciclos por minuto (o latidos por minuto) del paciente con solo contar las ondas R contenidas en el periodo de tiempo analizado.

En la etapa anterior se adjuntó la información de amplitud, tiempo transcurrido y los tiempos de disparo de la señal ECG completa, ahora se necesita hacer la división de la información en periodos correspondientes al tiempo en que se visualizó cada video. Para esto, se inicia un ciclo de lectura cuyo número de repeticiones será igual al número de datos contenidos en los vectores de amplitud y tiempo (son iguales), el cual leerá cada dato de amplitud y tiempo contenido en la señal ECG completa. En el momento en que la señal esté transcurriendo un instante de tiempo dentro del rango de los tiempos de disparo de alguno de los videos, la información de amplitud y tiempo contenida en ese periodo se almacenará en una variable de tipo vector que contenga el número de video al cual corresponde dicha información. Se obtienen 2 vectores, uno con valores de amplitud y otro con valores de tiempo. Esto ocurre para cada uno de los 16 videos visualizados por el sujeto, de esta manera se obtienen 16 vectores de amplitud y 16 vectores de tiempo. Este procedimiento se repite tanto en las señales ECG, como en las señales GSR ya que los tiempos de disparo de estas son los mismos.

3.2.3. Procesamiento

En algunos casos es necesario aplicar un tratamiento a las señales registradas con el objetivo de obtener información adicional de estas. La etapa de procesamiento fue enfocada a la modificación de las señales para obtener información específica de cada una de ellas y poder llevar a cabo la caracterización cuantitativa de los eventos de ansiedad.

Es importante destacar que el procesamiento de las señales ECG y GSR se realiza por separado, dado que los parámetros de caracterización son independientes entre sí.

Procesamiento de las señales ECG

Una de las manifestaciones que describen a los pacientes con ansiedad es la taquicardia, que se caracteriza por un aumento de la frecuencia cardíaca mayor a 100 latidos por minuto, entonces el objetivo de la etapa de procesamiento de las señales ECG será la modificación de la señal para facilitar el conteo de sus ondas R, lo que permitirá calcular la frecuencia cardíaca en cada video y detectar si el sujeto está sufriendo taquicardia. La extracción de la señal ECG sin ningún tipo de procesamiento se muestra en la Figura 3.1.

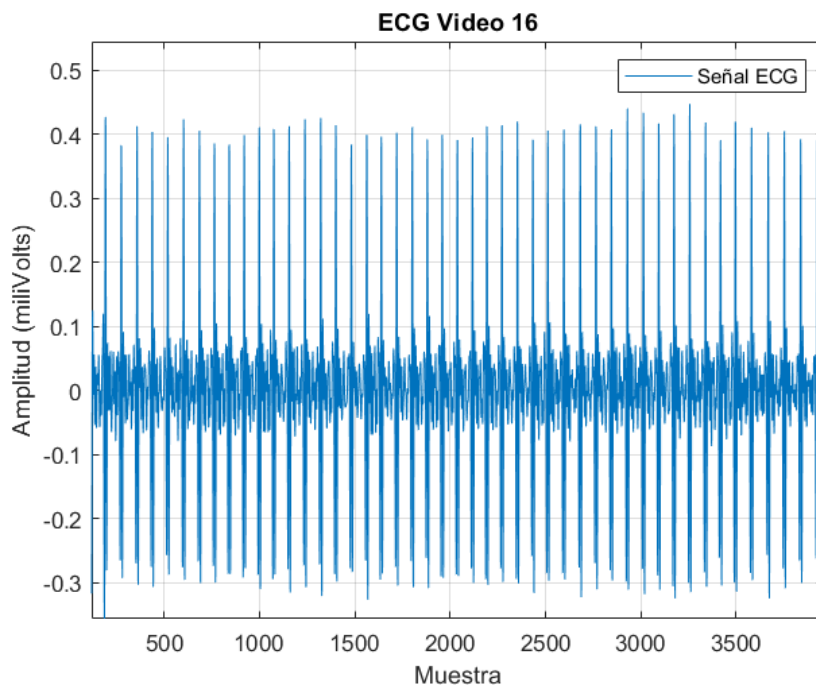


Figura 3.1: Señal ECG del sujeto 12, video 16 sin procesamiento.

Al igual que en la etapa de segmentación, el procesamiento de las señales ECG comienza con un ciclo de lectura cuyo número de repeticiones será igual al número de datos contenidos en los vectores de amplitud y tiempo. En este caso no se almacenarán directamente los datos, ahora se eliminan todos los picos con valores de amplitud negativa. Esto se logra de la siguiente manera:

$$V_{ECG} < 0 \rightarrow V_{ECG} = 0 \quad (3.1)$$

donde V_{ECG} es el valor de la señal ECG leído durante el ciclo. De esta manera son eliminados los picos negativos que pueden provocar errores a la hora de contar las ondas R contenidas en la señal ECG. El siguiente paso consiste en encontrar el valor de amplitud más alto de la señal, nuevamente haciendo uso de un ciclo de lectura y tomando en cuenta la siguiente condición:

$$V_{ECGMayor} < V_{ECGActual} \rightarrow V_{ECGMayor} = V_{ECGActual} \quad (3.2)$$

Con la condición establecida en 3.2 el ciclo comparará los valores de $V_{ECGMayor}$ con $V_{ECGActual}$, y de ser mayor $V_{ECGActual}$, entonces $V_{ECGMayor} = V_{ECGActual}$, y de esta manera se alternará el valor de $V_{ECGMayor}$ hasta terminar el ciclo y encontrar el punto con mayor amplitud en la señal ECG.

Hasta este punto se han resaltado 2 características de las señales ECG: se obtuvo la señal solamente con amplitudes positivas y se encontró la amplitud máxima de las 16 señales ECG. Estas acciones se llevaron a cabo con el fin de contar los picos en cada señal ECG correspondientes a las ondas R. Como se mencionó anteriormente, la señal ECG está compuesta por las ondas P, QRS y T, pero la onda con mayor amplitud es la onda R. Además, para medir la frecuencia del ritmo cardíaco se puede realizar la cuenta de las ondas R contenidas en un minuto y esto será equivalente a la frecuencia cardíaca. Utilizando la información obtenida hasta el momento, es posible comenzar el conteo de ondas R iniciando con la detección de los picos de la señal ECG denotado por $V_{ECGPico}$, comprendidos por todos aquellos puntos que cumplen la siguiente condición:

$$\begin{aligned} V_{ECGPico} &> V_{ECGAnterior} \\ V_{ECGPico} &> V_{ECGSiguiente} \end{aligned} \quad (3.3)$$

donde $V_{ECGAnterior}$ es el valor del punto anterior a $V_{ECGPico}$ y $V_{ECGSiguiente}$ es el valor del punto siguiente a $V_{ECGPico}$. De esta manera se determinan todos aquellos puntos en la señal ECG que son considerados picos. Una vez hecho esto, se procede con la detección de aquellos picos que corresponden a ondas R de la señal ECG. Una

característica a considerar de la onda R para poder llevar a cabo su detección es que son las ondas de mayor amplitud en las señales ECG. Haciendo uso de esta propiedad se descartan todas aquellas ondas con amplitud reducida. Una condición establecida de manera experimental para poder detectar las ondas R de la señal fue la siguiente:

$$V_{ECGPico} \geq V_{ECGMayor}/2 \rightarrow V_{ECGPico} = OndaR \quad (3.4)$$

Entonces todas aquellas señales que cumplan la condición establecida en 3.4 son consideradas ondas R de la señal ECG. Todos estos valores de amplitud se almacenarán en un vector y posteriormente se calcula su tamaño para determinar cuantas ondas R fueron detectadas y obtener la frecuencia cardíaca durante cada video visualizado. En la Figura 3.2 se muestra la señal de la Figura 3.1 después de convertir las amplitudes negativas en 0, además se muestran los picos de la señal detectados resaltados por un círculo color rojo.

Procesamiento de las señales GSR

Las señales GSR contenidas en la base de datos requirieron un tratamiento más complejo, ya que presentan una cantidad elevada ruido por sí mismas. Es necesario im-




Figura 3.2: Detección de los valores pico de la señal ECG del paciente 12, video 16.

plementar una etapa de filtrado que permita recuperar la señal suave y poder caracterizarla correctamente.

En la Figura 3.3 se muestra una señal GSR sin ningún tipo de procesamiento, en esta se puede observar que la forma de la señal no es suave, presenta cambios abruptos de amplitud. Este fenómeno puede ser causado por la baja resolución del sensor o por una frecuencia de muestreo elevada. Con este tipo de señales es complicado asegurar la fidelidad de la caracterización, ya que en las secciones donde hay cambios de amplitud se forman una especie de pulsos que pueden confundirse como picos de la señal. En la Figura 3.4 se muestra un acercamiento a la señal GSR sin procesamiento mostrada en la Figura 3.3, en esta se puede apreciar mejor la componente de alta frecuencia de oscilación que esta ocurriendo en las secciones donde varía la amplitud, y toma una forma que se asemeja a la de un tren de pulsos.

Para corregir este problema se hace uso de 2 filtros Butterworth de segundo orden, donde el primero de ellos es un filtro pasa-bajas con frecuencia de corte a 1.5Hz, mientras que el segundo será un filtro pasa-altas con frecuencia de corte a 0.05Hz, recordando que la frecuencia de muestreo de las señales se fijó en 100Hz. Aplicando los filtros correspondientes a la señal mostrada en las Figuras 3.3 y 3.4 se obtiene la señal mostrada en la Figura 3.5.




Figura 3.3: Señal GSR sin procesamiento.

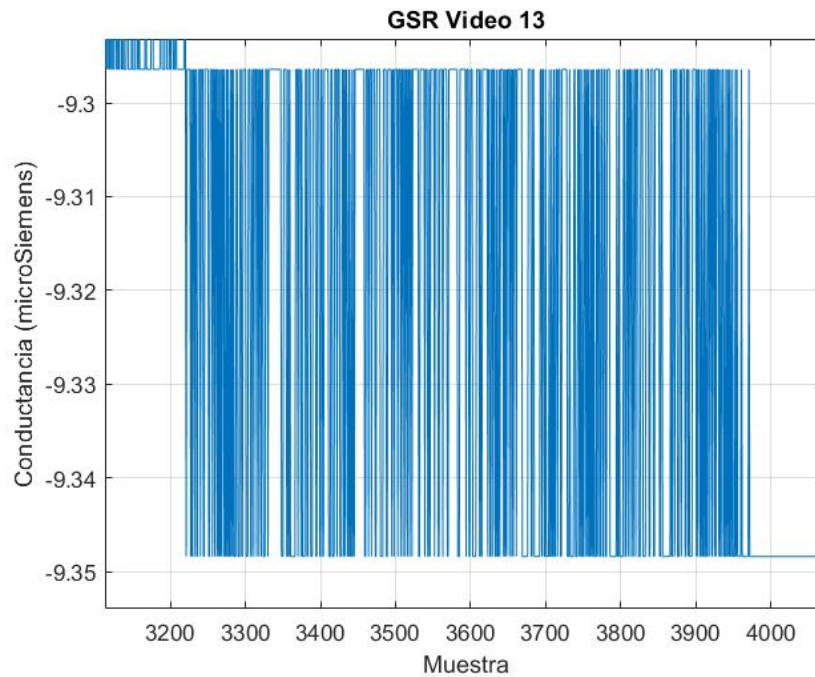


Figura 3.4: Acercamiento a la señal GSR sin procesamiento.

En la Figura 3.5 se aprecia una mejora considerable en la forma de la señal con la aplicación de los 2 filtros. Los parámetros de diseño de los filtros aplicados fueron propuestos por Ihming et al. en [4].

3.3. Caracterización de las señales fisiológicas obtenidas

La etapa de caracterización consiste en extraer toda aquella información relevante que permita describir el comportamiento de las señales estudiadas. Se comienza por un análisis de probabilidad y estadística que ayude a entender el comportamiento de las señales ECG y GSR durante un evento de ansiedad. El análisis en el dominio de la frecuencia ha sido descartado en distintas investigaciones [4], debido al tiempo de duración de las muestras ECG. De acuerdo al *“European Heart Journal”*, para obtener un análisis preciso de señales ECG es necesario una duración mínima de 2 a 5 minutos [28]. Las señales consideradas en el presente trabajo de tesis tienen una duración de 1 minuto (correspondiente a la duración de cada video), pero aún así se proseguirá con la caracterización en el dominio de la frecuencia para definir atributos que permitan realizar la detección de ansiedad en capítulos posteriores.




Figura 3.5: Señal GSR con procesamiento.

La información fue extraída, segmentada y procesada utilizando MATLAB. Una vez completada la etapa de procesamiento de la base de datos se procedió a exportar la información a una hoja de cálculo de Excel 2022 para facilitar la manipulación de la información y análisis estadístico para la caracterización.

Por parte de las señales ECG, se extrajeron de MATLAB los datos de frecuencia cardíaca. La muestra está conformada por 55 sujetos de prueba, a los cuales se les presentaron 16 videos. Durante la sesión de exposición, se realizó el registro de las señales fisiológicas del sujeto, esto deja un total de 880 datos de frecuencia cardíaca.

Pasando a las mediciones de señales GSR, se exportó de MATLAB el valor promedio de la respuesta obtenida de cada sujeto durante cada clip, por lo que nuevamente se cuenta con 880 datos de señales GSR. A continuación, se muestran los datos estadísticos analizados para realizar la caracterización de las señales:

- El promedio (\bar{x}):

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N} \quad (3.5)$$

- La varianza (S_x^2):

$$S_x^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N - 1} \quad (3.6)$$

- La desviación estándar (S_x):

$$S_x = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N - 1}} \quad (3.7)$$

- Valor máximo de la señal (Max):

$$Max = \max(x) \quad (3.8)$$

- Valor mínimo de la señal (Min):

$$Min = \min(x) \quad (3.9)$$

- Moda (Mo):

$$Mo = \text{Valor de } x \text{ con mayor frecuencia} \quad (3.10)$$

- Mediana (Me):

$$Me = \text{Valor central cuando } x \text{ va de menor a mayor} \quad (3.11)$$

- Frecuencia (Frec):

$$Frec = \# \text{ de apariciones de } x_i \quad (3.12)$$

- Frecuencia relativa (FrecR):

$$FrecR = \frac{Frec(x_i)}{N} \quad (3.13)$$

- Covarianza entre 2 variables (Cov_{xy}):

$$Cov_{xy} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{N - 1} \quad (3.14)$$

- Correlación entre 2 variables (r):

$$r = \frac{Cov_{xy}}{S_x S_y} \quad (3.15)$$

donde x es la señal analizada, y corresponde a una segunda señal analizada, x_i y y_i son el valor i -ésimo de las señales analizadas, N es el número de datos del experimento. Con esta información se procede con la composición de inferencias requeridas para la caracterización de las señales.

3.3.1. Caracterización de las señales ECG

En la Figura 3.6 se muestra un histograma de las frecuencias cardíacas registradas. Como se puede observar, la distribución de los datos está sesgada a la izquierda, lo que significa que el promedio es mayor a la mediana de los datos. Un aspecto importante a resaltar de la Figura 3.6 es que el valor de frecuencia cardíaca con más apariciones es 75 latidos por minuto, que corresponde a un porcentaje del 6 % de probabilidad de obtener ese registro en los pacientes de la base de datos.

En la Tabla 3.1 se muestran los datos correspondientes a la estadística descriptiva de la frecuencia cardíaca. Para obtener estos resultados se tomaron en cuenta los datos de frecuencia cardíaca de los 55 sujetos durante los 16 videos, que resulta en 880 lecturas de frecuencia cardíaca. Iniciando con el promedio, se puede observar en la Tabla 3.1 que se obtuvo un valor de aproximadamente 83 latidos por minuto, además es posible corroborar lo observado en la Figura 3.6, ya que el promedio es mayor que la mediana de la frecuencia cardíaca, lo que genera una distribución sesgada a la izquierda. Se tiene una desviación estándar de 10.75 con una moda de 75 latidos por minuto. Anteriormente se ha mencionado que se consideró la taquicardia como una de las principales manifestaciones fisiológicas de un evento de ansiedad, y para comprobarlo se identificaron todas aquellas lecturas de frecuencia cardíaca mayores o iguales a 100 latidos por minuto. Como se puede observar en la Tabla 3.1, se registraron 72 lecturas que cumplen con las características de la taquicardia, lo que resulta en un 8 % de probabilidad de obtener lecturas con taquicardia en esta muestra. Para el caso de la bradicardia, solo se obtuvo una lectura




Figura 3.6: Histograma de frecuencias cardíacas.

Estadística descriptiva de la frecuencia cardíaca			
VARIABLES ESTADÍSTICAS	VALOR	VARIABLES ESTADÍSTICAS	VALOR
Promedio de todas las frecuencias cardíacas (lpm)	82.75795455	Frecuencia relativa de la bradicardia	0.001136364
Desviación estándar de todas las frecuencias cardíacas (lpm)	10.75698277	Porcentaje de probabilidad de bradicardia	0%
Moda de la frecuencia cardíaca (lpm)	75	Valor máximo de frecuencia cardíaca (lpm)	118
Frecuencia relativa de la moda	0.056818182	Frecuencia del valor máximo	1
Porcentaje de probabilidad de la moda	6%	Frecuencia relativa del valor máximo	0.001136364
Mediana de la frecuencia cardíaca (lpm)	81	Porcentaje de probabilidad del valor máximo	0%
ECG con taquicardia registrada	72	Valor mínimo de frecuencia cardíaca (lpm)	53
Frecuencia relativa de la taquicardia	0.081818182	Frecuencia del valor mínimo	1
Porcentaje de probabilidad de taquicardia	8%	Frecuencia relativa del valor mínimo	0.001136364
ECG con bradicardia registrada	1	Porcentaje de probabilidad del valor mínimo	0%

Tabla 3.1: Estadística descriptiva de la frecuencia cardíaca.

menor a 60 latidos por minuto, lo que resulta en prácticamente una posibilidad nula de obtener una lectura de bradicardia en esta muestra. Para la moda se tiene un valor de 72 latidos por minuto, tal y como se observó en el histograma de la Figura 3.6, que tiene una probabilidad del 6 %.

3.3.2. Caracterización de las señales GSR

La estadística descriptiva de la GSR se muestra en la Tabla 3.2. Para estos resultados se obtuvo el promedio de las amplitudes registradas durante cada video por todos los sujetos, lo que deja una cantidad de 880 datos de promedios de GSR. El promedio de amplitud de las señales GSR obtenido fue de $0.000561858\mu S$. Una particularidad de esta

información es que no se cuenta con un valor de moda, ya que no hay ningún valor de amplitud promedio que se repita más de una vez, esto indica una gran variación entre las respuestas obtenidas. Es posible realizar una medición de la dispersión de los datos haciendo uso de la desviación estándar, la cual resultó en un valor de 0.017921304, que no es lo suficientemente grande como para inferir en que no existe relación entre la respuesta obtenida por cada sujeto, ya que no representa una magnitud significativa en relación con el rango de amplitudes registradas. El valor máximo de la GSR es de $0.142452591\mu\text{S}$ y el valor mínimo de $-0.087484163\mu\text{S}$.

Los datos estadísticos mostrados en la columna derecha de la Tabla 3.2 fueron obtenidos de una manera distinta. El programa desarrollado para obtener el valor promedio de amplitud de la señal GSR también extraía los valores de máximo, mínimo y desviación estándar durante cada video, por lo que se tienen 880 datos de cada variable estadística y los datos de la columna derecha muestran el promedio de estas variables. Esto se hizo con el objetivo de buscar una relación directa entre la frecuencia cardíaca y alguna de las variables estadísticas de la GSR. Durante el experimento se observó que en la mayoría de los casos en donde los pacientes manifestaban taquicardia en su frecuencia cardíaca, el valor máximo de la GSR tenía una amplitud considerablemente mayor que la del resto de pacientes, esto indica la existencia de un factor de correlación positivo entre variables que permite establecer una relación entre los niveles de ansiedad y la amplitud máxima obtenida en la GSR. Dicha información puede utilizarse como un atributo útil para la clasificación de señales con y sin ansiedad.

Estadística descriptiva de las señales GSR			
Variables estadísticas (todos los datos)		Variables estadísticas (por sujeto)	
Promedio de la GSR (μS)	0.000561858	Promedio máximos GSR (μS)	1.079336227
Desviación estándar de la GSR (μS)	0.017921304	Promedio mínimos GSR (μS)	-0.8074768
Máximo de la GSR (μS)	0.142452591	Promedio Desviaciones estándar GSR (μS)	0.313073091
Mínimo de la GSR (μS)	-0.087484162	Moda de los promedios GSR (μS)	No existe

Tabla 3.2: Estadística descriptiva de las señales GSR.

Capítulo 4

Análisis de las señales en el dominio del tiempo

Las señales fisiológicas recolectadas para este trabajo fueron seleccionadas por su relación y capacidad para detectar los síntomas de taquicardia e hiperhidrosis. Para poder interpretar el comportamiento de estas señales es necesario establecer un conjunto de atributos cuantitativos que describan el comportamiento general y poder detectar aquellas señales que presenten un evento de ansiedad. Este capítulo está enfocado en la selección de atributos en el dominio del tiempo.

4.1. Atributos para las señales de Electrocardiograma

Las señales de ECG han sido un importante objeto de estudio para el análisis de estrés y ansiedad, se ha demostrado que estas emociones causan variaciones en la actividad cardiovascular que pueden ser medidas a través de la VFC [5].

La VFC es una medida de la actividad cardíaca que refleja la variación de tiempo entre los intervalos RR (distancia entre 2 ondas R de los complejos QRS) de una señal ECG. Diversos estudios han demostrado que la ansiedad está asociada con una reducida VFC [29], [30], por lo que los atributos seleccionados para las señales ECG se enfocan en las características de los intervalos RR.

4.1.1. Algoritmo de Pan-Tompkins

Una herramienta ampliamente utilizada para la extracción de atributos de señales ECG [4], [1], es el algoritmo de Pan-Tompkins [2]. Este es un algoritmo de detección en

tiempo real de los complejos QRS que conforman a una señal ECG utilizando información de amplitud, pendiente y ancho de los complejos. Los componentes principales del algoritmo se muestran a continuación [2]:

1. Filtrado: esta etapa comienza por aplicar un filtro pasa-bajas digital a la señal ECG con frecuencia de corte de 11 Hz. La ecuación de diferencias correspondiente al filtro pasa bajas se muestra a continuación:

$$y(nT) = 2y(nT - T) - y(nT - 2T) + x(nT) - 2x(nT - 6T) + x(nT - 12T) \quad (4.1)$$

donde $y(nT)$ es el valor de salida en el instante nT y $x(nT)$ es el valor de la señal de entrada en el instante nT . Posteriormente, se aplica un filtro pasa-altas digital con frecuencia de corte de 5 Hz cuya ecuación de diferencias se muestra a continuación:

$$y(nT) = 32x(nT - 16T) - [y(nT - T) + x(nT) - x(nT - 32T)] \quad (4.2)$$

2. Derivación: después de la etapa de filtrado de la señal, se procede con la diferenciación para obtener información acerca de la pendiente de los complejos QRS. La ecuación de diferencias correspondiente al diferenciador se muestra a continuación:

$$y(nT) = (1/8T)[-x(nT - 2T) - 2x(nT - T) + 2x(nT + T) + x(nT + 2T)] \quad (4.3)$$

3. Potencia de la señal: en esta etapa, el resultado de la diferenciación de la señal se eleva al cuadrado punto por punto, lo que resulta en una señal únicamente con amplitudes positivas. La ecuación implementada se muestra a continuación:

$$y(nT) = [x(nT)]^2 \quad (4.4)$$

4. Integración: en esta etapa se utiliza una ventana en movimiento que integra la señal por partes con el objetivo de obtener información acerca del ancho y la pendiente de la onda R del complejo QRS. La ecuación de diferencias para la integración se muestra a continuación:

$$y(nT) = (1/N)[x(nT - (N - 1)T) + x(nT - (N - 2)T) + \dots + X(nT)] \quad (4.5)$$

donde N es el número de muestras dentro de la ventana de integración.

5. Umbrales adaptativos: en esta etapa se establecen los valores de los umbrales que detectan las ondas R de la señal ECG utilizando información de la amplitud de distintos picos detectados dentro de una ventana. Si alguno de los picos sobrepasa los umbrales establecidos se define como una onda R de la señal ECG.

Para implementar esta herramienta se desarrolló un algoritmo en lenguaje de programación Python que aplica cada una de las etapas de procesamiento previamente mencionadas para obtener la ubicación de las ondas R de la señal ECG, con lo cual se puede hacer una estimación de la duración de los intervalos RR de la señal. Esto permite medir tanto frecuencia cardíaca, como variabilidad de la frecuencia cardíaca en la muestra ECG analizada, recordando que las señales recopiladas en este trabajo tienen duraciones de 1 minuto. En la Figura 4.1 se muestra el resultado de aplicar el algoritmo de Pan-Tompkins a una señal ECG. Como se puede observar, se detectan correctamente las ondas R de la señal, lo que permite calcular correctamente variables que involucren información acerca de los intervalos RR de la señal ECG.

4.1.2. Atributos seleccionados

Con la información obtenida con la aplicación del algoritmo de Pan-Tompkins se procede a seleccionar aquellos atributos que permitan identificar eventos de ansiedad

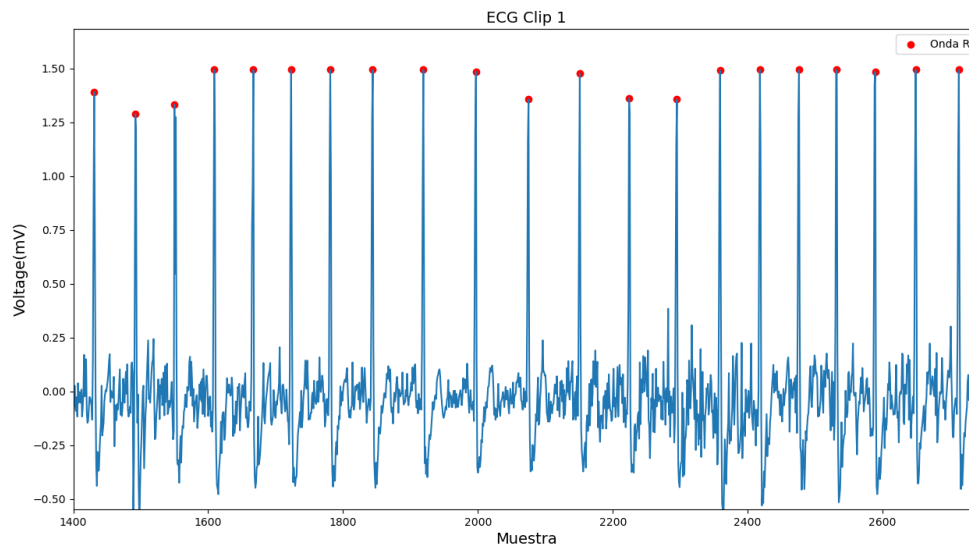


Figura 4.1: Detección de ondas R de una señal ECG implementando el algoritmo de Pan-Tompkins.

con una alta precisión. Como primer atributo se seleccionó la frecuencia cardíaca (FC), cuyo valor en función de los intervalos RR se calcula con la siguiente ecuación:

$$FC = \frac{60}{\bar{RR}} \quad (4.6)$$

donde \bar{RR} es la duración promedio de los intervalos RR contenidos en la señal ECG analizada. Existen diversas variables que describen de manera cuantitativa el comportamiento de la VFC en una señal ECG, además, existen estudios que han demostrado una relación entre algunas variables de la VFC y los eventos de ansiedad, tal es el caso de la raíz del cuadrado de las diferencias sucesivas promedio (RCDSP), que ha demostrado ser una variable de gran relevancia para detectar señales con ansiedad [5], alcanzando una precisión de hasta 85 %. La fórmula para calcular la RCDSP se muestra a continuación:

$$RCDSP = \sqrt{\frac{\sum_{n=1}^{N-1} (RR_{n+1} - RR_n)^2}{N-1}} \quad (4.7)$$

donde RR_{n+1} es el valor del intervalo RR en la posición $n+1$ y RR_n es el valor del intervalo RR en la posición actual n , la variable N representa el número de intervalos RR contenidos en la señal ECG analizada. Existen otras variables descriptivas de la VFC que han demostrado un gran impacto para la detección de ansiedad, como las mostradas en [3], donde se utilizó la desviación estándar de los intervalos RR (DERR) y el promedio de la primera diferencia de los intervalos RR (PPDRR) en conjunto con otras variables derivadas de la actividad cardíaca para alcanzar una precisión de hasta 97.29% para la detección de señales con ansiedad. Las fórmulas para calcular la DERR y la PPDRR se muestran a continuación:

$$DERR = \sqrt{\frac{\sum_{n=1}^N (RR_n - \bar{RR})^2}{N-1}} \quad (4.8)$$

$$PPDRR = \frac{\sum_{n=1}^{N-1} RR_{n+1} - RR_n}{N} \quad (4.9)$$

4.2. Atributos para las señales de respuesta galvánica de la piel

Las señales GSR han sido una herramienta importante para la detección de emociones. Su efectividad para realizar esta tarea varía de acuerdo al tipo de atributos seleccionados para el estudio, pero ha demostrado ser una herramienta eficiente para detectar distintas emociones [31], [32], [33].

Las señales GSR están compuestas de 2 componentes principales: la componente tónica, medida por los niveles de conductividad de la piel (NCP) los cuales varían lentamente con respecto al tiempo (elevaciones y declives lentos), y la componente fásica, medida por las respuestas de conductividad de la piel (RCP) la cual se manifiesta con variaciones rápidas en forma de picos contenidos sobre la componente tónica y está asociada con la activación del sistema nervioso simpático provocada por estímulos espontáneos [31]. Entonces, para estudiar los atributos relacionados a eventos estimulantes a corto plazo (por ejemplo: imágenes o música) es importante trabajar con las RCP de las señales GSR [31].

La componente tónica de la señal GSR es la que se extrae después de aplicar un filtro Butterworth pasa-bajas de segundo orden con frecuencia de corte de 1.5 Hz a la señal obtenida directamente del sensor. Para obtener la componente fásica de la señal GSR es necesario aplicar un segundo filtro, pero en este caso Butterworth pasa-altas de segundo orden con frecuencia de corte de 0.05 Hz [34], de esta manera se puede proceder al análisis de las RCP de la componente fásica. Las RCP se presentan como picos en la componente fásica de la señal GSR, pero no cualquier pico es considerado una RCP, es necesario hacer una exclusión. De acuerdo con las recomendaciones de Braithwaite et al. [34], para que un pico de la componente fásica sea considerado una RCP debe de superar un umbral de $0.05 \mu\text{S}$, además, estas respuestas cuentan con un tiempo de inicio y un tiempo final, con esta información se puede estimar el tiempo de duración de la RCP.

4.2.1. Procedimiento de extracción de atributos GSR

Para poder extraer todos los atributos necesarios de la componente fásica de la GSR se desarrolló un algoritmo en lenguaje de programación Python como el mostrado durante la investigación [35], para identificar y almacenar los elementos fundamentales de las RCP de la señal, los cuales se mencionan a continuación:

- Tiempo de inicio: se toman como tiempos de inicio de las RCP los instantes en los que la componente fásica sobrepasa el valor del umbral en forma ascendente.
 - Punto máximo: se identificará como el punto máximo de una RCP al pico de mayor amplitud contenido entre el tiempo de inicio y el tiempo final.
 - Tiempo final: se toman como tiempos finales de las RCP los instantes en los que la componente fásica pasa por el valor de umbral de forma descendente.
-

- Amplitud: la amplitud se toma como la diferencia de amplitudes entre el punto de inicio y el pico más alto encontrado antes de llegar al tiempo final de la RCP.
- Duración: la duración es la diferencia entre el tiempo final y el tiempo de inicio.
- Área bajo la curva: el área bajo la curva (ABC) de una RCP fue calculada implementando el método de integración numérica trapezoidal tomando como amplitud la señal GSR y como rango el número de muestras contenidas dentro de la RCP.

En la Figura 4.2 se presenta el resultado de obtener la componente física de una GSR con ansiedad. Aquí se señalan los elementos fundamentales de una RCP. Marcados en azul se tienen a todos aquellos tiempos de inicio y final, dentro de los cuales se busca el punto máximo que cumpla con el umbral establecido de $0,05\mu\text{S}$. Los puntos máximos encontrados en la RCP se marcan en rojo.

En la Figura 4.3 se muestra la componente física de una señal GSR cuando el paciente se encuentra sin sufrir de un evento de ansiedad. Haciendo una comparación cualitativa entre señales se puede observar que existe gran diferencia entre ellas. La primera de ellas es la amplitud de las RCP detectadas, en la señal GSR con ansiedad se pueden observar picos con mayor amplitud, mientras que los picos de la señal sin ansiedad tienen una amplitud reducida en la mayoría de sus casos. Otra diferencia evidente es la duración, en la señal con ansiedad se observa que la separación entre los tiempos de inicio y final es mayor en comparación con la señal sin ansiedad. Una característica significativa entre las señales es el área formada por las RCP detectadas, suponiendo que la distancia formada por la diferencia entre el tiempo final y el tiempo de inicio es la base y utilizando la amplitud del punto máximo como la altura, se pueden visualizar las RCP de la señal como triángulos de área determinada que puede ser calculada aplicando el método de integración numérica trapezoidal. Entonces, haciendo la comparación entre áreas de la señal GSR con ansiedad y sin ansiedad, se observan áreas mayores en la señal con ansiedad. Utilizando este algoritmo para identificar las partes fundamentales de las RCP de una señal GSR se puede proceder a establecer los atributos de interés para diferenciar entre señales con ansiedad y sin ansiedad.

4.2.2. Atributos seleccionados

Una vez identificadas las diferencias significativas entre las señales GSR con ansiedad y sin ansiedad, es necesario establecer variables numéricas que puedan expresar estas diferencias cualitativas de manera cuantitativa. La primera variable seleccionada es el número de RCP detectadas en la señal GSR, denotadas con las siglas RCPRE (RCP

relacionada a eventos), ya que son las RCP detectadas que superan los umbrales establecidos [34].

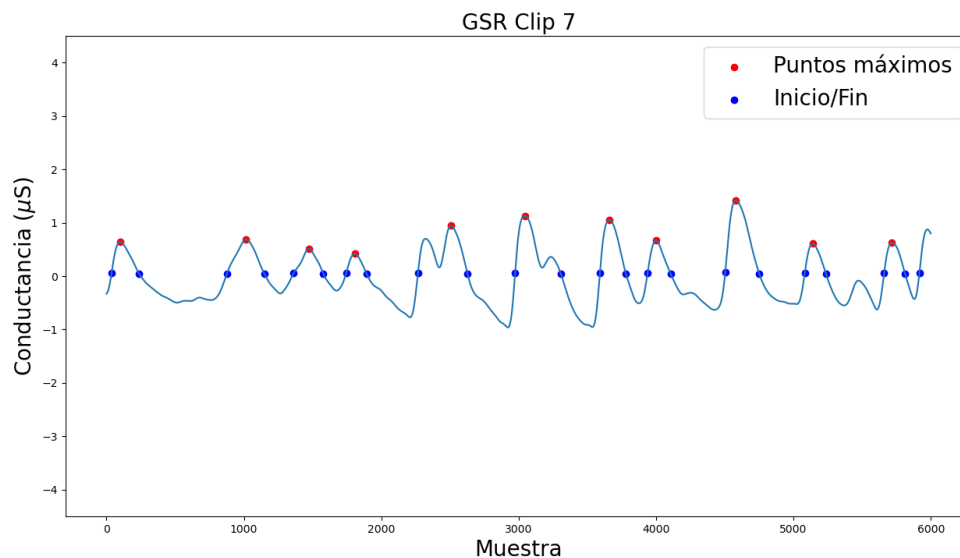


Figura 4.2: Componente fásica de una señal GSR con ansiedad.

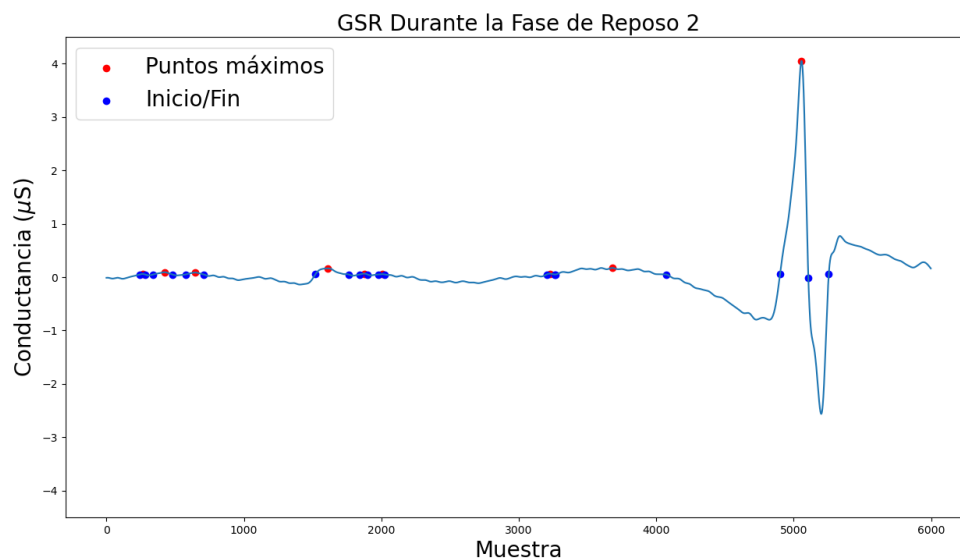


Figura 4.3: Componente fásica de una señal GSR sin ansiedad.

Otra variable seleccionada fue la amplitud promedio de las RCP (*AmpPromRCP*). Esta variable ha demostrado ser de gran utilidad para la detección de emociones utilizando las señales GSR [31], además se ha implementado para detectar la ansiedad en 2 y 3 niveles (una decisión de 2 niveles es una respuesta binaria, mientras que 3 niveles se refiere a una medida de alto, medio o bajo) con una precisión de 89.8% y 74.4% respectivamente [4]. La ecuación utilizada es la siguiente:

$$AmpPromRCP = \frac{\sum_{n=1}^N AmpRCP_n}{N_{RCP}} \quad (4.10)$$

donde $AmpRCP_n$ es la amplitud de la RCP actual y N_{RCP} es el número de RCP detectadas en la señal GSR analizada. La siguiente variable seleccionada fue la duración promedio de las RCP (*DurPromRCP*) y se calcula de la siguiente manera:

$$DurPromRCP = \frac{\sum_{n=1}^N DurRCP_n}{N_{RCP}} \quad (4.11)$$

donde $DurRCP_n$ es la duración de la RCP actual. Otra variable seleccionada fue el valor máximo de la componente fásica de la GSR (*MaxGSR*) y se tomó esta decisión por la correlación que se observó durante la etapa de caracterización con la frecuencia cardíaca, es decir, a medida que variaba el valor de frecuencia cardíaca, había una variación proporcional en el valor máximo de la componente fásica de la GSR. El siguiente atributo seleccionado es la suma de las áreas formadas por las RCP (*SumABC*), esto se realizó con el objetivo de identificar la diferencia que existe entre el área de las RCP de las señales con ansiedad y sin ansiedad. Esta variable se calcula de la siguiente manera:

$$SumABC = \sum_{n=1}^N ABC_n \quad (4.12)$$

donde ABC_n es el área bajo la curva de la RCP actual, calculada utilizando el método de integración numérica trapezoidal. El último conjunto de atributos corresponden a los parámetros de Hjorth [36], utilizados para realizar una descripción cuantitativa de las señales de Electroencefalograma (EEG). El objetivo de la aplicación de estos atributos es comprobar si otorgan información de utilidad para la caracterización de señales GSR con ansiedad. Algunos estudios han implementado estos parámetros en las señales GSR para la detección de emociones [31], pero no se expone el grado de importancia que estos parámetros tuvieron para cumplir esta tarea. Los parámetros de Hjorth se mencionan a continuación [36]:

- Actividad (Ax): esta variable expresa una medida de la varianza de la amplitud, en ocasiones relacionada con la potencia promedio en el análisis espectral. Su ecuación se presenta a continuación:

$$Ax = \sum_{n=1}^N (X(n) - \mu)^2 \quad (4.13)$$

donde $X(n)$ es el valor actual de la señal (la componente física de la GSR en este caso), μ es el valor de amplitud promedio de la señal completa y N es el número de muestras contenidas en el vector de amplitudes.

- Movilidad (Mx): es una medida de la desviación estándar de la pendiente comparada con la desviación estándar de la amplitud. Se toma como un valor de frecuencia promedio. La ecuación se muestra a continuación:

$$Mx = \sqrt{\text{var}(\dot{X}(n))\text{var}(X(n))} \quad (4.14)$$

donde $\text{var}(X_n)$ es la varianza de la señal GSR y $\text{var}(\dot{X}_n)$ es la varianza de la derivada de la señal GSR.

- Complejidad (Cx): mide la similitud de la señal estudiada con una señal seno, lo que correspondería a la unidad en caso de una máxima similitud. Este parámetro cuantificará cualquier desviación de la señal seno como un aumento en la unidad. La ecuación para calcular este parámetro se muestra a continuación:

$$Cx = M(\dot{X}(n))M(X(n)) \quad (4.15)$$

donde $M(\dot{X}(n))$ es la movilidad de la señal derivada y $M(X(n))$ es la movilidad de la señal.

En la Tabla 4.1 se muestran todos los atributos seleccionados. En la primera columna se tienen todos los atributos extraídos de las señales ECG. En la segunda columna se tienen todos los atributos extraídos de las señales GSR. Se tienen en total 13 atributos en el dominio del tiempo, sin contar la etiqueta de clase. Estos atributos fueron extraídos en las muestras de todos los pacientes de la base de datos, las cuales tienen una duración de 1 minuto, correspondiente a la duración de cada clip visualizado.

Tabla de atributos seleccionados en el dominio del tiempo	
Atributos para las señales ECG	Atributos para las señales GSR
FC	RCPRE
RCDSP	AmpPromRCP
DERR	DurPromRCP
PPDRR	MaxGSR
	SumABC
	Actividad
	Movilidad
	Complejidad

Tabla 4.1: Atributos extraídos en el dominio del tiempo.

Capítulo 5

Análisis de las señales en el dominio de la frecuencia

En el capítulo anterior, se propuso un conjunto de características en el dominio del tiempo para la detección de eventos de ansiedad. Una perspectiva diferente se muestra a continuación, donde se proponen atributos extraídos de las señales fisiológicas en el dominio de la frecuencia, con el objetivo de evaluar su relevancia para la detección de eventos de ansiedad.

5.1. Análisis espectral

El análisis espectral es una herramienta que tiene como objetivo estimar la distribución de la potencia a través de la frecuencia de una secuencia finita estacionaria. Este tipo de análisis tiene aplicación en diferentes campos. En economía, meteorología, astronomía y en algunos otros estudios, el análisis espectral es implementado para revelar “Periodicidades escondidas” en la información estudiada, lo que es asociado con un comportamiento cíclico y un proceso recurrente [37].

Este tipo de análisis ha demostrado ser de gran utilidad en las tareas de detección de estados emocionales, incluyendo ansiedad, a través de distintas señales fisiológicas. Durante la investigación [38] se utilizó una base de datos con 23 pacientes a los que se les indujo el sentimiento de ansiedad por medio de terapia de exposición, durante la cual, se recolectaban las señales EEG de cada paciente. La detección se realizó en 2 modalidades, la primera de ellas fue la detección de 2 niveles, la cual consiste en clasificar las señales con ansiedad y sin ansiedad. La segunda modalidad fue la detección de 4 niveles, y consiste en determinar en cada señal si el sentimiento de ansiedad es severo, moderado, ligero o

normal. Los atributos utilizados para realizar la detección fueron extraídos del dominio de la frecuencia, e incluían la potencia en las bandas fundamentales de las señales EEG: δ (2-4 Hz), θ (5-7 Hz), α (8-12 Hz), β (13-29 Hz) y γ (30-45 Hz). Se alcanzó una precisión de clasificación utilizando el algoritmo de Bosque Aleatorio del 94.9 % y 92,7 % para la detección en 2 y 4 niveles, respectivamente.

Existen dos enfoques principales para realizar un análisis espectral. El primer enfoque hace uso de un filtro pasa bandas con un ancho de banda muy pequeño, y se realiza un barrido a través de las frecuencias de interés, y la potencia de salida del filtro dividida por el ancho de banda es utilizada como una medida del contenido espectral de la entrada del filtro (la señal estudiada). Este es considerado uno de los métodos clásicos (o no-paramétricos) para el análisis espectral. El segundo enfoque, conocido como “enfoque paramétrico”, consiste en la postulación de un modelo para la señal analizada, la cual provee los medios necesarios para estimar el espectro, de esta manera el problema se reduce a encontrar los parámetros correctos para el modelo propuesto. Los métodos paramétricos ofrecen una mejor estimación espectral que los no-paramétricos cuando las señales satisfacen fielmente al modelo propuesto, sin embargo, en la mayoría de aplicaciones, las señales no satisfacen dicho modelo, por lo que los métodos no-paramétricos entregan mejores resultados [37].

5.1.1. Densidad de la potencia espectral

La mayoría de las señales producidas de manera natural tienen un comportamiento estocástico, es decir, su variación a futuro no se puede predecir, solo se pueden hacer afirmaciones probabilísticas. Una señal aleatoria finita cuenta con una potencia promedio, y es por esto que se puede caracterizar por medio de una densidad de la potencia espectral (DPE) [37]. El cálculo de esta variable se lleva a cabo por medio de los métodos no-paramétricos, ya que se está hablando de variables de comportamiento aleatorio, lo que complicaría la sintonización de los parámetros de un modelo. Un método no-paramétrico para realizar una estimación de la DPE es el periodograma. Una de las aplicaciones principales de este método es determinar posibles periodicidades en series de tiempo. La implementación de este método en señales digitales (obtenidas de una señal analógica muestreada) se realiza con la siguiente ecuación [37]:

$$\hat{\phi}(\omega) = \frac{1}{N} \left| \sum_{t=1}^N y(t) e^{-i\omega t} \right|^2 \quad (5.1)$$

donde N es el número de muestra analizado, $y(t)$ es la señal en el dominio del tiempo, i representa una variable compleja, ω es la frecuencia angular medida en radianes por intervalo de muestreo y t es la variable de tiempo. Una de las ventajas de la aplicación de estos métodos es que tienen una gran resolución, pero esto genera variaciones muy elevadas que en ocasiones dificultan la interpretación analítica de estos resultados. Esta variación ha sido motivación para el desarrollo de métodos modificados que reduzcan esta variación, a costo de una menor resolución, tal es el caso del periodograma de Welch [37].

El método de Welch tiene como objetivo reducir las altas fluctuaciones en el periodograma. El método inicia por separar la señal en el dominio del tiempo en pequeños segmentos, los cuales son ajustados a una función ventana. Una particularidad de este método es que los segmentos ajustados se superponen entre sí. La superposición recomendada para la aplicación de este método es del 50%. Una vez realizada la segmentación y el ajuste de la señal con su respectiva superposición se procede con el cálculo de la transformada rápida de Fourier (TRF) de cada segmento. Finalmente, se promedia la DPE de los periodogramas obtenidos de cada segmento. El procedimiento para el cálculo del periodograma por el método de Welch se describe con la siguiente ecuación [37]:

$$\hat{\phi}_j(\omega) = \frac{1}{MP} \left| \sum_{t=1}^M v(t)y_j(t)e^{-i\omega t} \right|^2 \quad (5.2)$$

donde M representa el tamaño de los segmentos en los que se dividió la señal, $v(t)$ es la ecuación de la ventana temporal, $y_j(t)$ es la j -ésima muestra de la señal en el dominio del tiempo y P denota la potencia de la ventana temporal seleccionada $v(t)$, dada por la siguiente ecuación:

$$P = \frac{1}{M} \sum_{t=1}^M |v(t)|^2 \quad (5.3)$$

Entonces, aplicando las ecuaciones 5.2 y 5.3 se obtiene el periodograma de cada segmento, finalmente solo se calcula la DPE de Welch promediando los periodogramas de la siguiente manera:

$$\hat{\phi}_W(\omega) = \frac{1}{S} \sum_{j=1}^S \hat{\phi}_j(\omega) \quad (5.4)$$

donde S representa el total de periodogramas obtenidos de la señal en el dominio del tiempo.

5.2. Atributos para las señales de electrocardiograma

La VFC ha demostrado ser de alta relevancia para la detección de emociones utilizando análisis en el dominio del tiempo [29], [30]. Otros estudios han obtenido resultados importantes para la detección de ansiedad y distintas emociones a través del análisis de la VFC en el dominio de la frecuencia [3], [39]. En estos estudios se ha observado que al obtener el periodograma de la VFC se pueden observar fluctuaciones en la banda de altas frecuencias (AF), correspondientes al rango de 0.15 a 0.4 Hz.

5.2.1. Procedimiento de extracción de atributos ECG

Debido a que los atributos en el dominio de la frecuencia están relacionados con la VFC, el análisis espectral parte por la detección de las ondas R de las señales de ECG con el algoritmo de Pan-Tompkins [2], mencionado en secciones anteriores. Este algoritmo retornará una serie de tiempo en la que se especifican las duraciones de cada intervalo RR contenido en la señal ECG. A partir de esta serie de tiempo, se calcula el espectro de potencia.

Para la obtención del espectro de frecuencia de la VFC se desarrolló un algoritmo en lenguaje de programación Python siguiendo la metodología propuesta por Guo et al. [39], en la que se calcula el periodograma por medio de la transformada rápida de Fourier, tomando 100 Hz como frecuencia de muestreo. Al aplicar este algoritmo se obtienen 2 vectores, uno que contiene los valores de frecuencia y otro con los valores de DPE correspondientes.

Una vez obtenidos los valores de frecuencia y DPE, se puede obtener el espectro de frecuencia de la señal, tal y como se muestra en la Figura 5.1. Aquí se puede observar que las señales de variabilidad de frecuencia cardíaca trabajan en un rango de frecuencia aproximado de 0 a 0.6 Hz.

Además del análisis espectral de la VFC, se analizará el espectro de potencia obtenido directamente de la señal ECG para comprobar si otorga información relevante para la detección de ansiedad. El procedimiento es exactamente el mismo, la única diferencia es que la serie de tiempo utilizada es la señal ECG.

5.2.2. Atributos seleccionados

Como se mencionó previamente, la banda de frecuencia que ha demostrado un gran desempeño en la detección de ansiedad va de 0.15 a 0.4 Hz, correspondiente a la banda

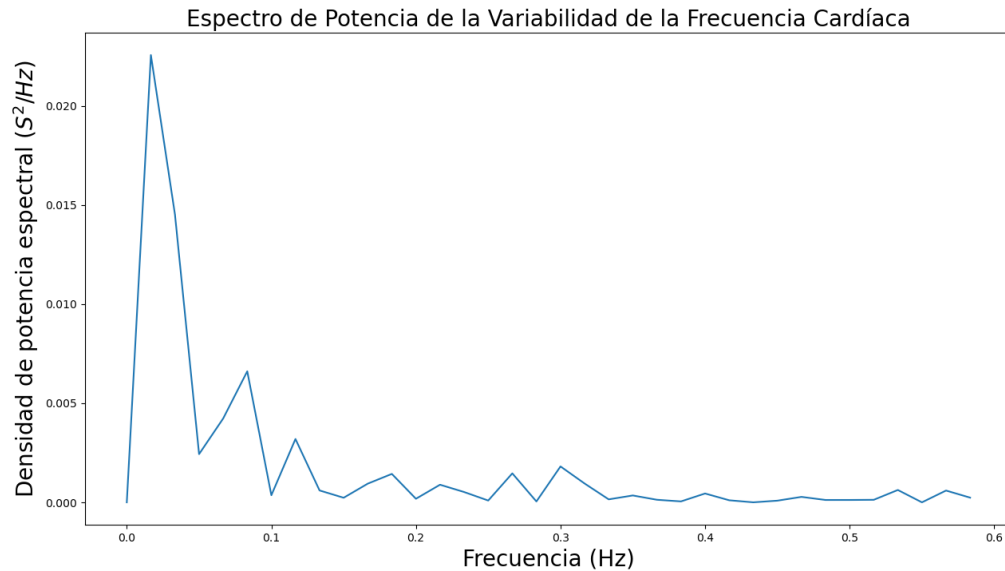


Figura 5.1: Espectro de potencia de la variabilidad de la frecuencia cardíaca.

de altas frecuencias. El atributo seleccionado para el analizar las fluctuaciones en esta banda de frecuencias es la potencia de banda de los intervalos RR (PotenciaRR). Esta variable ha demostrado ser de gran utilidad en la detección de eventos de ansiedad en distintas investigaciones, como la que se muestra en [3], donde se buscaba detectar ansiedad durante una defensa de tesis. El algoritmo desarrollado en dicha investigación alcanzó una precisión de clasificación del 81.82%.

El procedimiento para calcular la PotenciaRR consiste en calcular el área bajo la curva formada por las frecuencias de interés en el espectro de potencia de la VFC, en este caso, de 0.15 a 0.4 Hz. El cálculo del área bajo la curva se realizó aplicando una integración numérica trapezoidal tomando como amplitud la DPE y como rango las frecuencias de 0.15 a 0.4 Hz. El mismo procedimiento se utiliza con la potencia de banda de la señal ECG (PotenciaECG), en donde se calcula la potencia en la banda de 0.15 a 0.4 Hz pero ahora utilizando el periodograma obtenido a partir de la señal ECG.

5.3. Atributos para las señales de Respuesta Galvánica de la Piel

Actualmente no se han reportado atributos extraídos del espectro de potencia de señales GSR para la detección de eventos de ansiedad específicamente. El análisis espectral de las señales GSR ha tenido aplicación en la identificación de distintos estados emocio-

nales. Durante la investigación [40], se diseñó un experimento para aumentar los niveles de carga mental de los participantes mientras sus señales GSR eran registradas. En este estudio se detectó que en el espectro de potencia de la GSR existen cambios significativos en la banda de 0.03 a 0.5 Hz que permiten identificar distintos niveles de carga mental que pueden conducir al estrés. Un punto de vista distinto se muestra en [41], donde se proponen nuevos atributos en el dominio de la frecuencia para cuantificar la función del sistema simpático. El análisis del sistema simpático ha sido ampliamente investigado por su relación con ciertas enfermedades y condiciones fisiopatológicas en el campo de la actividad cardiovascular, y ha demostrado tener un impacto de diagnóstico importante.

5.3.1. Procedimiento de extracción de atributos GSR

Para la extracción de atributos en el dominio de la frecuencia de las señales GSR se siguió el procedimiento propuesto por Posada-Quintero et al. [41], el cual cuenta con una etapa de procesamiento de la señal y una etapa de cálculo del espectro de potencia. La etapa de procesamiento comienza con la aplicación de un filtro pasa-bajas de octavo orden Chebyshev tipo 1 con frecuencia de corte de 0.8 Hz. Posteriormente se realiza una reducción de la resolución de la señal, pasando de una frecuencia de muestreo de 100 Hz a 2 Hz, esto significa que las señales GSR pasan de un aproximado de 6000 muestras, a 120 muestras en total (utilizando un factor de 1/50). Finalmente, se aplicó un filtro pasa-altas de octavo orden Butterworth con frecuencia de corte de 0.01 Hz para remover cualquier tendencia de la señal. La reducción de la resolución de la señal no afecta su dinámica espectral, ya que la potencia de las señales GSR está mayormente confinada en las frecuencias menores a 0.4 Hz [41].

Una vez realizado el procesamiento correspondiente, se procede con la obtención del espectro de potencia de la señal, utilizando el método del periodograma refinado de Welch. La aplicación de este método requiere la selección de una ventana para la segmentación de la señal. Para este trabajo se seleccionó una ventana de tipo “Blackman”, la cual se muestra en la Figura 5.2, con un tamaño de 128 puntos. La superposición entre ventanas aplicada fue del 50 %. Finalmente se calcula la TRF de cada segmento y los espectros de potencia obtenidos son promediados para obtener el espectro total de la señal. Para este trabajo, se agregó una etapa de normalización de las señales. Esta consiste en adaptar las amplitudes de las señales para que todas se encuentren dentro de una escala de 0 a 1 dividiendo las amplitudes del espectro entre el valor máximo de DPE. Esto se realizó con el objetivo de facilitar la identificación de fluctuaciones en las diferentes áreas de frecuencia del espectro de potencia.




Figura 5.2: Ventana de Blackman [37].

Una vez calculados los valores de frecuencia y DPE por medio del método de Welch, se obtiene el espectro de potencia de la señal GSR, como el mostrado en la Figura 5.3. En este se puede observar que las señales GSR trabajan en un rango de frecuencia entre 0 y 0.4 Hz, como se mencionó previamente. Además, se puede observar que la etapa de normalización se realizó correctamente, ya que la amplitud de la señal se encuentra dentro de la escala de 0 a 1. Una particularidad del periodograma de Welch es que sacrifica resolución, a cambio de reducir la excesiva variabilidad que una TRF ocasionaría, lo que facilita la inspección analítica del espectro, ya que cuenta con curvas con cambios menos abruptos, a diferencia de los obtenidos en el espectro de la VFC en la Figura 5.1.




Figura 5.3: Espectro de potencia de una señal GSR.

5.3.2. Atributos seleccionados

Los atributos seleccionados para este trabajo consisten en el cálculo de la potencia en las bandas de frecuencia de interés de las señales GSR sugeridos por Posada-Quintero et al. [41], con el objetivo de analizar si estos atributos pueden aplicarse también para la detección de eventos de ansiedad. Los atributos seleccionados, con su respectiva banda de frecuencia, se muestran a continuación:

- Potencia en muy bajas frecuencias (PotenciaMBF) de 0-0.045 Hz
- Potencia en bajas frecuencias (PotenciaBF) de 0.045-0.15 Hz
- Potencia en altas frecuencias 1 (PotenciaAF1) de 0.15-0.25 Hz
- Potencia en altas frecuencias 2 (PotenciaAF2) de 0.25-0.4Hz
- Potencia en muy altas frecuencias (PotenciaMAF) de 0.4-0.5 Hz

En la Tabla 5.1 se muestran todos los atributos seleccionados en el dominio de la frecuencia para la detección de ansiedad. En la primera columna se muestran los atributos extraídos de las señales ECG. En la segunda columna se muestran los atributos extraídos de las señales GSR. Los espectros para las muestras de 1 minuto tanto de las señales ECG, como de las señales GSR fueron calculados y graficados, posteriormente se calculó la potencia en las bandas de interés correspondiente.

Tabla de atributos seleccionados en el dominio de la frecuencia	
Atributos para las señales ECG	Atributos para las señales GSR
PotenciaRR	PotenciaMBF
PotenciaECG	PotenciaBF
	PotenciaAF1
	PotenciaAF2
	PotenciaMAF

Tabla 5.1: Tabla de atributos extraídos en el dominio de la frecuencia.

Capítulo 6

Clasificación de las señales con ansiedad

El objetivo de determinar atributos potencialmente significativos para detectar eventos de ansiedad es implementar algoritmos de clasificación basados en aprendizaje automático. Este tipo de algoritmos hace uso de atributos y etiquetas en una etapa de entrenamiento para generar un modelo que utilice estos atributos como las entradas y produzca una decisión en la salida, siendo esta decisión una clasificación. En este trabajo se realizó la clasificación en 2 niveles: señales con ansiedad y señales sin ansiedad. A continuación, se describen los algoritmos seleccionados basado en desempeño demostrado en investigaciones previas para la detección de emociones y eventos de ansiedad.

6.1. Etiquetado de las señales

Una vez determinados los atributos de interés para cada señal fisiológica es importante etiquetar cada señal. Una etiqueta determina la clase a la que pertenece cada muestra, siendo la muestra en este caso 1 minuto de señales fisiológicas adquiridas durante cada clip visualizado por los pacientes. Para el caso de las señales con ansiedad, se toman todas aquellas que fueron recopiladas mientras que el paciente visualizaba un video, ya que se está trabajando con pacientes con fobia específica a las arañas, por lo que se espera que la ansiedad se active mientras el paciente está expuesto a su fobia específica. Cada paciente tuvo una sesión de reposo, en donde se tranquilizaban mientras que sus señales fisiológicas seguían siendo adquiridas, estas señales fueron etiquetadas como señales sin ansiedad.

En este estudio se tienen 729 muestras de señales con ansiedad y 228 muestras de

señales sin ansiedad, esto corresponde a un total de 952 muestras de señales fisiológicas. Estas muestras fueron recopiladas de 47 pacientes, las muestras de 10 sujetos tuvieron que ser descartadas, ya sea porque no contaban con señales durante la sesión de reposo o porque el excesivo ruido imposibilitaba la extracción de los atributos.

Para poder llevar a cabo el entrenamiento y la prueba de los algoritmos de clasificación es necesario hacer un archivo de texto donde se encuentren los atributos de cada muestra con su respectiva etiqueta, para esto se elaboró un archivo .csv en donde los atributos de las 952 muestras fueron ingresados con su respectiva etiqueta.

6.2. Clasificadores seleccionados

Los algoritmos de clasificación basados en aprendizaje automático supervisado implementados durante este trabajo, fueron aplicados a las muestras de la base de datos utilizando el software Weka 3.8.6. El funcionamiento de cada clasificador, así como los parámetros definidos para su aplicación en este trabajo, se muestran a continuación.

6.2.1. Bosques aleatorios

Para explicar el funcionamiento del algoritmo de bosques aleatorios es necesario conocer el funcionamiento de los árboles de decisiones. Los árboles de decisión son herramientas para regresión y clasificación que además extraen información útil acerca de la base de datos. Estos necesitan de muestras etiquetadas para su entrenamiento, las cuales representan las clases del problema [42]. Un árbol de decisiones es un modelo que divide la información de la base de datos en un conjunto de preguntas cuyas respuestas pueden ser más preguntas, hasta llegar a una posible respuesta [43]. Entonces el objetivo de este modelo es encontrar el conjunto de preguntas y respuestas óptimas para llegar a una clasificación precisa. En la Figura 6.1 se muestra un ejemplo de un árbol de decisiones, aquí se pueden observar sus partes principales, iniciando por el nodo raíz que corresponde a la primera pregunta, seguido por las ramas que pueden ir a 2 tipos de elementos, ya sea a una hoja que corresponde a una decisión (en este caso a una clasificación), o bien, puede pasar a un nodo de decisión del que se pueden desprender más hojas o nodos.

Una vez explicado el concepto de los árboles de decisiones, se describe el funcionamiento del algoritmo de bosques aleatorios. Este es un algoritmo de aprendizaje supervisado conformado por un conjunto de árboles de decisiones entrenados cada uno con una parte diferente de la base de datos principal. Al implementar una clasificación basada en un árbol de decisiones se entrena un solo modelo y se utiliza para realizar las pruebas de

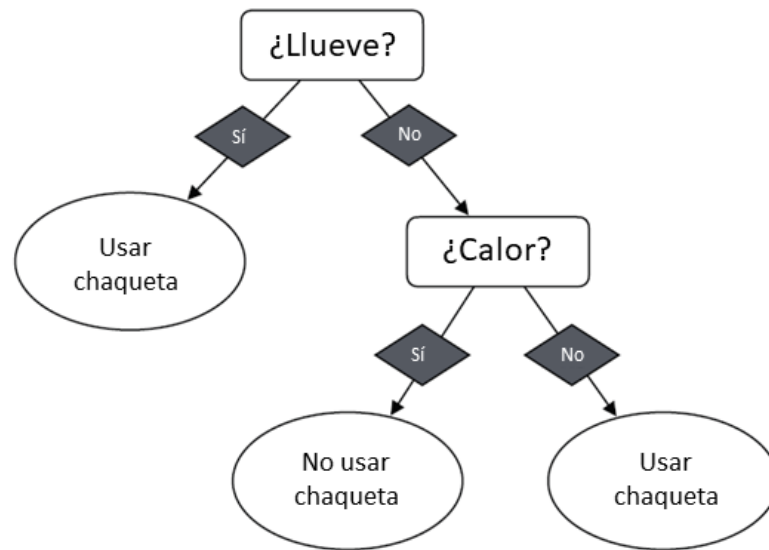


Figura 6.1: Ejemplo de un árbol de decisiones [42].

precisión. La ventaja de implementar bosques aleatorios para clasificación es que genera múltiples árboles de decisiones entrenados y listos para pasar a la etapa de pruebas de precisión [43]. Al momento de implementar una clasificación por bosques aleatorios es importante definir el número de atributos con los que trabajará cada árbol de decisiones y cuántos árboles serán utilizados. En una tarea de clasificación, cada árbol de decisiones entrega una respuesta, al final la respuesta con mayor ocurrencia es la salida del algoritmo principal [43].

Bosques aleatorios ha demostrado ser un algoritmo de alta precisión en la clasificación de señales con ansiedad. En investigación presentada en [4], se hizo la prueba con distintos clasificadores basados en aprendizaje automático para la clasificación de 2 y 3 niveles de ansiedad, en ambos casos el algoritmo que alcanzó una mayor precisión fue bosques aleatorios, con valores del 89.9% y 74.4%, respectivamente.

En este trabajo de tesis se aplicó el algoritmo de bosques aleatorios con un total de 100 árboles de decisión, esto significa que se entrenan 100 árboles con diferentes partes de la base de datos y al final, la clase seleccionada con más frecuencia es la decisión final del algoritmo.

6.2.2. Máquina de vectores de soporte

Máquina de vectores de soporte es uno de los métodos clásicos de clasificación basados en aprendizaje automático que hoy en día siguen siendo de gran utilidad para la solución

de problemas de clasificación mediante la implementación de una frontera con forma lineal (ya sea una recta o un hiper-plano). Las MVS buscan establecer una frontera que se encuentre lo más alejado posible de los puntos de la base de datos. Una particularidad del método de clasificación con MVS es que divide las muestras de la base de datos utilizando 2 líneas paralelas en lugar de una que cumpla con 2 condiciones; clasificar las muestras correctamente y además intenta aumentar el espacio entre ellas lo más posible [42]. En la Figura 6.2 se muestra una representación gráfica de la división que establece el clasificador para separar las 2 clases de la base de datos. Como se puede observar, el clasificador 2 es el que tiene mejores resultados ya que permite una mayor separación entre las líneas paralelas.

Para asegurar un correcto funcionamiento del clasificador utilizando MVS es necesario establecer una función de error que tome en cuenta tanto la capacidad de clasificación, como la distancia entre las líneas paralelas de la frontera. Entonces esta ecuación tomaría la siguiente forma [42]:

$$\text{Error} = \text{Error de clasificación} + \text{Error de distancia} \quad (6.1)$$

donde el error de clasificación está determinado por el número de clasificaciones acertadas y el error de distancia toma en cuenta el peso de los atributos para determinar la distancia entre ambas rectas paralelas. En la Figura 6.2, se puede observar cómo el clasificador 2 es el que tiene menor error, ya que clasifica correctamente las muestras del problema al mismo tiempo que tiene las rectas con mayor separación.

Este método de clasificación basado en aprendizaje automático se ha implementado para la detección de señales con ansiedad, como se muestra en [1], donde se utilizaron atributos derivados de los intervalos RR extraídos de 15 sujetos para la clasificación de 2 clases: señales con ansiedad y señales sin ansiedad. El algoritmo presentado demostró tener una precisión del 71.1 % utilizando el clasificador con MVS.




Figura 6.2: Representación esquemática de la clasificación por MVS [42].

6.2.3. K-Vecinos más cercanos

El algoritmo k -Vecinos más cercanos (k -VMC) es uno de los métodos de clasificación más famosos para la minería de datos. Su funcionamiento consiste en agrupar todas aquellas muestras que tengan atributos parecidos, es decir, cuando se realiza la tarea de clasificación de una muestra, cuya clase es desconocida, se verifica su similitud con otras muestras ya etiquetadas (muestras de entrenamiento) y dependiendo de la clase a la que pertenecen estas muestras cercanas, es la decisión que toma el clasificador [44].

Para que este algoritmo tenga un funcionamiento óptimo es necesario que se compruebe la similitud de los atributos de la muestra de prueba con el número de muestras de entrenamiento confiable y al final se comprueba la clase a la que pertenecen las muestras más cercanas y se lleva a cabo la clasificación de la muestra de prueba. De esta característica viene el nombre del clasificador, ya que el parámetro k representa el número de muestras de entrenamiento que se tomaran en cuenta para la comparación. En la Figura 6.3 se muestran 2 ejemplos, el primero de ellos con un valor de $k = 1$ y el segundo con $k = 4$. Como se puede observar en la imagen, $k = 1$ solo toma en cuenta al vecino más cercano, por lo que la clasificación resultará en la clase de esa muestra. En cambio, cuando aumenta el valor de k se hace la comparación con un mayor número de muestras y al final la clasificación resulta en la clase del mayor número de muestras cercanas.

El algoritmo k -VMC ha sido utilizado en distintas ocasiones para la detección de emociones. Durante la investigación [45], se implementó un clasificador k -VMC en conjunto con atributos extraídos de señales de frecuencia cardíaca, temperatura de la piel y oxigenación para detectar los niveles de estrés de 21 estudiantes. La precisión alcanzada durante este experimento fue de 90 %, un valor destacado en comparación con otras investigaciones que han buscado implementar k -VMC para la clasificación de señales fisiológicas. Otro ejemplo donde se buscó implementar un clasificador basado en el algoritmo k -VMC fue en [46], donde se experimentó con señales de fotopletismografía (PPG) y EEG recolectadas por auriculares y lentes inteligentes de 20 sujetos. Para la clasificación en 3 clases de ansiedad (bajo, medio, alto), esta investigación obtuvo una precisión del 62.5 %, lo que representa una diferencia significativa con respecto a otras investigaciones. Esta diferencia se puede deber al conjunto de atributos seleccionados de las señales fisiológicas y a los parámetros establecidos en el clasificador.

En este trabajo de tesis se aplicó el algoritmo de K-vecinos más cercanos tomando en cuenta un valor de $k = 1$, esto quiere decir que las muestras de prueba serán clasificadas con la clase de la muestra de entrenamiento con la que más compartan similitudes.




Figura 6.3: (a) Prueba de clasificación con $k=1$. (b) Prueba de clasificación con $k=4$ [44].

6.2.4. Redes neuronales

Las redes neuronales son un tipo de algoritmo de aprendizaje automático que trata de emular el funcionamiento del cerebro humano. Para comprender el funcionamiento de las redes neuronales, es necesario conocer sus partes elementales: los perceptrones. Un perceptrón es un modelo matemático que utiliza los atributos de las muestras de entrenamiento para generar una función lineal de clasificación. La definición general de esta función matemática se muestra a continuación:

$$w_1x_1^{(i)} + w_2x_2^{(i)} + w_3x_3^{(i)} + \dots + w_nx_n^{(i)+b} \quad (6.2)$$

donde $x_n^{(i)}$ representa el n -ésimo atributo de la i -ésima muestra de la base de datos, w_n representa el peso otorgado a cada uno de los atributos y b representa un escalar de valor constante denominado en la literatura como “bias”. Para que un perceptrón cumpla correctamente con la tarea de clasificación, deben de ser sintonizados los valores de peso para cada atributo y la bias, este procedimiento dependerá de la naturaleza de las muestras de la base de datos y los atributos seleccionados. En la Figura 6.4 el resultado de una clasificación implementando un perceptrón simple. Como se puede observar, no hay bias, se tienen solamente 2 atributos cuyos pesos son de 1 y ambas muestras fueron clasificadas correctamente.

Los algoritmos de clasificación basados en redes neuronales están compuestos por un conjunto de perceptrones (llamados neuronas) interconectados entre sí y organizados en distintas capas. En esta red, cada una de las neuronas cuenta con un número determinado de entradas y salidas que a su vez están conectadas con otras neuronas [43]. En la Figura 6.5 se muestra un ejemplo de una red neuronal, aquí se pueden observar las partes




Figura 6.4: Ejemplo de clasificación con un perceptrón simple [42].

principales de una red neuronal. Iniciando por la capa de entrada, esta contiene todos aquellos atributos que se toman en cuenta para la clasificación de una muestra, en el caso de la imagen son solo 2 atributos. Como elementos conectores se tienen las ramas de la red neuronal, las cuales contienen el valor del peso de cada atributo. Al centro de la red neuronal se encuentra la siguiente capa, nombrada capa escondida, todas aquellas capas contenidas entre la capa de entrada y la de salida llevan este nombre. En las capas escondidas se encuentran todos los perceptrones (neuronas) que comienzan a hacer operaciones con los atributos de entrada para tomar decisiones y arrojar un valor de salida. Una red neuronal puede tener más de una capa escondida y en el mayor de los casos esto mejora la precisión de clasificación. Después de la capa escondida se tiene un perceptrón más, el cual se encuentra en la capa de salida. Aquí se observa que el perceptrón recibe las salidas de las neuronas contenidas en la capa escondida con sus respectivos pesos y bias para realizar una última operación y llegar así a una decisión final. El caso mostrado en la figura utiliza la función escalón para que los valores de salida de los perceptrones sean discretos (0 y 1), pero comúnmente se utilizan otras funciones (por ejemplo la función sigmoide) para que los perceptrones entreguen valores continuos a su salida [42].

Durante la investigación presentada en [5] se implementó un algoritmo basado en redes neuronales para la clasificación de señales con ansiedad. La única señal fisiológica utilizada en este caso fueron las señales ECG, de las que se extrajeron atributos relacionados con la VFC (RCDSP) para diferentes ventanas de tiempo. La precisión alcanzada implementando redes neuronales fue del 83.2%.




Figura 6.5: Ejemplo de una red neuronal usando perceptrones discretos [42].

En la Figura 6.6 se muestra la red neuronal diseñada para la presente tarea de clasificación. Como se puede observar, cuenta únicamente con una capa escondida con 8 perceptrones, la cual recibe el peso de los atributos de entradas, realiza las operaciones correspondientes y envían los resultados a la capa de salida para que se tome la decisión de clasificación. El peso de cada atributo se calcula durante la etapa de entrenamiento del algoritmo.

6.2.5. Selector de atributos

Un selector de atributos está conformado por un método de evaluación y uno de búsqueda, el objetivo de su implementación es identificar el conjunto de atributos con mayor impacto en la toma de decisiones de un clasificador especificado. El método de




Figura 6.6: Red neuronal diseñada para este trabajo.

evaluación implementado para este trabajo fue “WrapperSubSetEval”, el cual utiliza la técnica “validación cruzada” en conjunto con un clasificador para estimar la precisión de clasificación que otorga el grupo de atributos analizado [47].

6.3. Selección de atributos y validación

Una vez determinado el método de evaluación, se prosigue con el método de búsqueda. Para este trabajo se seleccionó el método “BestFirst”, el cual cuenta con 3 modos de funcionamiento [47]:

- Hacia delante: en este modo se inicia con un atributo, después se evalúa la precisión y posteriormente se agrega un atributo más. Este procedimiento se repite hasta que la precisión empieza a decaer, en ese momento la búsqueda termina y se entrega la lista con los atributos que obtuvieron la mejor precisión. El programador puede determinar cuantos atributos sin aporte de mejora permitir antes de terminar la búsqueda.
- Hacia atrás: el funcionamiento es similar a la búsqueda hacia delante, pero en este modo se inicia con la lista completa de atributos, se evalúa la precisión y posteriormente se remueve un atributo. El proceso se repite hasta que la precisión deja de mejorar y se entrega la lista de atributos.
- En ambas direcciones: en este modo se inicia por una lista de atributos determinada por el programador y comienza a realizar la búsqueda en ambas direcciones (agregando o removiendo atributos).

6.3.1. Validación del modelo

Los métodos de validación de modelos consisten en medir el desempeño de los clasificadores utilizando distintas combinaciones de muestras de entrenamiento y de prueba, es decir, se toma una porción de la base de datos para el entrenamiento del algoritmo de clasificación y la otra porción se utiliza para probar la precisión del clasificador [47]. Existen distintas técnicas de validación del modelo, pero en este trabajo de tesis se utilizó la “validación cruzada de 5 iteraciones”. Esta técnica consiste en dividir las muestras de la base de datos en 5 grupos del mismo tamaño, después se selecciona uno de ellos para ser el grupo de prueba y el resto se utiliza para el entrenamiento del modelo. Una vez finalizado el entrenamiento, se comprueba la precisión del clasificador en las muestras de

prueba y se registran los resultados. Posteriormente se elige un nuevo grupo de pruebas y el anterior pasa a usarse para el entrenamiento. Este proceso de cambiar el grupo de pruebas y obtener la precisión del clasificador se realiza 5 veces. Al finalizar, se tendrán 5 precisiones de clasificación de las cuales se calculará el promedio y esa será la precisión del modelo de clasificación [47].

Capítulo 7

Resultados de clasificación

En este capítulo se muestran los resultados obtenidos de los algoritmos selectores de atributos y la precisión de clasificación que alcanzó cada uno en la detección de eventos de ansiedad en la base de datos. Las pruebas se realizan con la lista de atributos completa (atributos en el dominio del tiempo y de la frecuencia).

7.1. Cálculo de la precisión de clasificación

Para calcular la precisión de clasificación se utiliza la siguiente fórmula:

$$Precisión = \frac{TP + TN}{TP + FP + TN + FN} \quad (7.1)$$

donde TP son los verdaderos positivos (donde positivo representa ansiedad) TN son los verdaderos negativos (donde negativo representa muestras sin ansiedad), FP son los falsos positivos (muestras incorrectamente clasificadas con ansiedad) y FN son los falsos negativos (muestras incorrectamente clasificadas sin ansiedad). La base de datos está conformada por 952 muestras, donde 729 corresponden a señales con ansiedad y 228 a señales sin ansiedad. Cabe recalcar que la clasificación se realizó en 2 niveles de ansiedad, siendo señales con ansiedad y sin ansiedad las 2 opciones de clasificación posibles.

7.2. Precisión de clasificación de cada algoritmo

En la Tabla 7.1 se muestran las precisiones obtenidas por cada algoritmo de clasificación supervisado implementado. Como se puede observar, el algoritmo que demostró un mejor desempeño para la detección de ansiedad fue el algoritmo de bosques aleato-

rios, alcanzando una destacable precisión del 81.8 %, lo que corresponde a 784 muestras clasificadas correctamente y 175 incorrectas.

Estudios previos habían utilizado la misma base de datos de pacientes aracnofóbicos para desarrollar algoritmos similares para la detección de ansiedad. Una de ellas es la expuesta en [5], donde se diseñó una red neuronal convolucional (RNC) para la detección de ansiedad en 2 niveles. El único atributo utilizado fue la RCDSF, el cual es un atributo de la VFC extraído del dominio del tiempo. La precisión alcanzada con esta configuración fue del 77.14 %. Durante el trabajo presentado en [35], también se utilizó la misma base de datos, en este caso utilizando una mayor cantidad de atributos pero todos exclusivamente

Clasificador	Mejor precisión obtenida	Mejores atributos
Bosques aleatorios	81.8%	FC
		RCDSF
		DERR
		PotenciaRR
		PotenciaECG
		RCPRE
		Actividad
		Complejidad
PotenciaMBF		
Maquina de vectores de soporte	77.8%	FC
		DERR
		PPDRR
		PotenciaRR
		PotenciaECG
		RCPRE
		AmpPromRCP
		DurPromRCP
		MaxGSR
		SumABC
		Movilidad
		Complejidad
		PotenciaMBF
		PotenciaAF1
PotenciaAF2		
PotenciaMAF		
K-Vecinos más cercanos	73.9%	FC
		RCDSF
		DERR
		RCDRE
		DurPromRCG
		MaxGSR
		SumABC
		Movilidad
		Complejidad
		PotenciaAF1
		PotenciaAF2
Redes neuronales	79.1%	RCDSF
		DERR
		PPDRR
		PotenciaRR
		PotenciaECG
		RCPRE
		MaxGSR
		Actividad
		Movilidad
		PotenciaMBF
		PotenciaBF
		PotenciaAF1
PotenciaAF2		
PotenciaMAF		

Tabla 7.1: Tabla de precisión obtenida por cada clasificador.

extraídos en el dominio del tiempo de las señales ECG y GSR. El clasificador que alcanzó la mayor precisión de clasificación fue árboles anidados, con 78 % para la detección de 2 niveles de ansiedad. Como se puede observar, los resultados obtenidos durante el trabajo actual son destacables con aquellos obtenidos por investigaciones previas, alcanzando una precisión del 81.8% para la detección de ansiedad en 2 niveles. Se puede atribuir esta mejora a la implementación tanto de atributos en el dominio del tiempo, como en la frecuencia, aspecto que no es comúnmente cubierto en la detección de ansiedad por medio de señales ECG y GSR.

Al momento del desarrollo de este proyecto, se realizó la prueba aplicando solamente los atributos extraídos del dominio del tiempo de ambas señales. Las precisiones fueron menores en absolutamente todos los clasificadores, aún cuando se utilizó el algoritmo selector de atributos óptimos. La diferencia promedio de precisión obtenida fue del 0.55 %. Esto significa que los atributos en el dominio de la frecuencia aportan información relevante para la aplicación de cualquier algoritmo de clasificación supervisado basado en aprendizaje automático.

En la Tabla 7.2 se muestra el número de ocasiones en las que fue seleccionado cada atributo por el algoritmo selector de atributos para cada clasificador. En ella se puede observar que los atributos de DERR y RCPRE fueron los atributos más seleccionados, demostrando que las señales fisiológicas seleccionadas ofrecen información relevante para la detección de ansiedad por medio de la implementación de algoritmos de clasificación basados en aprendizaje automático.

7.3. Matriz de confusión

Las matrices de confusión son herramientas que permiten medir el desempeño de un algoritmo de clasificación otorgando información acerca de las muestras que fueron clasificadas correcta e incorrectamente [47]. En la Figura 7.1 se muestra la matriz de confusión obtenida con el algoritmo de bosques aleatorios. Como se puede observar, se clasificaron correctamente 710 muestras con ansiedad, fallando en clasificar solamente 19 muestras, lo que representa un 97.3 % de efectividad clasificando muestras con ansiedad. Para el caso de las muestras sin ansiedad se obtiene un desempeño diferente, en este caso de clasificaron correctamente 74 muestras, fallando en 156, lo que representa un 32.1 % de muestras sin ansiedad clasificadas correctamente. Este es un resultado esperado, debido a la gran diferencia que existe en la cantidad de muestras con ansiedad con respecto a las muestras sin ansiedad, teniendo 729 y 230 muestras respectivamente, a

Señal fisiológica	Atributos	Selecciones
ECG	FC	3
	RCDSP	3
	DERR	4
	PPDRR	2
	PotenciaRR	3
	PotenciaECG	3
GSR	RCPRE	4
	AmpPromRCP	1
	DurPromRCP	2
	MaxGSR	3
	SumABC	2
	Actividad	2
	Movilidad	3
	Complejidad	3
	PotenciaMBF	3
	PotenciaBF	1
	PotenciaAF1	3
	PotenciaAF2	2
	PotenciaMAF	2

Tabla 7.2: Número de selecciones de cada atributo por cada clasificador.

este comportamiento se le conoce como desbalance de la base de datos [48].

7.4. Comparación con investigaciones previas

7.4.1. Tabla de comparación

En la Tabla 7.3 se muestra la comparación entre el algoritmo de clasificación que alcanzó la mayor precisión durante esta investigación y algoritmos publicados previamente que comparten el mismo objetivo. En esta se puede observar que las señales ECG son las más utilizadas para esta tarea, aunque existen excepciones, como la mostrada en [49], donde se alcanzó una precisión de clasificación del 92.3%, siendo una de las más altas publicadas hasta el momento.

El desempeño de los clasificadores puede ser influenciado por distintos factores. En la Tabla 7.3 se puede observar una gran variedad de algoritmos de clasificación implementados, donde el algoritmo de MVS es el que fue utilizado con más frecuencia. Durante el presente trabajo de tesis también se implementó el algoritmo MVS, pero no fue el que alcanzó la mayor precisión de clasificación, tal y como de muestra en la Tabla 7.1,

	Ansiedad	Sin ansiedad
Ansiedad	710	19
Sin ansiedad	156	74

Figura 7.1: Matriz de confusión del algoritmo de bosques aleatorios.

esto muestra la sensibilidad que tienen los resultados a la lista de atributos seleccionada. Otro factor influyente en los resultados de precisión es el método de validación. El método más utilizado fue la validación cruzada, la cual se caracteriza por iterar las muestras de entrenamiento y prueba. El otro método de validación utilizado fue la división de las muestras, el cual consiste en tomar una porción definida de muestras para el entrenamiento y el resto permanecen como muestras de prueba. Este método puede ser poco confiable ya que solo se realiza una prueba, mientras que en una validación cruzada la precisión resultante se obtiene de promediar las precisiones calculadas durante cada iteración, lo que otorga un resultado que refleja el desempeño del clasificador.

7.4.2. Figura de mérito

Las figuras de mérito otorgan información acerca de la comparación del desempeño de un sistema diseñado contra el estado del arte [50]. En este caso, se compara el algoritmo diseñado durante el trabajo actual, contra algoritmos que implementen clasificadores basados en aprendizaje automático para la detección de ansiedad diseñados en investigaciones previas. La característica principal analizada para definir el desempeño de los sistemas es la precisión, ya que indica la capacidad del algoritmo para identificar las diferentes clases del problema, en este caso, señales con ansiedad y sin ansiedad.

Referencia	Aplicación	Señal estudiada	Método de validación	Clases	Algoritmo de clasificación	Precisión
Adheena et al. (2018) [1]	Detección de ansiedad en pacientes estimulados emocionalmente	ECG	División del 70%	2 niveles	MVS	71.1%
				2 niveles	Filtro de Kalman	69.3%
Vulpe-Grigorasi and Grigore (2021) [4]	Detección de ansiedad en pacientes con fobia específica	ECG	División del 80%	2 niveles	1D-RNC	77.1%
Wen et al. (2020) [2]	Detección de ansiedad social durante un discurso en público	ECG	Validación cruzada de 5 iteraciones	2 niveles	MVS	81.8%
Ihming et al. (2020) [3]	Detección de ansiedad en pacientes aracnofóbicos	ECG, GSR	Validación cruzada de 10 iteraciones	2 niveles	Árboles anidados	89.80%
				3 niveles		74.40%
Haritha et al. (2017) [49]	Detección de ansiedad en pacientes con trastornos mentales	Intervalos de respiración	No reportado	2 niveles	MVS	92.3%
Selzler et al. (2021) [36]	Detección de ansiedad en pacientes aracnofóbicos	ECG, GSR	Validación cruzada de 10 iteraciones	2 niveles	Árboles anidados	78.5%
				3 niveles		60.5%
El algoritmo propuesto	Detección de ansiedad en pacientes aracnofóbicos	ECG, GSR	Validación cruzada de 5 iteraciones	2 niveles	Bosques aleatorios	82.0%

Tabla 7.3: Comparación del algoritmo propuesto con investigaciones previas.

Comparación entre precisión y señales fisiológicas

Un aspecto que podría definir la selección de un algoritmo es la cantidad de señales fisiológicas que considera para la detección de ansiedad. Una mayor cantidad de señales fisiológicas, requiere un mayor número de sensores, lo que a su vez aumenta el número de etapas de procesamiento de señales y la cantidad de atributos considerador para entrenar a los algoritmos de clasificación.

En la Figura 7.2 se muestra la figura de mérito diseñada para comparar el algoritmo propuesto con investigaciones previas, las cuales se muestran con el número de referencia con las que se pueden ubicar en la sección de bibliografía. El eje Y contiene las precisiones obtenidas, mientras que el eje X contiene la cantidad de señales fisiológicas requeridas por cada investigación. El algoritmo del trabajo actual trabaja con 2 señales fisiológicas, electrocardiograma y respuesta galvánica de la piel, con las cuales se logró alcanzar una precisión del 81.8 %. Durante [35] se implementaron las mismas señales fisiológicas y base de datos, pero se consiguió una menor precisión de clasificación. Una de las diferencias destacables entre el algoritmo propuesto y el desarrollado durante [35] es que durante

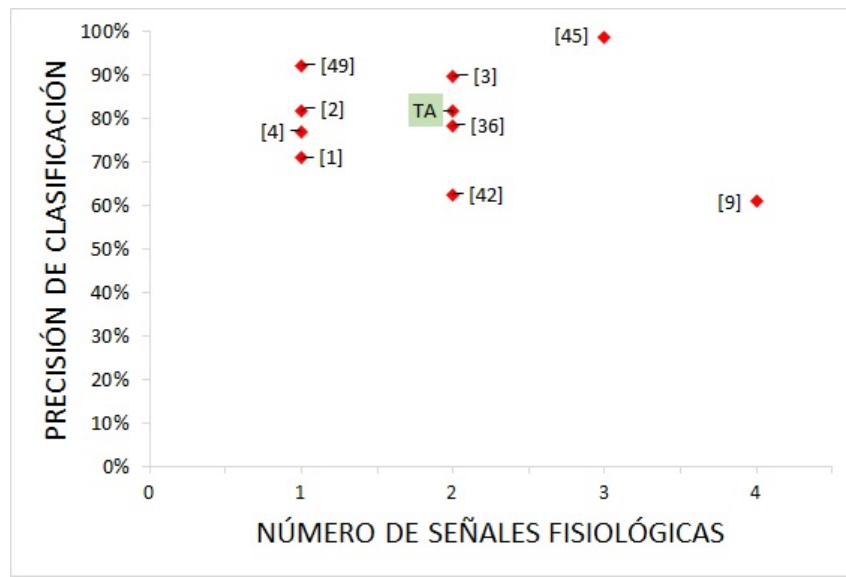


Figura 7.2: Figura de mérito para la comparación de precisión y señales fisiológicas.

este trabajo de tesis se utilizaron variables extraídas del dominio de la frecuencia y se implementaron los parámetros de Hjorth para el análisis de las señales GSR, mientras que en [35] se limitaron a atributos extraídos del dominio del tiempo.

Comparación entre precisión y atributos

Otro aspecto a tomar en cuenta a la hora de seleccionar un algoritmo para la detección de ansiedad es el número de atributos necesarios para el correcto funcionamiento del mismo. Un mayor número de atributos, requiere una mayor capacidad computacional y el tiempo de ejecución del programa aumentaría dependiendo de la complejidad de los mismos, lo que complicaría una aplicación de análisis de señales en tiempo real, además, aumentaría los requerimientos de la unidad de procesamiento en caso de querer hacer una implementación con un dispositivo vestible.

En la Figura 7.3 se muestra la figura de mérito en la que se comparan las precisiones alcanzadas en investigaciones previas y el trabajo actual (ubicadas en el eje Y), con su respectivo número de atributos (ubicados en el eje X). Durante el trabajo actual se utilizaron 9 atributos en total para la detección de ansiedad. En la figura de mérito se puede observar cómo afecta la cantidad de atributos a la precisión obtenida. En la investigación [1] se hizo uso únicamente de 3 atributos extraídos de la variabilidad de la frecuencia cardíaca, y se logró un 71.1% de precisión, pero solo fue necesaria una señal fisiológica, lo que podría reducir considerablemente la cantidad de equipo necesario para

llevar a cabo la implementación del algoritmo.

En la Figura 7.2 se mostraba que la investigación [49] requería únicamente de una señal fisiológica para alcanzar una destacable precisión de clasificación del 92.3%, pero en la Figura 7.3 se puede observar que esta investigación fue la que necesitó de un mayor número de atributos para su funcionamiento, llegando a 15 atributos necesarios.

Entonces es importante tener en cuenta la cantidad de señales fisiológicas y atributos necesarios para el funcionamiento del algoritmo de detección de ansiedad, ya que se pueden alcanzar precisiones altas implementando una gran cantidad de señales fisiológicas, pero hay que tomar en cuenta que el sistema de adquisición y procesamiento se robustecerá considerablemente. El trabajo actual cuenta un número balanceado tanto de señales, como de atributos, requiriendo únicamente 2 señales fisiológicas y 9 atributos, y alcanzó una destacable precisión de clasificación del 81.8%, lo que lo hace un fuerte candidato para implementaciones para la detección de ansiedad.

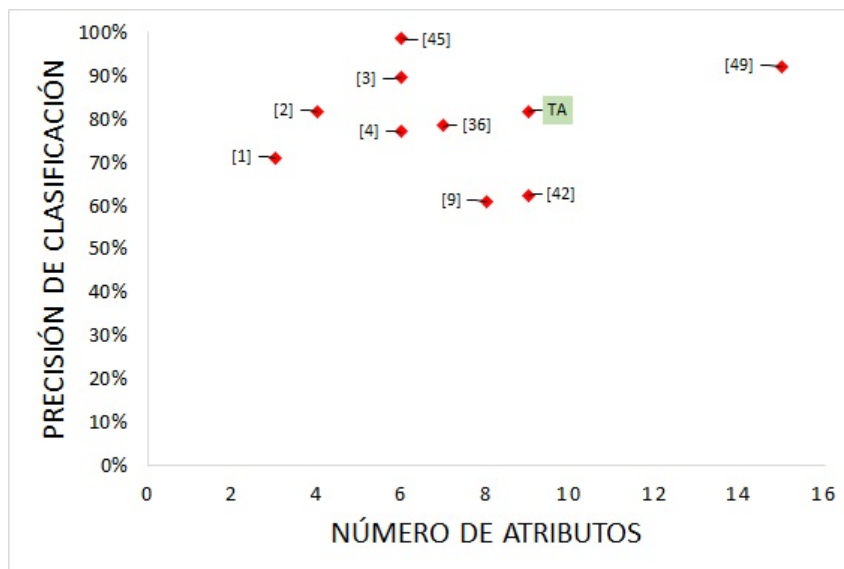


Figura 7.3: Figura de mérito para la comparación de precisión y atributos necesarios.

Conclusiones

Este trabajo fue desarrollado para contribuir en la detección de eventos de ansiedad brindando información objetiva por medio de variables cuantitativas que apoyen en el tratamiento de pacientes que sufran de este tipo de padecimientos.

El objetivo planteado para combatir la problemática seleccionada fue la implementación de algoritmos de clasificación basados en aprendizaje automático para desarrollar un algoritmo computacional con la capacidad de detectar los eventos de ansiedad de un paciente. Este trabajo comenzó desde el estudio de todos los tipos de ansiedad, seguido por la investigación de los síntomas característicos de estos trastornos en conjunto con las señales fisiológicas que se ven afectadas por estas manifestaciones. Esto permitió la selección de las señales que serían la base de esta investigación; electrocardiograma y respuesta galvánica de la piel.

Una vez seleccionadas las señales fisiológicas, comenzó la caracterización de las mismas para extraer los atributos necesarios para la detección de ansiedad por medio de clasificadores basados en aprendizaje automático. A continuación, se enumeran algunas de las aportaciones que trajo el desarrollo de esta investigación:

- Se ha implementado con éxito el algoritmo de Pan-Tompkins por medio de un programa desarrollado en lenguaje de programación Python para la detección de las ondas R de las señales de electrocardiograma, lo que permitió obtener propiedades de las mismas, como la variabilidad de la frecuencia cardíaca, para caracterizar un evento de ansiedad.
 - Se desarrolló un algoritmo en lenguaje de programación Python para automatizar la detección de las partes fundamentales de las respuestas de conductancia de la piel contenidas en la componente fásica de la respuesta galvánica de la piel.
 - Se realizó la caracterización en el dominio del tiempo, tanto de las señales de electrocardiograma, como para las señales de respuesta galvánica de la piel, en situaciones
-

en que los sujetos sufrían ansiedad y en etapas de reposo con el objetivo de hacer la comparación entre señales.

- Se realizó la caracterización en el dominio del tiempo, tanto de las señales de electrocardiograma, como para las señales de respuesta galvánica de la piel, en situaciones de ansiedad y etapas de reposo con el objetivo de hacer la comparación entre señales con y sin ansiedad.
- Se realizó la caracterización en el dominio de la frecuencia de las señales fisiológicas para proponer atributos innovadores que permitan cuantificar eventos de ansiedad por medio de un análisis espectral.
- Se comparó el desempeño de distintos algoritmos de clasificación basados en aprendizaje automático: bosques aleatorios, maquina de vectores de soporte, K-Vecinos más cercanos y redes neuronales. Se utilizaron en conjunto con un algoritmo selector de atributos óptimos y un método de validación cruzada de 5 iteraciones.
- Se propone un método de clasificación basado en el algoritmo de bosques aleatorios que requiere un total de 9 atributos: FC, RCDSP, DERR, PotenciaRR, PotenciaECG, RCPRE, Actividad, Complejidad y PotenciaMBF. El método propuesto alcanzó una destacable precisión de clasificación del 81.8 %.
- El algoritmo de clasificación propuesto combina atributos de las señales ECG y GSR, lo que permitió aumentar la precisión de clasificación que se podría alcanzar utilizando solamente una de las señales fisiológicas.
- Se propone una figura de mérito en la que se compara la precisión alcanzada, con el número de señales fisiológicas requeridas por algoritmos propuestos en investigaciones previas y el trabajo actual. En esta se declaran los requerimientos de aumentar el número de señales fisiológicas.
- Se propone una metodología de comparación del desempeño de algoritmos de clasificación para la detección de ansiedad mediante la implementación de figuras de mérito, tomando en cuenta características como la precisión obtenida, señales fisiológicas y atributos necesarios para su implementación.

El enfoque del trabajo en pacientes con trastorno de fobia específica hacia las arañas, no limita la implementación de este algoritmo en pacientes con otro tipo de trastorno de ansiedad. Como se mencionó en los preliminares de investigación, los trastornos de

ansiedad se caracterizan por tener a la ansiedad como el síntoma principal del paciente, y son considerados una familia de trastornos mentales distintos, pero relacionados entre sí por la aparición de eventos de ansiedad. El hecho de que el algoritmo propuesto en este trabajo se enfoque únicamente en la detección de eventos de ansiedad, lo hace útil para la detección de este sentimiento en pacientes con cualquier otro tipo de trastorno mental que pertenezca a la familia de los trastornos de ansiedad.

Para mejorar los resultados obtenidos se sugiere la elaboración de una base de datos balanceada, es decir, que cuente con las misma cantidad de muestras con y sin ansiedad. Esto aseguraría que el entrenamiento del algoritmo se realice de manera balanceada y aprenda a identificar correctamente ambas clases.

Este trabajo puede ser el punto de partida para futuras investigaciones, ya que se puede utilizar el algoritmo sugerido para realizar una implementación con un dispositivo vestible que cuente con los sensores necesarios para la recolección de las señales fisiológicas necesarias, y con las herramientas de procesamiento y caracterización aquí expuestas, calcular los atributos necesarios para la aplicación del algoritmo de bosques aleatorios y detectar en tiempo real los eventos de ansiedad que sufre una persona durante su día, lo que brindaría datos objetivos a los profesionales de la salud y brindaría un apoyo en el diagnóstico y tratamiento de pacientes.

Bibliografía

- [1] M. A. Adheena, N. Sindhu, and S. Jerritta. Physiological Detection of Anxiety. *2018 International Conference on Circuits and Systems in Digital Enterprise Technology (ICCSDET)*, 2018.
 - [2] Jiapu Pan and Willis J. Tompkins. A Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering*, 1985.
 - [3] Wanhui Wen, Guangyuan Liu, Zhi-Hong Mao, Wenjin Huang, Xu Zhang, Hui Hu, Jiemin Yang, and Wenyan Jia. Toward Constructing a Real-time Social Anxiety Evaluation System: Exploring Effective Heart Rate Features. *IEEE Transactions on Affective Computing*, 2020.
 - [4] Frank R. Ihming, Antonio Gogeochea H., Frank Neurohr-Parakenings, Sarah K. Schäfer, Johanna Lass-Hennemann, and Michael Tanja. On-line Anxiety Level Detection from Biosignals: Machine Learning Based on a Randomized Controlled Trial with Spider Fearful Individuals. *PLoS ONE*, 6 2020.
 - [5] Adrian Vulpe-Grigorasi and Ovidiu Grigore. A Neural Network Approach for Anxiety Detection Based on ECG. *2021 International Conference on e-Health and Bioengineering (EHB)*, 2021.
 - [6] Coordinación de Comunicación Social del Senado de la República. 14.3% de la población mexicana padece trastornos de ansiedad. url <http://comunicacion.senado.gob.mx/index.php/informacion/boletines/39699-14-3-de-la-poblacion-mexicana-padece-trastornos-de-ansiedad.html>, 12 2017. Accedido 10-11-2021.
 - [7] Diario ContraRéplica. 14.3% de los mexicanos sufren de ataques de ansiedad. url <https://www.contrareplica.mx/nota-143-de-los-mexicanos-sufren-de-ataques-de-ansiedad202010338>, 3 2020. Accedido 10-09-2021.
-

-
- [8] Benjamin James Sadock, Virginia Alcott Sadock, and Pedro Ruiz. *Sinópsis de Psiquiatría, Ciencias de la Conducta/Psiquiatría Clínica*. Wolters Kluwer, 11 edition, 2015.
- [9] Pedro Moreno. *Superar la Ansiedad y el Miedo*. DESCLÉE DE BROUWER, 9 edition, 2011.
- [10] Carlos Alberto Gutiérrez Gómez. Reconocimiento de Niveles de Ansiedad a Partir del Análisis Multimodal y Técnicas de Aprendizaje de Máquina en Señales Fisiológicas, 2014.
- [11] Joseph D. Bronzino, editor. *The Biomedical Engineering Handbook, Medical Devices and Systems*. Taylor and Francis Group, 3 edition, 2006.
- [12] American Psychiatric Association. *Manual Diagnóstico y Estadístico de los Trastornos Mentales (DSM-V)*. Editorial Médica Panamericana, 5 edition, 2014.
- [13] Dr. Dale Dubin. *Electrocardiografía Práctica*. Interamericana, 3 edition, 1986.
- [14] Manual MSD. ECG: Lectura de las Ondas. url <https://www.msdmanuals.com/es-co/hogar/multimedia/figure/ecg-lectura-de-las-ondas>.
- [15] My EKG. Intervalos y Segmentos del Electrocardiograma. url <https://www.my-ekg.com/generalidades-ekg/intervalos-segmentos-ekg.html>, 1 2022.
- [16] My EKG. Ritmo Sinusal Normal, Cómo Reconocerlo en un Electrocardiograma. url <https://www.my-ekg.com/trucos-consejos-ekg/ritmo-sinusal-diagnostico.html>, 1 2022.
- [17] My EKG. Ritmo Cardíaco. url <https://www.my-ekg.com/como-leer-ekg/ritmo-cardiaco.html>, 1 2022.
- [18] Ana Gabriela Mojica-Londoño. Actividad Electrodermica Aplicada a la Psicología: Análisis Bibliométrico. *Revista Mexicana de Neurociencia*, 8 2017.
- [19] Montserrat Aiger Vallés. Patrones Electrodermicos de la Actividad Grupal, 2013.
- [20] M.A. Callejas, R. Grimalt, and E. Cladellas. Actualización en Hiperhidrosis. *Actas Dermo-Sifilográficas*, 2009.
- [21] Sarah K. Schäfer, Frank R. Ihmig, Karen A. Lara H., Frank Neurohr, Stephen Kiefer, Marlene Staginnus, Johanna Lass-Hennemann, and Tanja Michael. Effects
-

of Heart Rate Variability Biofeedback During Exposure to Fear-provoking Stimuli within Spider-fearful Individuals: Study Protocol for Randomized Controlled Trial. *Trials*, 4 2018.

- [22] PhysioNet. Physionet data bank. url <https://physionet.org/about/>.
- [23] V.C. Goessl, J.E. Curtiss, and S.G. Hofmann. The Effect of Heart Rate Variability Biofeedback Training on Stress and Anxiety: a Meta-analysis. *Psychol Med*, 2017.
- [24] Plux. url <https://www.pluxbiosignals.com/pages/about>.
- [25] Scosche Industries. url <https://www.scosche.com/>.
- [26] L.G. Öst. One Session Treatment for Specific Phobias. *Behav Res Ther*, 1989.
- [27] MathWorks. url <https://es.mathworks.com/products/matlab.html>.
- [28] Task Force of The European Society of Cardiology, The North American Society of Pacing, and Electrophysiology. Heart Rate Variability. *European Heart Journal*, 1996.
- [29] John A. Chalmers, Daniel S. Quintana, Maree J. Anne Abbott, and Andrew H. Kemp. Anxiety Disorders are Associated with Reduced Heart Rate Variability: A Meta-analysis. *Frontiers in psychiatry*, 2014.
- [30] Judith Held, Andreea Vişlă, Christine Wolfer, Nadine Messerli-Bürgy, and Christoph Flückiger. Heart Rate Variability Change During a Stressful Cognitive Task in Individuals with Anxiety and Control Participants. *BMC Psychology*, 2021.
- [31] Jainendra Shukla, Miguel Barreda-Ángeles, Joan Oliver, G.C. Nandi, and Domènec Puig. Feature Extraction and Selection for Emotion Recognition from Electrodermal Activity. *IEEE Transactions on Affective Computing*, 2021.
- [32] Jonghwa Kim and Elisabeth André. Emotion Recognition Based on Physiological Changes in Music Listening. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008.
- [33] Jennifer A. Healey and Rosalind W. Picard. Detecting Stress During Real-World Driving Tasks Using Physiological Sensors. *IEEE Transactions on Intelligent Transportation Systems*, 2005.
-

-
- [34] Jason J. Braithwaite, Derrick G. Watson, Robert Jones, and Mickey Rowe. A brief guide for analysing electrodermal activity. url <https://www.biopac.com/wp-content/uploads/EDA-SCR-Analysis.pdf>, 2013.
- [35] Roger Selzler, Adrian D. C. Chan, and James R. Green. Impact of Subject-specific Training Data in Anxiety Level Classification from Physiologic Data. *2021 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, 2021.
- [36] Bo. Hjorth. EEG analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, 1970.
- [37] Petre Stoica and Randolph Moses. *Spectral Analysis of Signals*. Pearson Prentice Hall, 2005.
- [38] Farah Muhammad and Saad Al-Ahmadi. Human State Anxiety Classification Framework Using EEG Signals in Response to Exposure Therapy. *PLoS ONE*, 2022.
- [39] Han Wen Guo, Yu Shun Huang, Jen Chien Chien, and Jiann Shing Shieh. Short-term Analysis of Heart Rate Variability for Emotion Recognition via Wearable ECG Device. *2015 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS)*, 2015.
- [40] Yoshira Shimomura, Takumi Yoda, Koji Sugiura, Akinori Horiguchi, Koichi Iwanaga, and Tetsuo Katsuura. Use of Frequency Domain Analysis of Skin Conductance for Evaluation of Mental Workload. *Physiological Anthropology*, 2008.
- [41] Hugo F. Posada-Quintero, John P. Florian, Alvaro D. Orjuela-Cañón, Tomas Aljama-Corrales, Sonia Charleston-Villalobos, and Ki H. Chon. Power Spectral Analysis of Electrodermal Activity for Sympathetic Function Assessment. *Annals of Biomedical Engineering*, 2016.
- [42] Luis G. Serrano. *Grokking Machine Learning*. Manning Publications Co., 1 edition, 2021.
- [43] Shan Suthaharan. *Machine Learning Models and Algorithms for Big Data Classification*, volume 36. Springer, 2016.
- [44] Antonio Mucherino, Petraq J. Papajorgji, and Panos M. Pardalos. *Data Mining in Agriculture*, volume 34. Springer, 2009.
-

- [45] Jorge Rodríguez Arce, Liliana Lara Flores, Otniel Portillo Rodríguez, and Rigoberto Martínez Méndez. Towards an Anxiety and Stress Recognition System for Academic Environments Based on Physiological Features. *Computer Methods and Programs in Biomedicine*, 2020.
 - [46] Yali Zheng, Tracy C. H. Wong, Billy H. K. Leung, and Carmen C. Y. Poon. Unobtrusive and Multimodal Wearable Sensing to Quantify Anxiety. *IEEE Sensors Journal*, 2016.
 - [47] Ian Witten, Eibe Frank, and Mark A. Hall. *Data Mining Practical Machine Learning Tools and Techniques*. Elsevier Inc., 3 edition, 2011.
 - [48] Nathalie Japkowicz and Shaju Stephen. The Class Imbalance Problem: A Systematic Study. *IOS Press*, 2002.
 - [49] H. Haritha, Negi Swati, R. Sarath Menon, Anand Kumar, and C. Santosh Kumar. Automating Anxiety Detection using Respiratory Signals Analysis. *2017 IEEE Region 10 Symposium (TENSYMP)*, 2017.
 - [50] Johan van der Tang, Dieter Kasperkovitz, and van Roermund. *High-Frequency Oscillator Design for Integrated Transceivers*, volume 748. Springer Science and Business Media, 2003.
-



IEEE
ETCM
2022

Ecuador Technical Chapters Meeting



CERTIFICATE

This document certifies that:

Alfonso Andrade González, María Monserrat Morín Castillo, Alina Santillán Guzmán
and Amparo Dora Palomino Merino

presented the paper entitled::

Threshold-based anxiety detection algorithm through ECG and GSR signals

at the IEEE Ecuador Technical Chapters Meeting (ETCM 2022)

Awarded in Quito - Ecuador, October 11th-14th , 2022

Co-organized with




Mónica Huerta, PhD

ETCM 2022 General Chair
IEEE Ecuador Section Chair



Paulo Leica, PhD
ETCM 2022 General Chair
Escuela Politécnica Nacional




Advancing Technology
for Humanity

Threshold-based anxiety detection algorithm through ECG and GSR signals

Alfonso Andrade González

Facultad de Ciencias de la Electrónica
Benemérita Universidad Autónoma de Puebla
Puebla, México
alfonso.andradeg@alumno.buap.mx

María Monserrat Morín Castillo

Facultad de Ciencias de la Electrónica
Benemérita Universidad Autónoma de Puebla
Puebla, México
maria.morin@correo.buap.mx

Alina Santillán Guzmán

Facultad de Electrónica
Universidad Popular Autónoma del Estado de Puebla
Puebla, México
alina.santillan@upaep.mx

Amparo Dora Palomino Merino

Facultad de Ciencias de la Electrónica
Benemérita Universidad Autónoma de Puebla
Puebla, México
amparo.palomino@correo.buap.mx

Abstract—This paper shows an anxiety detection algorithm, based on thresholds. The physiological signals used in this case are the electrocardiographic signal (ECG) and the galvanic skin response (GSR). Real ECG and GSR signals are used from 55 patients suffering from anxiety caused by arachnophobia. They were exposed to 16 clips with spider images. Those signals were taken from a Physionet database. From a total of 880 clips, the proposed algorithm has been able to detect anxiety events in the 67% of the cases. Moreover, in 93% of the patients, the algorithm has correctly detected anxiety when at least in one of the clips they suffered anxiety.

Keywords—Anxiety detection, Physiological signals, Anxiety characterization, Specific phobia

I. INTRODUCTION

Anxiety is a common biological response that can be seen as a signal that alerts when danger is close, which allows taking preventive actions. This is a normal and necessary feeling; the problem comes when this signal works improperly and the warning occurs even if there is not apparently danger. In this situation, an anxiety disorder may have been detected. Anxiety is considered to be a family of different mental diseases, but directly related, which include [1]: panic disorder, agoraphobia, specific phobia, social anxiety disorder and generalized anxiety disorder. Relation between these mental disorders is the increase of anxiety levels. Most common symptoms for anxiety disorders as described in [1] are: epigastric pain, diarrhea, hyperhidrosis, hyperreflexia, concern, mydriasis, heart palpitations, paresthesia, pollakiuria, syncope, tachycardia, tremors and vertigo. Abnormal anxiety levels can be detected by monitoring physiological signals that are affected by the symptoms previously mentioned.

The importance of detecting anxiety levels on people has been increasing due to the rising behavior that anxiety disorder cases have had on the past few years. According to the Mexico's Senate [2], 14.3% of Mexican population suffers from generalized anxiety disorder, it is the second most common mental disease, followed by depression and addictions. In

[3], an estimation was made for people who were diagnosed with an anxiety disorder based on the Diagnostical Statistical Manual IV (DSM-IV) in 21 countries to find the proportion of patients who perceived a need for treatment; received any treatment; and possibly received appropriate treatment. As a result, out of 51547 respondents, 9.8% suffered a 12-month anxiety disorder according to DSM-IV, where 27.6% of them were receiving any treatment, and only 9.8% were receiving possibly appropriate treatment. From the total 12-month anxiety disorder patients, only 43.3% perceived a need for care. One of the reasons for the lack of treatments is the similarity of the symptoms that anxiety disorders can have as compared with other diseases. A useful solution to improve anxiety disorders recognition can be the implementation of technology to detect anxiety events on patients to prove if their symptoms are caused by anxiety or any other problems.

There have been many investigations focused on detecting anxiety through physiological signals like the one showed in [4], which its main objective was to detect anxiety levels through electrocardiogram (ECG), galvanic skin response (GSR) and respiration frequency signals using different machine learning techniques and validating which of these has a better performance in detecting anxiety levels through statistical variables of the studied biosignals.

A different research is presented in [5], where the analyzed biosignals were electroencephalographic (EEG), and their main objective was to identify multiple anxiety levels using EEG frequency-domain and time-domain analysis and recognizing the ability that different features such as different EEG bands or brain locations can be used to detect different anxiety levels.

Respiratory signals have also been used to detect anxiety, as in [6], where an anxiety detection system was developed using this kind of signals as its main input. Analyzing signals in time and frequency domain, statistical features were calculated to be used on a support vector machine (SVM)

backend classifier along with machine learning algorithms to develop an automated system that could be used with mobile phones and a low cost sensor for acquiring and monitoring respiratory signals such as respiratory rate (RR) and breath-breath variability (BBV) so the patient can take preventive actions when high anxiety levels are detected. In this case, only the detection system is developed, they did not focus on developing a wearable device that acquires and processes the signals on its own.

Efforts on developing wearable devices to detect anxiety levels have been made, as in [7], where they focused on the design of a wearable device to monitor physiological signals, which performs data analysis to identify primary stages of physiological stress and evaluate the patient's current stress levels. Constant exposure to high stress levels could lead to mental disorder such as depression and anxiety. Hardware design of the wearable device consisted of miniaturized, low-power, and low-cost sensors, which monitored heart rate, body temperature and heart rate waveform. Along with the hardware design, software design must be developed, which consisted of a physiological stress detection algorithm for decision-making based on multiple parameters extracted from physiological signals.

The main objective of this work is to present a threshold-based algorithm to detect anxiety caused by arachnophobia, by analyzing ECG and GSR signals, through some of its most common symptoms, tachycardia and hyperhidrosis.

Normal heart rate is set at a range between 60 to 100 beats per minute and is produced by the sinoatrial node (SAN). A heart rate value higher than 100 beats per minute is considered as tachycardia, while a heart rate value lower than 60 beats per minute is known as bradycardia. To detect these changes in the heart activity, ECG signals must be monitored. The electrocardiogram is a register used to visualize and analyze all stages of heart stimulation. These stages are represented as different waves in the ECG signal, which are: P wave, QRS complex and T wave. Every heartbeat register in the ECG is represented by these 3 waves. This allows the calculation of the heart rate through ECG signals [8]. An easy and computable way is done by counting each of the R waves contained in a 1-minute-long ECG. The R waves are in every QRS complex, and they are characterized for being the highest amplitude waves in the signal.

Another common symptom on anxiety disorder patients is hyperhidrosis. This symptom is characterized by the excessive amount of sweat secreted by the body sweat glands on a specific area, even if the patient is resting and on a low temperature area [9]. Sweat produces changes on skin permeability, which can be used to detect this symptom through GSR signals. The GSR is a bioimpedance signal that measures skin resistance, which is proportional to skin permeability. Changes in the GSR response are correlated with the secretion of the sweat glands. The GSR signals result on very useful tools due to its direct relation with cognition and emotional changes which are also related with patient's autonomic nervous system [10].

II. METHODOLOGY

As mentioned before, ECG and GSR signals were used in this work to detect anxiety events. They were analyzed and characterized in order to develop an anxiety detection algorithm based on the extracted information from the studied signals. Patients should be feeling anxiety while their signals are being acquired. In the next subsections an explanation on the signal processing is given.

A. Database information

In order to develop the anxiety algorithm detection, a database has been used. This database contains ECG and GSR signals from patients diagnosed with anxiety caused by arachnophobia. The database was obtained from the website "Physionet". This web site offers a great amount of clinical and physiological signals for educational and biomedical research purposes. The chosen database was developed during the research presented in [11]. Its main goal was to validate the usefulness of exposure therapy techniques to reduce specific phobia anxiety disorders. In that case, they used 80 spider fearful patients, 20 of them used a heart rate variability technique to minimize anxiety effects, and hence they were not considered for this work. Moreover, 5 participants were excluded due to noisy ECG signals. Therefore, only 55 patients data were studied. Exclusion criteria were: presence of any other mental disorder and suffering from any cardiovascular disease. All patients watched 16 one-minute long clips, extracted from TV documentaries where detailed spiders images were shown. During the exposure to the clips, ECG, GSR and breathing frequency signals were acquired using the "Bitalino" device, but only the ECG and GSR were used in this work. Data were saved as text documents using the "Biofeedback system", which was developed by the research team of [10]. The sampling rate for the ECG and GSR was set at 100 Hz.

B. Electrocardiographic Signal Processing

Processing was made using MATLAB software. The first step consisted of extracting the data from the text files by separating the raw signals with its corresponding clip, using the trigger times document which gives the start and end times of the physiological signal acquisition per clip. At the end of this stage there were 16 amplitude vectors and 16 time vectors per patient.

Once the signals were extracted, the next stage was to transform the ECG signal into a completely positive one using the following condition:

$$V_{ECG}(k) < 0 \rightarrow V_{ECG}(k) = 0 \quad (1)$$

where $V_{ECG}(k)$ is the current ECG amplitude value of the signal at time k , so (1) turns the negative amplitude values into 0 and that leaves a signal only with positive values. Then, it was necessary to count the peaks of the signal. A peak is considered to be a point in the signal that has a higher amplitude than the point before and the point after it.

This could be seen as a triangle with its three vertices. This condition can be described with the following relation:

$$\begin{aligned} V_{ECG}(k) &> V_{ECG}(k+1) \\ V_{ECG}(k) &> V_{ECG}(k-1) \end{aligned} \quad (2)$$

where $V_{ECG}(k)$ was considered as a signal peak if its amplitude value was higher than its previous value $V_{ECG}(k-1)$ and the next value $V_{ECG}(k+1)$. Then, the highest amplitude value of the signal had been found. In other words, the number of R waves should be detected and computed by identifying every peak on the signal that fulfilled the next conditions:

$$V_{PEAK}(k) > V_{HIGH}/2 \rightarrow V_{PEAK} = R\ wave \quad (3)$$

where V_{HIGH} is the highest value in the ECG signal previously found and $V_{PEAK}(k)$ is the current analyzed signal peak. By computing the number of all R waves contained in one minute of the ECG signal the heart rate can be estimated during every clip. Noise provoked peaks are detected too, but they are excluded because they can not fulfill the conditions established by equation (3).

C. Galvanic Skin Response Processing

GSR processing begins with the extraction of time and amplitude from text files and separating data by clips with their corresponding triggering times. As can be seen on Fig. 1, a GSR signal from one of the subjects during the exposure of clip 13 is depicted. As observed, there were some sensor resolution problems that were causing distortion on the amplitude changes on the signals. To solve this problem the filters proposed in [4] were used: A second order low-pass Butterworth filter with a cutoff frequency at 1.5 Hz, and a second order high-pass Butterworth filter with a cutoff frequency at 0.05 Hz. Those filters were applied to all GSR signals. Once they were filtered, the characterization was performed.

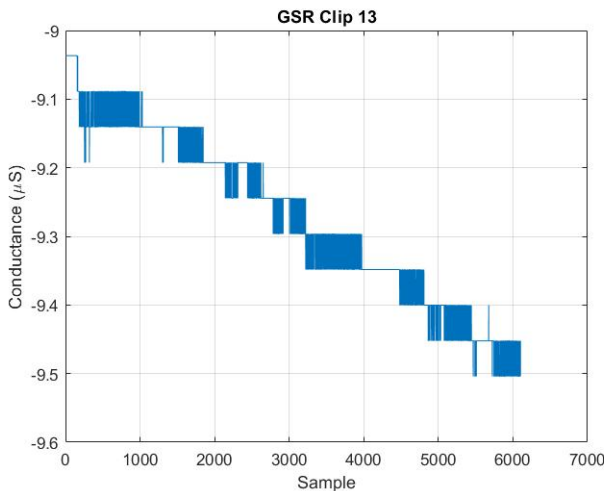


Fig. 1. Noisy Galvanic Skin Response Signal Example.

D. Physiological Signal Characterization

To see how physiological signals behave during an anxiety event during each clip, statistical values were obtained. There were 880 physiological signals, corresponding to the 55 participants of the studied research. Statistical variables considered were: mean value, mode, median, standard deviation, relative frequencies, and probability. Physiological information such as heart rate and maximum GSR per clip was extracted using MATLAB.

These statistical variables were used to understand the way anxiety may physically affect the patients and be able to set thresholds for each physiological signal, assuming (based on the database information) that every patient is suffering from anxiety due to the exposure to their specific phobia.

E. Anxiety Detection Algorithm Design

The flowchart for the anxiety detection algorithm is shown in Fig. 2. The flowchart was used as a guide to code (in MATLAB) the algorithm and visualize the flow of information inside this process. As can be observed in Fig. 2, the algorithm was structured in 5 different stages: Stage 1 consisted of data extraction from text files to MATLAB to begin data manipulation and processing. In stage 2, data processing was performed, by applying the filters explained before to clean the noisy signals. Stage 3 consisted of computing the heart rate and maximum GSR value per clip for every patient. In stage 4, an adjustment of the heart rate and maximum GSR value thresholds was performed to compare them with every heart rate and maximum GSR value to determine in which clips the patient presented an anxiety event. The threshold for the heart rate (Threshold HR) was set at 82 beats per minute by taking the average of all heart rates (HR) from all patients and clips. The threshold for the GSR (Threshold Max GSR) was set at $1.079\mu S$ by taking the average of the maximum values of all patients and clips. If the heart rate is greater than Threshold HR or the maximum value of GSR is greater than Threshold Max GSR, then an anxiety event is detected. Finally, in stage 5, a text file where the heart rate, the maximum GSR value and the detected anxiety events were observed is generated for every patient and organized in a table format.

III. RESULTS

A. Electrocardiographic Signal

Fig. 3 shows how ECG signals have just positive amplitudes. The red circles corresponds to every detected peak on the signal. As can be seen, not only R waves are detected as peaks, but also others smaller peaks that need to be excluded from the counting process in order to avoid a misleading result. For that reason, the highest amplitude of the signal was detected as explained before, and then used to set a condition. Every peak detected above the green line was considered as an R wave. The green line was calculated by means of (1).

B. Galvanic Skin Response Signal

The signal showed in Fig. 4 corresponds to the GSR signal of one of the subjects from clip 13, the same as in Fig. 1, but

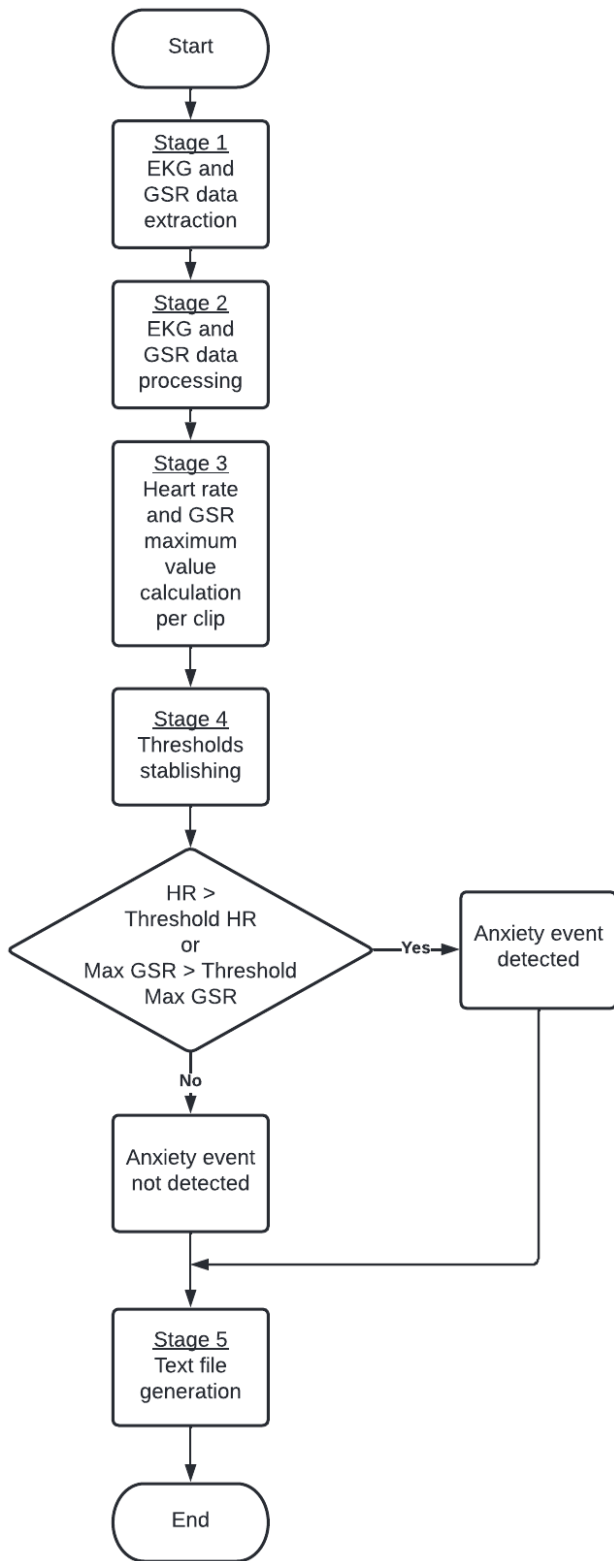


Fig. 2. Anxiety Detection Algorithm Flowchart.

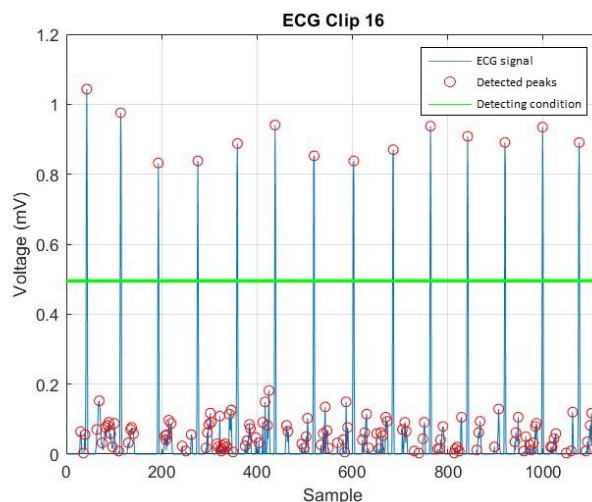


Fig. 3. Example of a processed ECG signal.

this time after applying a low-pass and a high-pass Butterworth filters. As can be seen, the signal has been cleaned. These filters were applied on every GSR signal extracted from the database, and the cleaned signals were used for the detection algorithm.

C. Physiological Signal Characterization Analysis

Table I shows a summarized information about heart rate descriptive statistics. The mean value obtained from all 880 data was about 83 beats per minute, which is different from the median value of 81 beats per minute. This means that the data distribution is not completely centered. Standard deviation is 11 beats per minute, which means that, on average, the difference between every heart rate and the mean value is 11 beats per minute. The mode of this data had a value of 75 beats per minute that represents 6% probability of occurrence. This analysis gives a chance to prove if anxiety events are followed by tachycardia symptoms, but as shown in Table 1, just 72 cases have tachycardia's heart rate range, and this represents only 8% probability of occurrence. On this characterization it was also proved that Bradycardia (heart rate lower than 60 beats per minute), had 0% probability of occurrence approximately in this experiment.

TABLE I
HEART RATE DESCRIPTIVE STATISTICS

Heart Rate Descriptive Statistics			
Statistical variable	Value	Statistical variable	Value
Mean value (bpm)	82.7579	Relative frequency of Bradycardia	0.00113
Standard deviation (bpm)	10.7569	Bradycardia probability	0%
Mode (bpm)	75	Maximum heart rate value (bpm)	118
Mode relative frequency	0.0568	Maximum value appearances	1
Mode probability	6%	Relative frequency of the maximum	0.0011
Median (bpm)	81	Maximum value probability	0%
ECGs with Tachycardia	72	Minimum heart rate value (bpm)	53
Relative frequency of Tachycardia	0.0818	Minimum value appearances	1
Tachycardia probability	8%	Relative frequency of the minimum	0.0011
ECGs with Bradycardia	1	Minimum value probability	0%

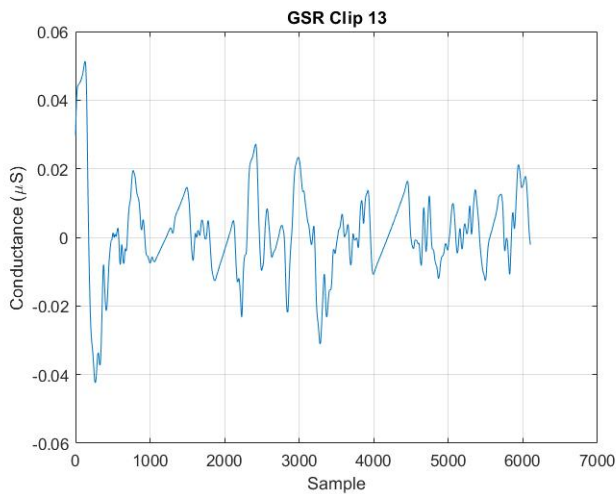


Fig. 4. Clean Galvanic Skin Response Signal Example.

Table II shows the descriptive statistics of the GSR signals. In this case, only the mean value of all (i.e. 880) maximum GSR values, the mean of all minimum values and the mean value of the standard deviations of all GSR values are written. The mode was not found due to the independent behavior that GSR has. Even though standard deviation is not too high, GSR is similar but never the same among patients. As mentioned in the previous section, Maximum GSR per clip was selected for the detection algorithm due to the proportional behavior it has with the heart rate, i.e. if anxiety increases, so these signals.

Based on this information, the anxiety detection algorithm has been designed. This first approximation's efficiency was tested by measuring its precision to identify anxiety level of every participant. As already mentioned, thresholds values were taken from the average of the heart rate and maximum GSR. As mentioned above, the Threshold HR was set to 82 beats per minute, and Threshold max GSR value was set to $1.079\mu S$. Detection is made using an "OR" function between both thresholds, considering anxiety's relation with autonomous nervous system and the fact that anxiety affect different on every patient. There were cases where tachycardia was detected, but the subject had a low GSR, or vice versa.

D. Anxiety Detection Algorithm Results

Out of 880 clips, using a thresholds-based detection algorithm, anxiety events were detected in 589 clips, which corresponds to 67% of the clips. According to the thresholds-based anxiety detection algorithm, 51 out of 55 patients were identified as they suffered at least one anxiety event during exposure session. Only 4 patients did not suffer any anxiety event during the complete session. This means that the algorithm's efficiency was 93%. There were many cases where patients suffered from anxiety in one of the clips, but there were other cases that presented anxiety during the complete exposure session. This could be a clear indicator that there exists different anxiety levels.

TABLE II
GALVANIC SKIN RESPONSE DESCRIPTIVE STATISTICS

Galvanic Skin Response Descriptive Statistics	
Statistical variable	Value
Mean of maximum values (μS)	1.07933
Mean of minimum values (μS)	-0.8074
Mean of standard deviation (μS)	0.31307

IV. DISCUSSION

Participants of the experiment suffered from specific phobia to spiders, so it is assumed that, during exposure session, they suffered from anxiety. It was observed anxiety affects differently in every patient, some of them experienced changes on their GSR, while others increase their heart rate. To improve algorithm's behavior, adaptive thresholds values should be set considering patient's baseline for every signal to detect the way anxiety particularly affects the patient physiologically.

Algorithms based on machine learning techniques have shown a great behavior detecting anxious and non-anxious signals, as in [12], where support vector machine (SVM) and Kalman's filters showed an accuracy of 71.1% and 69.35% respectively using features extracted from R-R intervals in ECG signals. An important difference between SVM and Kalman's filter is that SVM needs a training stage and a testing stage, while Kalman's filter only require a testing stage, consequently, training stage seems to improve the classifier's accuracy to detect anxiety. Threshold-based algorithm developed during this research does not use a training stage, in fact, thresholds were set using the average values calculated from the database during the characterization stage. Comparison between psychological metrics and the acquired signals is fundamental in the training stages to ensure high detection accuracy. However, they were not used in the proposed work because it is assumed that the patients are suffering from anxiety due to the exposure to their specific phobia.

V. CONCLUSION

A threshold-based anxiety detection algorithm has been proposed, based on ECG and GSR signals. The mean value of the heart rate and the average of the maximum GSR values were used as thresholds. These values were taken from the analysis of the descriptive statistics. Moreover, by analyzing the signals at every clip and from every patient the features to be extracted and used for the detection algorithm were obtained. According to the results, in 589 cases out of 880 a correct anxiety detection was performed. This corresponds to the 67%. Furthermore, in 93% of the subjects, at least one anxiety event was detected.

Further research should be focused on detecting anxiety events on real-time by monitoring different physiological signals. There should be necessary an adjustment of thresholds to be able to identify if the physiological signals are changing specifically due to anxiety. Healthy subjects should also be analyzed. In this way, a comparison could be made and differences might be found.

Moreover, using a different detection method, such as machine learning algorithms in order to improve the efficiency may be used in the future.

REFERENCES

- [1] B. J. Sadock, V. A. Sadock and P. Ruiz, Kaplan and Sadock's Synopsis of Psychiatry. Behavioral sciences/clinical Psychiatry, 11th ed., Philadelphia: Wolters Kluwer, 2015.
- [2] Coordinación de Comunicación Social del Senado de la República, "14.3% of mexican population suffers from an anxiety disorder," comunicacion.senado.gob.mx. <http://comunicacion.senado.gob.mx/index.php/informacion/boletines/39699-14-3-de-la-poblacion-mexicana-padece-trastornos-de-ansiedad.html> (accessed Jun. 27, 2022).
- [3] J. Alonso, Z. Liu, S. Evans-Lacko, et al. "Treatment gap for anxiety disorders is global: Results of the World Mental Health Surveys in 21 countries." *Depress Anxiety*, vol. 35, pp. 195–208, Mar. 2018, doi: 10.1002/da.22711
- [4] F. R. Ihming, A. Gogea-coechea, F. Neurohr-Parakenings, S. K. Schäfer, J. Lass-Hennemann, T. Michael, "On-line anxiety level detection from biosignals: Machine learning based on a randomized controlled trial with spider fearful individuals," *PLoS ONE* vol. 15, no. 6, Jun. 2020, doi: 10.1371/journal.pone.0231517
- [5] Z. Li et al., "The Recognition of Multiple Anxiety Levels Based on Electroencephalograph," in *IEEE Transactions on Affective Computing*, vol. 13, no. 1, pp. 519-529, 1 Jan.-March 2022, doi: 10.1109/TAFFC.2019.2936198.
- [6] H. Haritha, S. Negi, R. S. Menon, A. A. Kumar and C. S. Kumar, "Automating anxiety detection using respiratory signal analysis," 2017 IEEE Region 10 Symposium (TENSYP), 2017, pp. 1-5, doi: 10.1109/TENCONSpring.2017.8069995.
- [7] H. Xu, N. Zhang and Q. Liu, "Wearable psychological stress monitoring equipment and data analysis based on a wireless sensor," *Journal of Sensors*, vol. 2022, 2022, doi: <https://doi.org/10.1155/2022/7027086>.
- [8] D. Dubin, *Practical Electrocardiography*, 3rd ed., Spain: Interamericana, 1986.
- [9] M. Connolly and D. D. Berker, "Management of Primary Hyperhidrosis", *American Journal of Clinical Dermatology*, vol. 4, no. 10, pp. 681-697, 2003.
- [10] M. Aiger Vallés, "Group Electrodermal activity patterns," Ph.D. Thesis, Sch. of Social Psychology, Univ. Barcelona, Barcelona, 2013. [Online]. Available: https://www.tdx.cat/bitstream/handle/10803/134062/MAV_TESIS.pdf?sequence=1
- [11] S. K. Schäfer et al., "Effects of heart rate variability biofeedback during exposure to fear-provoking stimuli within spider-fearful individuals: study protocol for randomized controlled trial," *Trials*, vol. 19, no. 1, pp. 184, Mar. 2018.
- [12] A. M.A., S. N. and J. S., "Physiological Detection of Anxiety," 2018 International Conference on Circuits and Systems in Digital Enterprise Technology (ICCSDET), 2018, pp. 1-5, doi: 10.1109/ICCSDET.2018.8821162.