



**UNIVERSIDAD DE CONCEPCIÓN  
FACULTAD DE INGENIERÍA  
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA**



**DETECCIÓN DE SOMNOLENCIA EN CONDUCTORES: ANÁLISIS DE SEÑALES  
FISIOLÓGICAS DURANTE LA SIMULACIÓN DE CONDUCCIÓN**

POR

**Mariana Antonia Rivera Montalba**

Memoria de Título presentada a la Facultad de Ingeniería de la Universidad de Concepción  
para optar al título profesional de Ingeniera Civil Biomédica

Profesor Guía  
Esteban Pino Quiroga

Enero 2025  
Concepción (Chile)

© 2025 Mariana Antonia Rivera Montalba

© 2025 Mariana Antonia Rivera Montalba

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

## **Agradecimientos**

A mi profesor tutor, Esteban Pino, por su guía, conocimientos y dedicación durante el desarrollo de este trabajo, su orientación y retroalimentación.

A mi familia, a mis padres, por su amor incondicional, paciencia, y entregando todo su apoyo, incluso en los momentos más difíciles. A mis hermanos, por su compañía y palabras de ánimo que me impulsaron a seguir adelante.

A mis amigos, quienes han sido un apoyo en los momentos de mayor desafío. Gracias por su compañerismo, sus consejos y por compartir conmigo risas y experiencias que hicieron este proceso mucho más llevadero.

A mi vida, Fernando, la persona más importante en mi universo, por ser mi motivación, por cada gesto de amor, por cada sonrisa que me levantó el ánimo y por estar siempre dispuesto a acompañarme en cada paso de este camino, gracias por ser mi refugio, mi fuerza y mi mayor alegría.

A todos, gracias por ser parte de este viaje.

## Resumen

La somnolencia y el cansancio son factores importantes en los accidentes de tráfico, sobre todo en las carreteras. Estadísticas recientes relacionan sustancialmente los accidentes mortales con el cansancio y la fatiga. En Chile, se reportaron 86,050 accidentes de tráfico en 2022, lo que provocó 1,745 muertes. De estos accidentes, 820 fueron causados por condiciones físicas deficientes como el cansancio y la fatiga. En este contexto, la investigación sobre seguridad vial se enfoca en el desarrollo de métodos automáticos para detectar la somnolencia del conductor y advertirle a tiempo mediante tecnologías de sensores y procesamiento de datos. El propósito de este proyecto es detectar signos iniciales de somnolencia mediante el examen de diversas señales fisiológicas como EEG, ECG, EMG y EDA para desarrollar un algoritmo que pueda identificar relaciones entre estas señales y la somnolencia durante la simulación de conducción.

Durante la etapa inicial de este estudio, se realizó una descripción detallada de los principios fisiológicos y de adquisición de señales relevantes, destacando sus características en relación con los estados de transición de vigilia y somnolencia. Se realizó una revisión del estado actual de conocimiento en el campo, la cual permitió identificar las características clave, modelos y algoritmos exitosos empleados en la detección de somnolencia.

Se utilizaron los datos obtenidos del estudio en simulador de conducción, realizado por Hermes Javier Mora, “Predicción de eventos tempranos de somnolencia mediante un conjunto de datos multifactoriales en conductores de vehículos”, usando los bloques para el estudio de somnolencia (bloque 2 y 3), de donde se obtuvieron señales fisiológicas de EEG, ECG, EMG y EDA. El estudio presente considera las características extraídas de las señales de EEG y ECG.

Se implementaron tres tipos diferentes de modelos de clasificación (redes neuronales, SVM y kernel), de los cuales se obtuvieron rendimientos positivos en la relación de las señales y los estados de somnolencia, destacando el modelo redes neuronales que logró una precisión del 91.23 % en el bloque 3 y 86.76 % en el bloque 2. Respecto a las características utilizadas, se calcularon la potencia de las bandas de frecuencia (delta, theta, alpha y beta), relaciones entre la potencia de las bandas (índice 1:  $P_{\theta}/P_{\alpha}$  ; índice 2:  $P_{\theta} + P_{\alpha}/P_{\alpha} + P_{\beta}$ ; índice 3:  $P_{\theta} + P_{\alpha}/P_{\beta}$ ), frecuencia cardíaca y variabilidad de la frecuencia cardíaca. Los canales frontales y occipitales tienen una contribución significativa en la detección de somnolencia, especialmente en la potencia de las bandas delta y theta, lo cual está alineado con estudios previos. Además, se destaca que los índices 1 y 2, aunque muestran una relación general con la somnolencia en varios

canales, no son tan específicos como el índice 3. Este último demuestra una relación más fuerte y precisa con las etiquetas de somnolencia en canales específicos, lo que sugiere que el índice 3 es más relevante para la identificación precisa del estado de somnolencia.

## Abstract

Drowsiness and fatigue are significant factors in traffic accidents, particularly on highways. Recent statistics show a substantial link between fatal accidents and fatigue. In Chile, 86,050 traffic accidents were reported in 2022, resulting in 1,745 deaths. Of these accidents, 820 were caused by poor physical conditions such as fatigue. In this context, road safety research focuses on developing automated methods to detect driver drowsiness and warn them in time using sensor technologies and data processing. The goal of this project is to detect early signs of drowsiness by examining various physiological signals such as EEG, ECG, EMG, and EDA, in order to develop an algorithm that can identify relationships between these signals and drowsiness during driving simulations.

During the initial phase of this study, a detailed description of the physiological principles and acquisition methods of relevant signals was carried out, emphasizing their characteristics in relation to the transition states between wakefulness and drowsiness. A review of the current state of knowledge in the field was conducted, which allowed identifying key features, models, and successful algorithms employed in drowsiness detection.

Data obtained from a driving simulator study conducted by Hermes Javier Mora, titled \*‘‘Prediction of Early Drowsiness Events Using a Multifactorial Dataset in Vehicle Drivers,’’\* was used, focusing on the blocks designed for studying drowsiness (blocks 2 and 3), where physiological signals such as EEG, ECG, EMG, and EDA were collected. The present study considers the features extracted from EEG and ECG signals.

Three different types of classification models were implemented (neural networks, SVM, and kernel), achieving positive results in associating the signals with drowsiness states. Notably, the neural network model achieved an accuracy of 91.23 % in block 3 and 86.76 % in block 2. Regarding the features used, the power of frequency bands (delta, theta, alpha, and beta) was calculated, along with ratios between band powers (index 1:  $P_\theta/P_\alpha$ ; index 2:  $(P_\theta + P_\alpha)/(P_\alpha + P_\beta)$ ; index 3:  $(P_\theta + P_\alpha)/P_\beta$ ), heart rate, and heart rate variability. Frontal and occipital channels contribute significantly to drowsiness detection, particularly in the power of delta and theta bands, aligning with previous studies. Furthermore, it is highlighted that indices 1 and 2, while generally showing a relationship with drowsiness across several channels, are not as specific as index 3. The latter demonstrates a stronger and more precise relationship with drowsiness labels in specific channels, suggesting that index 3 is more relevant for accurately identifying drowsiness states.

# Tabla de contenidos

ÍNDICE DE TABLAS.....	X
ÍNDICE DE FIGURAS .....	XII
<b>CAPÍTULO 1. INTRODUCCIÓN.....</b>	<b>1</b>
1.1 INTRODUCCIÓN GENERAL .....	1
1.2 OBJETIVOS .....	1
1.2.1 <i>Objetivos generales</i> .....	1
1.2.2 <i>Objetivos específicos</i> .....	2
1.3 ALCANCES Y LIMITACIONES.....	2
1.4 METODOLOGÍA .....	2
1.5 TEMARIO .....	3
<b>CAPÍTULO 2. MARCO TEÓRICO .....</b>	<b>4</b>
2.1 INTRODUCCIÓN .....	4
2.2 DETECCIÓN DE SOMNOLENCIA POR ANÁLISIS DE SEÑALES FISIOLÓGICAS .....	4
2.2.1 <i>Principios del electroencefalograma (EEG)</i> .....	4
2.2.2 <i>Principios del electrocardiograma (ECG)</i> .....	6
2.2.3 <i>Principios del electromiografía (EMG)</i> .....	7
2.2.4 <i>Principios de la respuesta galvánica de la piel (GSR)</i> .....	8
2.3 ANÁLISIS Y DESCOMPOSICIÓN DE DATOS .....	10
2.3.1 <i>Adquisición y consideraciones generales para EEG</i> .....	10
2.3.2 <i>Adquisición y consideraciones generales para ECG</i> .....	12
2.3.3 <i>Adquisición y consideraciones generales para EMG</i> .....	13
2.3.4 <i>Adquisición y consideraciones generales para SCR</i> .....	14
2.4 DISCUSIÓN .....	15
<b>CAPÍTULO 3. ESTADO DEL ARTE.....</b>	<b>17</b>
3.1 INTRODUCCIÓN .....	17
3.2 MODELOS Y ALGORITMOS RELEVANTES EN LA DETECCIÓN DE SOMNOLENCIA.....	17
3.2.1 <i>Enfoque en EEG</i> .....	17

3.2.2	<i>Enfoque en ECG</i> .....	20
3.2.3	<i>Estudio de EMG</i> .....	21
3.2.4	<i>Estudio de GSR</i> .....	22
3.3	DISCUSIÓN .....	22
<b>CAPÍTULO 4. DATOS DEL ESTUDIO .....</b>		<b>24</b>
4.1	INTRODUCCIÓN .....	24
4.2	DESCRIPCIÓN DE LOS DATOS .....	24
4.2.1	<i>Descripción del circuito</i> .....	24
4.2.2	<i>Descripción de voluntarios y adquisición de datos</i> .....	24
4.2.3	<i>Datos obtenidos</i> .....	25
4.3	HERRAMIENTAS Y PROGRAMAS UTILIZADOS .....	27
<b>CAPÍTULO 5. DESARROLLO DEL ALGORITMO .....</b>		<b>29</b>
5.1	INTRODUCCIÓN .....	29
5.2	PREPROCESAMIENTO DE LOS DATOS .....	29
5.2.1	<i>Inspección visual</i> .....	29
5.2.2	<i>Transformaciones y normalización</i> .....	32
5.2.3	<i>Selección de Datos</i> .....	34
5.3	ANÁLISIS DE DATOS .....	35
5.3.1	<i>Señal de EEG</i> .....	35
5.3.2	<i>Señal de ECG</i> .....	36
5.3.3	<i>Señal de EMG y FSR</i> .....	37
5.4	BALANCE DE CLASES .....	40
5.5	IMPLEMENTACIÓN DEL MODELO DE CLASIFICACIÓN .....	42
5.5.1	<i>Modelo de redes neuronales</i> .....	42
5.5.2	<i>Modelo clasificadores de aproximación de kernel</i> .....	44
5.5.3	<i>Modelos SVM</i> .....	45
5.6	CARACTERÍSTICAS RELEVANTES .....	47
5.7	DISCUSIÓN .....	50
<b>CAPÍTULO 6. CONCLUSIONES.....</b>		<b>53</b>
6.1	CONCLUSIONES .....	53
6.2	TRABAJO FUTURO .....	54
<b>GLOSARIO.....</b>		<b>56</b>

**REFERENCIAS ..... 57**

**ANEXO A. IMÁGENES..... 67**

**ANEXO B. TABLAS ..... 80**

# Índice de Tablas

2.1	Clasificación de ondas en EEG. . . . .	6
2.2	Parámetros fisiológicos asociados a la somnolencia, sus relaciones y limitaciones. . . . .	16
3.1	Resumen de resultados de detección de somnolencia. El significado de las abreviaturas es el siguiente: TD: dominio del tiempo, FD: dominio de la frecuencia, N: no lineal, EN: entropías, CN: redes complejas. SIG: etiquetado basado en señales, BE3: primeros y últimos tres minutos como dos etiquetas, BE5: primeros y últimos cinco minutos como dos etiquetas. LSTM: memoria a largo y corto plazo, KNN: K vecino más cercano, SVM: Support vector machine, ELM: Extreme Learning Machine, NN: red neuronal, EBE: Elemento por elemento. . . . .	20
5.2	Cantidad de muestras de cada etiqueta antes y después de los métodos de balanceo. . . . .	41
5.3	Modelos con mejor rendimiento de los modelos de redes neuronales para el bloque 2 (extraídos de los anexos B.3 y B.4 ) según los estados de somnolencia (Validación). . . . .	43
5.4	Modelos con mejor rendimiento de los modelos de redes neuronales para el bloque 3 (extraídos de los anexos B.6 y B.7) según los estados de somnolencia (Validación). . . . .	44
5.5	Modelos con mejor rendimiento de modelos de Kernel para el bloque 2 (extraído del anexo B.8) según los estados de somnolencia (Validación). . . . .	45
5.6	Modelos con mejor rendimiento de modelos de Kernel para el bloque 3 (extraído del anexo B.9) según los estados de somnolencia (Validación). . . . .	45
5.7	Modelos con mejor rendimiento de modelos de SVM para el bloque 2 (extraídos del anexo B.10) según los estados de somnolencia (Validación). . . . .	47
5.8	Modelos con mejor de rendimiento de modelos de SVM para el bloque 3 (extraídos del anexo B.11) según los estados de somnolencia (Validación). . . . .	47
5.9	Comparación de resultados de los modelos por bloque respecto su precisión global. . . . .	50
5.10	Comparación de los mejores resultados de los modelos por bloque respecto su precisión global. . . . .	50
5.11	Matriz de confusión del modelo con mejor precisión (modelo 23: precisión global 86.76 %) de redes de neuronales del bloque 2. . . . .	51

5.12 Matriz de confusión del modelo con mejor precisión (modelo 9: precisión global 91.23 %) de redes de neuronales del bloque 3. . . . . 51

5.13 Comparación de resultados (precisión) de los modelos de redes neuronales por bloque, respecto al método de balanceo y uso de PCA. . . . . 52

B.1 Datos por archivo. Revisión de datos contenidos en los archivos del equipo Nautilus, donde "x" corresponde a los seleccionados y " - " a los no seleccionados . . . . . 69

B.2 Tabla resumen de hiperparametros de los modelos de Redes Neuronales Bloque 2 . . . . 70

B.3 Rendimiento de los Modelos de Redes Neuronales Bloque 2 (Validación) - Parte 1 . . . . 71

B.4 Rendimiento de los Modelos de Redes Neuronales Bloque 2 (Validación) - Parte 2 . . . . 72

B.5 Tabla resumen de hiperparametros de los modelos de Redes Neuronales Bloque 3 . . . . 73

B.6 Rendimiento de los Modelos de Redes Neuronales Bloque 3 (Validación) - Parte 1 . . . . 74

B.7 Rendimiento de los Modelos de Redes Neuronales Bloque 3 (Validación) - Parte 2 . . . . 75

B.8 Tabla resumen de rendimiento de modelos de Kernel para el Bloque 2 según los estados de somnolencia (Validación) . . . . . 76

B.9 Tabla resumen de rendimiento de modelos de Kernel para el Bloque 3 según los estados de somnolencia (Validación) . . . . . 77

B.10 Tabla resumen de rendimiento de modelos de SVM para el Bloque 2 según los estados de somnolencia (Validación) . . . . . 78

B.11 Tabla resumen de rendimiento de modelos de SVM para el Bloque 3 según los estados de somnolencia (Validación) . . . . . 79

# Índice de Figuras

2.1	Medidas de SCR . . . . .	9
2.2	SCL y NSSCR . . . . .	10
5.1	Ejemplo de visualización datos . . . . .	30
5.2	Distribución de canales EEG . . . . .	33
5.3	Espectros y mapas de canales EEG . . . . .	33
5.4	Identificación de peaks . . . . .	37
5.5	Señal EMG Identificación de Actividad . . . . .	39
5.6	Actividad FSR . . . . .	40
5.7	Dependencia Parcial . . . . .	49
A.1	Visualización de señal EEG . . . . .	61
A.2	Ejemplo de visualización anomalías ECG . . . . .	61
A.3	Visualización Comparativa EMG . . . . .	62
A.4	Visualización señales FSR . . . . .	62
A.5	Visualización de señal EDA (GSR) . . . . .	63
A.6	Comparación señales ECG y EDA (GSR) . . . . .	63
A.7	Señal EEG Preprocesada . . . . .	64
A.8	Señal ECG Preprocesada . . . . .	64
A.9	Señal EMG Preprocesada . . . . .	65
A.10	Señal FSR Preprocesada . . . . .	65
A.11	Señal EDA Preprocesada . . . . .	66
A.12	Curvas de Perdida Redes Neuronales Bloque 2 . . . . .	67

## Capítulo 1. Introducción

---

### 1.1 Introducción General

La somnolencia y fatiga es una causa importante de accidentes de tránsito, principalmente de los que se registran en carreteras. El Informe Anual de Seguridad y Salud en el trabajo 2023 elaborado por la Superintendencia de Seguridad Social (SUSESO), concluyó que el 67 % de los accidentes fatales involucran vehículos en el tránsito terrestre (vía pública). [1] Según el análisis del Observatorio de Seguridad Vial, que utiliza como fuente principal los datos provenientes de la base de datos de siniestros de tránsito que registra Carabineros de Chile, dio a conocer que durante el año 2022 se registró un total de 86.050 siniestros de tránsito y 1.745 personas perdieron la vida. Específicamente, según la Comisión Nacional de Seguridad de Tránsito se produjeron 820 siniestros producidos por condiciones físicas deficientes (cansancio, sueño, fatiga, etc.) con 54 fallecidos y con un total de 847 lesionados [2].

Conociendo este contexto, la investigación sobre seguridad en la conducción se enfoca en el desarrollo de técnicas automáticas que detectan la somnolencia del conductor y alerten al conductor lo antes posible mediante la combinación adecuada de tecnologías de sensores y métodos de procesamiento de datos. Este proyecto se enfoca en identificar signos tempranos de somnolencia mediante la correlación de múltiples señales fisiológicas. Para ello, se realizará un análisis multicanal de señales como Electroencefalograma (EEG), Electrocardiograma (ECG), Electromiografía (EMG) y Actividad Electrodérmica (EDA), con el objetivo de desarrollar un algoritmo capaz de detectar indicadores de somnolencia durante la conducción simulada. Se consideraran los datos obtenidos del experimento de “Predicción de eventos tempranos de somnolencia mediante un conjunto de datos multifactoriales en conductores de vehículos” [3].

### 1.2 Objetivos

#### 1.2.1 Objetivos generales

Analizar la relación entre las señales de EEG, ECG, EMG y EDA respecto a los niveles de somnolencia, utilizando modelos de aprendizaje supervisado y profundo.

## 1.2.2 Objetivos específicos

- Identificar y caracterizar los parámetros fisiológicos asociados a la somnolencia en cada tipo de señal (EEG, ECG, EMG y EDA) basados en la evidencia reportada en la literatura científica.
- Extraer y analizar las características relevantes estudiadas de las señales fisiológicas.
- Diseñar e implementar modelos de aprendizaje supervisado y profundo para determinar la correlación entre las características extraídas de las señales fisiológicas y los niveles de somnolencia observados.

## 1.3 Alcances y limitaciones

- Alcance 1: Se trabajará con los datos obtenidos del experimento de conducción realizado en el laboratorio de transporte del departamento de Ingeniería Civil durante el año 2023. En específico, los datos obtenidos del experimento de “Predicción de eventos tempranos de somnolencia mediante un conjunto de datos multifactoriales en conductores de vehículos”.
- Limitación 1: Se utilizarán los recursos de software y hardware disponibles por parte de la Universidad y personal, lo que determinará la complejidad del procesamiento de datos y el algoritmo final. Usando como software principal MatLab y sus complementos en procesamiento de señales y modelos de clasificación.

## 1.4 Metodología

Para el trabajo de esta memoria de título se utilizará el programa Matlab para el procesamiento y visualización de las señales. Los datos a considerar fueron adquiridos a partir del trabajo de tesis doctoral, realizada por Hermes Javier Mora, “Predicción de eventos tempranos de somnolencia mediante un conjunto de datos multifactoriales en conductores de vehículos” [3], de donde se considerarán los datos fisiológicos obtenidos (ECG, EEG, EMG y GSR).

Primeramente, se realizará el estudio del estado del arte en los estudios relacionados en la detección de somnolencia mediante diferentes señales fisiológicas de forma conjunta y la evaluación de los modelos propuestos. Posteriormente, se trabajarán las señales proporcionadas por el estudio anteriormente mencionado, para esto se realizarán las siguientes actividades:

- Procesar y segmentar las señales fisiológicas para eliminar artefactos y obtener segmentos de datos limpios y adecuados para el análisis.
- Identificar características específicas en las señales fisiológicas que puedan indicar somnolencia, mediante técnicas de análisis de señales y procesamiento de datos.
- Seleccionar características relevantes de las señales fisiológicas que puedan ser utilizadas como indicadores de somnolencia.
- Desarrollar y entrenar un algoritmo de detección de somnolencia utilizando técnicas de aprendizaje automático y procesamiento de señales.
- Validar el rendimiento del algoritmo utilizando conjuntos de datos independientes y evaluando su precisión, sensibilidad y especificidad en la detección de la somnolencia durante la conducción simulada.
- Ajustar y optimizar el algoritmo en función de los resultados de la validación, buscando mejorar su capacidad de detección y minimizar posibles errores.

## **1.5 Temario**

- Capítulo 1: Introducción en forma general del trabajo, indicando los objetivos y alcances del proyecto.
- Capítulo 2: Marco teórico, en el cual se exploran los principios y consideraciones principales para el estudio de las señales consideradas.
- Capítulo 3: Estudio del estado del arte, donde se muestran las tecnologías que se han desarrollado en el área. Además, se tiene una discusión en la que se describe la información más relevante del análisis bibliográfico.
- Capítulo 4: Antecedente de adquisición de los datos a utilizar y herramientas de software a considerar.
- Capítulo 5: Revisión visual de los datos, pre-procesamiento de las señales seleccionadas, adquisición y evaluación de características e implementación de modelos de clasificación, para identificar los criterios de somnolencia.
- Capítulo 6: Conclusiones generales del informe y trabajo futuro.

## Capítulo 2. Marco Teórico

---

### 2.1 Introducción

La somnolencia es uno de los factores humanos de riesgo que afectan a la seguridad vial a nivel global, provocando siniestros fatales, que significan a nivel internacional el 15 y el 30 % del total de accidentes de tránsito [4]. Por este motivo, se han implementado diferentes dispositivos y sistemas paliativos ante la presencia de signos de somnolencia, incluidos en los vehículos o accesorios a estos, sin embargo, estos pueden ser deficientes en el sentido predictivo por la limitante del procesamiento de más de una señal fisiológica, conductual o vehiculares. A continuación, se describirán algunas de las señales fisiológicas más relevantes en el estudio de la somnolencia.

### 2.2 Detección de somnolencia por análisis de señales fisiológicas

Dentro de las señales fisiológicas relevantes para la detección temprana de somnolencia, la electroencefalografía (EEG) es la técnica más utilizada para medir la actividad eléctrica del cerebro y es la técnica estándar en los estudios del sueño, debido a su diferenciación en la actividad eléctrica en los estados de vigilia y somnolencia.

#### 2.2.1 Principios del electroencefalograma (EEG)

Se pueden caracterizar diferentes tipos de ondas presentes en un EEG de un adulto, estas ondas han sido identificadas según su frecuencia, retroactividad muscular y estado de conciencia [5].

- Actividad Alfa ( $\alpha$ ): El ritmo alfa, con una frecuencia entre 8 y 13 Hz y bajo voltaje con amplitudes medias entre 30 y 50  $\mu$ V, se observa en individuos despiertos, en reposo y con los ojos cerrados, siendo más prominente en las regiones occipitales (O1-O2). Desaparece con la somnolencia y el sueño, aunque puede surgir brevemente durante la alerta en pacientes somnolientos. Variaciones incluyen una variante rápida (el doble de la frecuencia) y una variante lenta (menor a 8 Hz, entre 3.5 y 6.5 Hz.).

- Actividad Beta ( $\beta$ ) y Ritmo Gamma ( $\gamma$ ): Los ritmos beta, con frecuencia mayor a 13 Hz, con registros de voltaje menores a  $20 \mu\text{V}$ , presentan un máximo frontal y pueden disminuir durante la somnolencia, ya que se relaciona a estímulos táctiles y actividad motora de las extremidades contralaterales, aunque aumentan en niños y adultos mayores. El ritmo gamma tiene una actividad de frecuencia igual o superior a 30 Hz.
- Actividad Theta ( $\theta$ ): Con frecuencia de 4 a 7 Hz y registros voltaje mayores  $30 \mu\text{V}$ , las ondas theta son escasas en adultos despiertos, pero comunes en niños. Su presencia se asocia con áreas centrales y temporales.
- Ritmo Mu ( $\mu$ ) y Ondas Lambda ( $\lambda$ ): El ritmo mu se localiza en áreas centrales y desaparece con la actividad motora, mientras que las ondas lambda son bifásicas y aparecen al cambiar la mirada.
- Ritmo Delta ( $\delta$ )
  - El ritmo Delta, que oscila entre 0,5 y 4 Hz y con registros de voltaje entre  $100 - 200 \mu\text{V}$ , es predominante durante las etapas 3 y 4 del sueño. No se encuentra presente en adultos despiertos y se destaca por su amplitud en el EEG. Durante la vigilia, su presencia indica una anomalía, mientras que en etapas pediátricas indica el grado de madurez cerebral. No obstante, los artefactos de movimientos musculares pueden producir ondas con una frecuencia similar.
  - Actividad Delta Juvenil y Ritmo Kappa: Las ondas delta juveniles son comunes en niños y adolescentes, y ocasionalmente en adultos jóvenes (7–10 %) en adultos jóvenes de 18 a 30 años. Las ondas deltas aisladas que tienen un máximo occipital y una amplitud similar a la del ritmo alfa del paciente caracterizan esta actividad. El ritmo kappa consiste en intervalos de actividad alfa o theta asociados con actividad mental.
- Ondas del Vertex: Las ondas del vertex, más comunes en niños, son negativas en el vértice y pueden ser facilitadas por estímulos sensoriales.
- Cambios durante la Somnolencia: Durante la somnolencia, se observan cambios como la reducción de la frecuencia del ritmo alfa, la aparición de actividad lenta en áreas centrales, y la presencia de actividad theta bilateral. En adultos mayores, la transición de vigilia a sueño puede ocurrir rápidamente, manifestándose con ondas delta bilaterales de alta amplitud y máximo frontal.

**Tabla 2.1:** Clasificación de ondas en EEG.

<b>Tipo de Actividad</b>	<b>Frecuencia (Hz)</b>	<b>Localización</b>	<b>Reactividad</b>
Alfa ( $\alpha$ )	8 - 13	Occipital	Apertura ocular
Beta ( $\beta$ )	13 - 30	Frontal	Estímulos táctiles y actividad motora de las extremidades contralaterales
Gamma ( $\gamma$ )	30 - 100		
Delta ( $\delta$ )	0.5 - 4		Fase III y IV del sueño
Mu ( $\mu$ )	7 - 12	Central	Actividad motora
Theta ( $\theta$ )	4 - 7	Central o Temporal	
Ondas Lambda ( $\lambda$ )		Occipital	Observación de imágenes complejas
Ritmo kappa	8 - 13	Temporal	Actividad mental

**Fuente:** Elaboración propia. Información obtenida de [5]

### 2.2.2 Principios del electrocardiograma (ECG)

El electrocardiograma (ECG) es el registro de la actividad eléctrica del corazón, mientras que el electrocardiógrafo es el dispositivo que muestra la dirección y magnitud de las corrientes eléctricas cardíacas. Al fluir la corriente en múltiples direcciones en el músculo cardíaco, el electrocardiógrafo utiliza electrodos colocados en la piel para obtener la resultante de todos los vectores generados en un momento dado. Estos electrodos están conectados a un galvanómetro, que mide la corriente pasando por el aparato y la transmite para registrar las ondas y complejos del ECG de superficie. Las derivaciones electrocardiográficas miden la corriente que va en la dirección marcada por una línea recta que une los electrodos utilizados.

- Derivaciones bipolares: mide la diferencia de potencial entre los registros de las extremidades. Las derivaciones bipolares de las extremidades son: DI (electrodo (+) en el brazo izquierdo y (-) en el brazo derecho), DII (electrodo (-) en el brazo derecho y (+) en la pierna izquierda) y DIII (electrodo (-) en el brazo izquierdo y (+) en la pierna izquierda).
- Derivaciones unipolares de las extremidades: conocidas como derivaciones V, se componen de

la unidad central (electrodos negativos unidos), la derivación conectada al brazo izquierdo se le denomina VL (L, Left), mientras que a la del brazo derecho se le asigna VR (R, Right). Dado que estos potenciales necesitan amplificación debido a su baja intensidad, se añade la letra "a" al principio, indicando que son derivaciones "aumentadas".

- Derivaciones unipolares precordiales: las derivaciones precordiales son un sistema unipolar no amplificado. La unidad terminal o electrodo cero representa el centro eléctrico del corazón ubicado en la mitad del tórax, ligeramente a la izquierda, donde los vectores (ejes) QRS y T tienen su origen.

El automatismo cardíaco sigue un orden descendente de despolarización. El nodo sinusoidal inicia generando una frecuencia cardíaca normal de 60 a 100 latidos por minuto (lpm). El siguiente es el tejido de unión, con una frecuencia entre 40 y 60 lpm, conocido como ritmo idiojuncional, que se caracteriza por la ausencia de onda "P" en el electrocardiograma (ECG). Luego vienen las ramas izquierda y derecha, seguidas por las fibras de Purkinje, con un ritmo idioventricular denominado frecuencia de 15 a 40 lpm [6].

Generalmente, una frecuencia cardíaca más baja en reposo implica una función cardíaca más eficiente y un mejor estado físico cardiovascular, por lo que un ritmo normal de un adulto varía entre 60 a 100 lpm, además, se deben considerar muchos otros factores pueden influir en la frecuencia cardíaca, incluidos la edad, niveles de condición física y de actividad, enfermedades cardiovasculares, colesterol alto o diabetes, temperatura del aire, posición del cuerpo (de pie o acostado, por ejemplo), emociones, tamaño del cuerpo y consumo de medicamentos.[7]

### 2.2.3 Principios del electromiografía (EMG)

Se refiere al estudio de la actividad eléctrica de los músculos esqueléticos. Ofrece información muy valiosa sobre el estado fisiológico y la activación de los nervios. Posibilita la ubicación, en el caso de parálisis musculares, del sitio de la lesión, que podría encontrarse en el cerebro, la médula espinal, el axón, la unión neuromuscular o las propias fibras musculares.

Un músculo está formado por unidades motoras dispuestas en paralelo y fibras musculares modificadas llamadas Husos Musculares que sirven para percibir las tracciones musculares y controlar la posición del músculo. La excitación de un músculo puede cambiar desde el mínimo hasta el máximo, lo que afecta la cantidad de unidades motoras activadas. El número de fibras musculares que contiene es determinante para la finura de los movimientos ejecutados, y la actividad de una unidad motora es crucial para la

contracción muscular. Se gradúa la fuerza de la contracción muscular controlando el número de axones estimulados y la frecuencia de estimulación.

El territorio de actividad registrado en cada unidad motora es mayor que el espacio físicamente ocupado por sus fibras y se superpone con las unidades vecinas. El área de una unidad motora en el miembro superior es generalmente de 5-7 mm de radio, mientras que en el miembro inferior es de 7-10 mm. Estos valores se han establecido a través de métodos electrofisiológicos. En la actividad voluntaria, se estudia principalmente los potenciales de unidad motora (PUM). Están formados por la suma de diferentes potenciales de acción de grupos de fibras musculares que se contraen casi al mismo tiempo. Pueden tener una sola fase, dos fases o tres fases y, a veces, cinco o más fosas polifásicas. Puede variar entre 2 y 15 ms en duración y entre 100 pV y 2 mV en amplitud, aunque estas magnitudes dependen del tipo de electrodos utilizados y del músculo considerado [8].


#### **2.2.4 Principios de la respuesta galvánica de la piel (GSR)**

La conductancia de una corriente aplicada es regulada por la actividad de las glándulas sudoríparas. Estas modulaciones generan actividad electrodérmica (EDA), que se refiere a los cambios en la conductancia eléctrica de la piel. El sudor es principalmente agua, a pesar de contener minerales, ácido láctico y urea, lo que aumenta la conductividad eléctrica de la piel al incrementarse la sudoración.

Responden más a los estímulos psicológicos que a los estímulos térmicos estas glándulas sudoríparas. La alta densidad de glándulas ecrinas en manos y pies hace que este fenómeno sea más evidente en esas zonas, pero la sudoración provocada por emociones involucra a todas las glándulas sudoríparas ecrinas [9]. La principal característica de una señal EDA es la presencia de respuestas de conductancia cutánea (SCR en sus siglas en inglés) que se producen como resultado de una reacción simpática asociada a un estímulo. Los SCR se refieren a los eventos transitorios rápidos y suaves que son detectados en la señal de EDA. Generalmente se fija un umbral mínimo de 0,05 o 0,04 [ $\mu$ S] para determinar un Respuestas de Conductancia Cutánea (Skin Conductance Response) (SCR) importante con el fin de prevenir mediciones erróneas ocasionadas por artefactos de movimiento, ruido del equipo y circunstancias experimentales [10].


Se reconocen al menos tres vías que conducen a la producción de SCR: El control hipotalámico se ve influenciado por los ganglios basales y contralaterales. Esto implica una vía de control excitatorio a través de la corteza premotora y otra vía con influencias expositivas y excitadoras en la corteza frontal, así como la formación reticular en el tronco encefálico. Estas vías implican diferentes roles funcionales asociados

con los mecanismos centrales: La formación reticular se activa con movimientos gruesos y aumento del tono muscular, la actividad hipotalámica regula la sudoración para termorregulación, la amígdala se activa en procesos afectivos, la corteza premotora participa en situaciones que requieren control motor fino y la corteza prefrontal se asocia con la orientación y la atención [11]. Durante experimentos sobre eventos, se anticipa la presencia de una respuesta galvánica de la piel (SCR) tras el estímulo, conocida como ERSCR. Las métricas cuantitativas de los SCR abarcan la amplitud, el tiempo de subida (o tiempo de inicio a pico) y otros indicadores (Figura 2.1).



**Figura 2.1:** Respuesta típica de conductancia de la piel (SCR) e ilustración de algunas medidas derivadas [11].

Se usan el nivel de conductancia de la piel (SCL) y las respuestas de conductancia de la piel no específicas (Respuestas de Conductancia de la Piel No Específicas (NSSCR)) para evaluar la respuesta a un estímulo tónico en la piel. El SCL, medido en microsiemens ( $\mu S$ ), evalúa la conductancia global ligada al nivel de actividad de la EDA y muestra las variaciones lentas en la EDA, se consideran una medida tónica. Se estima como el promedio de mediciones durante un intervalo de reposo sin estímulos. Las NSSCR no están relacionadas con un estímulo específico y son el resultado de variaciones espontáneas en la EDA durante un estímulo constante (Figura 2.2 ).



**Figura 2.2:** Descomposición de datos EDA en componentes tónicos y fásicos [11].

## 2.3 Análisis y descomposición de datos

Para garantizar la calidad de la adquisición y la interpretación precisa de los datos, es necesario abordar múltiples variables con un enfoque meticuloso al analizar las señales psicofisiológicas, como el EEG, ECG, EMG y EDA. El enfoque de esta sección es sobre las consideraciones y prácticas generales para adquirir estas señales, resaltando aspectos cruciales que afectan la detección de fenómenos como la somnolencia, actividad muscular y respuesta emocional. Esto implica tener en cuenta el montaje y configuración, procesamiento de datos y características específicas.

### 2.3.1 Adquisición y consideraciones generales para EEG

Dentro del análisis de las señales de EEG, existen múltiples variables que pueden determinar con gran diferencia la calidad de la adquisición en la detección de somnolencia.

- Montaje: Actualmente, los estudios de detección de la somnolencia en los conductores se centran en la diferencia EEG entre estados de alerta y somnolencia, y pocos de ellos informaron el fenómeno de superioridad del hemisferio. Por lo tanto, el canal bipolar puede proporcionar información

suficiente para detectar la somnolencia en los conductores basada en EEG [12].

- **Número de electrodos:** La cantidad de canales de EEG utilizados en los estudios de detección de somnolencia varía considerablemente. No obstante, la mayoría se concentra en señales EEG de uno o dos canales y enfoca su atención en la zona occipital. Solamente algunos utilizan más de cinco canales de EEG, lo que posibilita la obtención de un contexto cerebral más amplio.
- **Región destacada:** La zona en la que identifican cambios significativos corresponde a la región occipital, asociado a la corteza visual. Las miradas de reojo de los conductores se vuelven más frecuentes y prolongadas cuando pasan de estar alerta a sentirse somnolientos. Estos movimientos oculares reducen la claridad del campo visual y la percepción visual, lo que provoca cambios en el EEG, como un aumento de las ondas alfa [13].
- **Procesamiento de datos:** Con mayor frecuencia, se recurre a métodos no paramétricos, los cuales abarcan técnicas como la transformada de Fourier (normalmente computada mediante el algoritmo de transformada rápida de Fourier, Transformada Rápida de Fourier (Fast Fourier Transform) (FFT)), el método de Welch y el método multitaper de Thompson. Considerando la señal EEG estacionaria, la aplicación de funciones basadas en FFT describen características de potencia FFT de diferentes bandas de frecuencia de EEG, estas funciones de potencia de banda se pueden enviar directamente a un algoritmo de detección. Respecto a las ventanas de tiempo, se ha identificado que 1 min es el período de tiempo más favorecido para los métodos de detección basados en EEG[12]. El dominio de frecuencia de la señal también se puede obtener utilizando métodos de descomposición de ondas por la transformada wavelet, la cual utiliza una función wavelet madre subyacente para la descomposición, y la descomposición de búsqueda coincidente utiliza diccionarios de señales para encontrar el mejor ajuste para la señal. Los modelos autorregresivos permiten extraer características como los coeficientes de reflexión o los coeficientes de correlación parcial. Además, los coeficientes wavelet derivados de la descomposición wavelet también pueden emplearse como características.
- **Características en frecuencia:** Además de la descomposición por bandas de frecuencia, se pueden establecer relaciones que son aplicables como características en el análisis de la señal EEG:
  - **Potencia de banda:** Corresponde a la relación entre las bandas  $\theta$ ,  $\alpha$  y  $\beta$ , en algunos casos se incluyen las bandas  $\delta$  y  $\gamma$  para detectar somnolencia. Se han planteado diferentes relaciones, de las cuales se destacan las relaciones  $\theta/\alpha$  y  $(\theta + \alpha)/(\alpha + \beta)$ , destacando su desempeño en los algoritmos (SVM) y Regresión logística [14].

- **Características tiempo-frecuencia:** La transformada de Fourier de corto tiempo (Transformada de Fourier de Corto Tiempo (Short-Time Fourier Transform) (STFT)) es una técnica básica que segmenta uniformemente la señal observada para calcular sus componentes de frecuencia. Por otro lado, la transformada wavelet representa una alternativa común al espectrograma, ofreciendo también coeficientes como características en el dominio tiempo-frecuencia. Su principal ventaja sobre el espectrograma radica en el uso de ventanas de tamaño variable, adaptadas a las frecuencias del espectro [15].

### 2.3.2 Adquisición y consideraciones generales para ECG

La onda R representa el punto más alto en un ECG, mientras que el intervalo RR (Intervalo entre Ondas R (RRI)) se define como el lapso entre una onda R y la siguiente. La Variabilidad de la Frecuencia Cardíaca (Variabilidad de la Frecuencia Cardíaca (VFC)) es una manifestación fisiológica que refleja la actividad del Sistema Nervioso Autónomo (SNA). Las características lineales de la VFC se dividen en dos dominios principales: el temporal y el frecuencial. En el dominio temporal, se pueden calcular las siguientes características a partir de los datos originales de RRI:

- **Media:** Promedio de los RRI.
- **SD:** Desviación estándar de los RRI.
- **RMSSD:** Raíz Cuadrática Media de las diferencias entre RRI adyacentes.
- **Potencia Total (Potencia Total (TP)):** Variabilidad total de los RRI.
- **NN50:** Número de pares de RRI adyacentes cuya diferencia supera los 50 ms durante el período de medición.

Por otro lado, en el dominio de la frecuencia, las siguientes características pueden obtenerse a partir de la densidad espectral de potencia (Densidad Espectral de Potencia (Power Spectral Density) (PSD)) de los datos RRI remuestreados, calculada mediante análisis de Fourier o modelos autorregresivos (AR):

- **TP:** La Potencia Total es la suma de la potencia en todas las frecuencias presentes en la señal de RRI, lo que proporciona una medida global de la variabilidad cardíaca en un determinado período de tiempo.

- Potencia en la Banda de Baja Frecuencia (LF): Potencia en la banda de baja frecuencia (0,04 Hz - 0,15 Hz) en la PSD, reflejando la actividad del sistema nervioso simpático y parasimpático.
- Potencia en la Banda de Alta Frecuencia (HF): Potencia en la banda de alta frecuencia (0,15 Hz - 0,4 Hz) en la PSD, reflejando la actividad del sistema nervioso parasimpático.
- LF/HF: Relación entre LF y HF, que indica el equilibrio entre la actividad simpática y parasimpática. Se recomienda medir el RRI durante un período de dos a cinco minutos para el análisis de la VFC, con una frecuencia de muestreo del ECG superior a 200 Hz para una detección precisa de la onda R [16].

### 2.3.3 Adquisición y consideraciones generales para EMG

Montaje: La principal desventaja de usar señales EMG es que son aleatorias y complejas. Además, las condiciones estructurales y las características biológicas del músculo pueden alterar las señales recopiladas. Por lo tanto, el registro depende de la adherencia de estos sensores. La señal EMG resultante adquirida con electrodo de microaguja (MNE) es altamente comparable con la señal adquirida con el electrodo Ag/AgCl. Por lo tanto, MNE es una buena opción para un sistema de adquisición de señales EMG mínimamente invasivo [17]

Para extraer información sobre la fuerza de la contracción muscular y el contenido frecuencial de las señales electromiográficas de superficie (sEMG), se utilizan varios parámetros. Entender la fuerza de la contracción muscular y el contenido frecuencial de la señal sEMG depende fundamentalmente de estos parámetros. Analizar la actividad muscular y detectar cambios significativos, como los asociados con la fatiga muscular, es posible a través de la combinación de información de amplitud y espectro. Para extraer información sobre la fuerza de la contracción muscular y el contenido frecuencial de la señal sEMG, se utilizan varios parámetros [18]:

- Parámetros de Amplitud
  - Valor Cuadrático Medio (Valor Cuadrático Medio (Root Mean Square) (RMS)): Describe el promedio de la amplitud de la señal sEMG.
  - Valor Medio Rectificado (ARV): Indica la amplitud promedio de la señal rectificada.
  - Envolvente Lineal (LE): Colabora en la caracterización de la amplitud de la señal según el transcurso del tiempo.

### ■ Parámetros Espectrales

- Densidad Espectral de Potencia: Se puede analizar el contenido frecuencial de la señal mediante enfoques de Fourier o autorregresivos para estimar. En el caso de una señal sEMG, la PSD muestra cómo se distribuye la energía de la señal en diferentes frecuencias, lo que puede reflejar la actividad de las unidades motoras, la fatiga muscular y otros aspectos relevantes.
- Frecuencia Media (Frecuencia Media (Mean Frequency) (MNF)) y Frecuencia Mediana (Frecuencia Mediana (Median Frequency) (MDF)): Consiguen datos acerca de la frecuencia dominante de la señal.
  - La MNF proporciona una medida promedio de la frecuencia dominante de la señal sEMG y se utiliza para caracterizar la frecuencia central de la actividad muscular.
  - La MDF es una medida robusta de la frecuencia central de la señal sEMG y se utiliza para caracterizar la distribución de frecuencias de la actividad muscular. Al igual que la MNF, cambios en la MDF pueden reflejar alteraciones en la activación de las unidades motoras y en la fatiga muscular.

### 2.3.4 Adquisición y consideraciones generales para SCR

- Montaje: Debido a la naturaleza de EDA y al lugar de adquisición de la señal, el registro de señales puede necesitar electrodos especiales, geles para electrodos y dispositivos distintos a los usados en otras medidas psicofisiológicas. La calidad de las mediciones de EDA se ve influenciada por los electrodos.
- Procesamiento y selección de características: Medir automáticamente las respuestas de conductancia de la piel (SCR) utilizando modelos matemáticos es atractivo tanto teórica como aplicadas. Se han realizado numerosos estudios que analizan métodos automáticos para detectar respuestas espontáneas de conductancia de la piel (SCR), extraer la amplitud u otras medidas de un solo SCR causante y manejar la superposición de las SCR. La ocurrencia frecuente de un segundo SCR antes de que finalice un SCR determinado es el desafío principal.
  - Análisis en tiempo: En el dominio del tiempo, normalmente se obtienen dos medidas de la EDA: El nivel de conductancia de la piel (Nivel de Conductancia de la Piel (Skin Conductance Level) (SCL)) y las respuestas no específicas de conductancia de la piel (NSSCR). La SCL se obtiene promediando varias mediciones tomadas durante un periodo específico. Los eventos

transitorios rápidos contenidos en las señales EDA son las respuestas de conductancia de la piel (SCR). Se calcula el índice NS.SCRs contando el número de SCR en un período dado.

- **Análisis en frecuencia:** Procesamiento de datos EDA basado en análisis espectral: Cuando se enfrentaban varios factores estresantes, hubo un aumento significativo en el poder espectral de la EDA en la misma banda que las bajas frecuencias de la VFC, conocidas por estar influenciadas al menos parcialmente por el sistema nervioso simpático.

Se planteó el índice de control simpático EDASymp, que se basa en el análisis espectral de potencia de EDA con un rango ampliado de frecuencias que va desde 0,15 hasta 0,25 Hz y representa entre un 5 % y un 10 % adicional de la potencia espectral. El índice demostró una sensibilidad al estrés similar a las medidas en el dominio del tiempo (por ejemplo, SCL y NSSCR) ante la mayoría de los estímulos, pero mostró ser aún más sensible al estrés inducido por la prueba de presión fría. El uso de un enfoque variable en el tiempo para analizar espectros mejoró la sensibilidad y coherencia del índice de análisis espectral del control simpático [19].

Se basa en la descomposición dispersa de EDA mediante un conjunto de átomos del diccionario (elementos básicos o componentes fundamentales), el EDA-grama representa otra alternativa de análisis presentada que es una huella digital multidimensional de la señal EDA. El espectrograma EDA representa la amplitud de los átomos seleccionados del diccionario en su dimensión espectral, mientras que los coeficientes de los átomos representan la intensidad y a su vez la amplitud de los SCR. Los resultados de las pruebas sugieren que algunas características derivadas del EDA-grama pueden diferenciar entre los niveles de excitación y el tipo de estrés al acentuar las fluctuaciones de la señal [20].

## 2.4 Discusión

El uso de estas señales fisiológicas en la detección de somnolencia es un área prometedora para la investigación. Teniendo en cuenta los parámetros fisiológicos relacionados con la somnolencia discutidos, como la actividad cerebral medida por EEG, la variabilidad de la frecuencia cardíaca medida por ECG, la actividad muscular medida por EMG y la activación autónoma medida por EDA, es posible desarrollar sistemas para detectar tempranamente este estado.

Como ejemplo, la reducción de la potencia en ciertas bandas de frecuencia en el EEG, acompañada por cambios específicos en la variabilidad de la frecuencia cardíaca y la actividad muscular, podría ser utilizada como indicadores importantes de la somnolencia. Podría incrementar la sensibilidad y especifi-

cidad de estos sistemas al integrar múltiples señales fisiológicas, lo que permitiría detectar la somnolencia de manera más precisa en diversas poblaciones y contextos.

Es fundamental considerar las limitaciones particulares de cada señal, como su susceptibilidad a artefactos y la variabilidad individual, con el fin de asegurar la fiabilidad y validez de las mediciones.

**Tabla 2.2:** Parámetros fisiológicos asociados a la somnolencia, sus relaciones y limitaciones.

Señas Fisiológica	Amplitud y Rango de frecuencia	Correlación positiva de indicadores	Correlación negativa de indicadores	Limitaciones
EEG	2 $\mu$ V - 10 $\mu$ V 10Hz - 2kHz	Potencia de las bandas $\theta$ y $\alpha$	Potencia banca $\beta$ , Entropía	La baja amplitud de la señal EEG dificulta su separación del ruido.
ECG	50 $\mu$ V - 50 mV 0.05 Hz - 100 Hz	VFC, FC	Ritmo cardiaco, VLF, LF, LF/HF, Frecuencia respiratorio	La tasa de detección es sensible a los sensores de proximidad de ECG no intrusivos
EMG	20 $\mu$ V - 10 mV 10Hz - 10 kHz	Cambio de frecuencia central hacia la región de frecuencia más baja	Amplitud EMG, Cambio de frecuencia central hacia la región de frecuencia más baja	Alterar debido a la biología muscular
EDA	10k $\Omega$ - 10M $\Omega$ 1.76V - 0.14V	Resistencia de la piel	Conductancia de la piel	Muy sensible a la temperatura ambiente.

**Fuente:** Elaboración propia.

## Capítulo 3. Estado del Arte

---

### 3.1 Introducción

En este capítulo se realiza la investigación actual e histórica de los criterios de detección, algoritmos y modelos para la identificación de somnolencia.

### 3.2 Modelos y algoritmos relevantes en la detección de somnolencia

En este capítulo se profundizará en el análisis del estado actual de la detección de somnolencia a través de las señales fisiológicas previamente identificadas para este proyecto, con un enfoque en los estudios más recientes. Se ofrece una revisión crítica de las metodologías utilizadas por varios investigadores en este ámbito, presentando una visión completa y actualizada de los avances en el campo.

#### 3.2.1 Enfoque en EEG

Según el estudio de somnolencia mediante análisis de EEG, se pueden identificar las siguientes seis categorías abarcan una amplia variedad de características de EEG relacionadas con los algoritmos de detección de la somnolencia en los conductores: Características puramente temporales, características derivadas de la transformada rápida de Fourier (FFT), características basadas en estadísticas de orden superior (Estadísticas de Orden Superior (Higher-Order Statistics) (HOS)), características wavelet, otras que se enfocan en tiempo-frecuencia y características híbridas.

En los estudios que han tenido mayor éxito en la detección de la somnolencia, se destacan numerosas herramientas y criterios pertinentes que facilitan una evaluación precisa de los estados de somnolencia. Se han identificado proyectos con resultados importantes en este campo a través del análisis del estado del arte. Como se mencionó anteriormente, la segmentación en bandas de frecuencia y la variabilidad son los principales atributos de las señales de EEG, por consiguiente, no resulta sorprendente la eficacia del análisis de esta señal en el dominio de la frecuencia y la utilización de criterios de entropía.

La integración de varios criterios puede resultar muy beneficiosa respecto a la robustez del algoritmo, sin embargo se debe equilibrar igualmente la carga computacional asociada a la adición de dichas

características. En el estudio “Intelligent system for drowsiness recognition based on ear canal electroencephalography with photoplethysmography and electrocardiography” se utilizaron  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ , índices de relación, estadísticas en el dominio de la frecuencia, el exponente de Hurst generalizado, Dimensión fractal de Higuchi (Dimensión Fractal de Higuchi (Higuchi Fractal Dimension) (HFD)), Entropía espectral (Entropía Espectral (Spectral Entropy) (SpEN)) y Entropía de permutación (PE), utilizando Auriculares EEG de oído [21], junto con fotoplethysmografía (PPG) y ECG. La precisión más alta alcanzada fue del 99,5 %. Las etiquetas de verdad fundamental se dividieron en cinco niveles y fueron etiquetadas por expertos en función de expresiones de comportamiento. Los autores clasificaron las características utilizando cuatro métodos diferentes, y en cada método, al menos cuatro de las siete características mejor clasificadas eran características no lineales. [22]

Así también, el artículo “Driver fatigue detection through multiple entropy fusion analysis in an EEG-based system” logró establecer una fusión de múltiples entropías, es decir, entropía espectral, entropía aproximada, entropía de muestra y entropía difusa, como características en comparación con el modelado autorregresivo (AR) mediante cuatro clasificadores (Máquinas de Soporte Vectorial (Support Vector Machines) (SVM), Propagación hacia Atrás (Back Propagation) (BP), Bosques Aleatorios (Random Forest) (RF) y K-Vecinos Más Cercanos (K-Nearest Neighbors) (KNN)). Obteniendo a la vez cuatro regiones de canales importantes, que reunía los electrodos basados en el peso, mediante un método de selección de canales simplificado (Región A: TP7, CP3, T5 y P3; Región B: FC3 y FCz; Región C: T4 y T6; Región D: O1 y O2). Finalmente, se estableció el modelo de evaluación para detectar la fatiga del conductor, comparando los resultados de los clasificadores basados en los datos de EEG de las cuatro regiones. El enfoque de validación cruzada de dejar uno fuera obtuvo una precisión del 98,3 %, una sensibilidad del 98,3 % y una especificidad del 98,2 %.[23]

Otros enfoques, se están llevando a cabo sobre el uso de modelos de aprendizaje profundo. Los modelos de aprendizaje profundo son conocidos por su capacidad para aprender estructuras ocultas en los datos, pero para un entrenamiento adecuado, con frecuencia requieren una gran cantidad de datos. Se pueden usar con datos sin procesarlos como entrada, pero también se pueden usar con funciones o ambas. Aquellos centrados en el dominio de la frecuencia, logran establecer una exitosa correlación entre diversas señales fisiológicas, como lo demuestra el artículo "Detección de somnolencia del conductor a partir de señales EEG y EOG utilizando redes GAN y Memoria a corto-largo plazo (Long Short-Term Memory) (LSTM)". Se logró una precisión de clasificación final del 98 %. Las etiquetas fundamentales de verdad para la clasificación se derivaron del fenómeno de bloqueo alfa y el fenómeno de atenuación-desaparición de la onda alfa. Los autores emplearon únicamente el canal O2 de la señal EEG y llevaron a cabo una transformada wavelet continua para calcular la densidad espectral de potencia (PSD). Las

redes LSTM tienen la ventaja de capturar dependencias a largo plazo en datos secuenciales, volviéndolas ideales para analizar los patrones cambiantes en el tiempo de señales fisiológicas relacionadas con los niveles de somnolencia [24].

Considerando los criterios de entropía, para el artículo “Automated Detection of Driver Fatigue Based on AdaBoost Classifier with EEG Signals” se utilizó funciones Sample Entropy Normalizada (Sample Entropy Normalized, SEN), Entropía Aproximada (Approximate Entropy) (ApEn), Entropía Muestral (Sample Entropy) (SampEn) y Entropía Difusa (Fuzzy Entropy) (FuzzyEn) de 32 canales de la señal EEG. Se finalizó un experimento basándose en el parámetro EOG asociado con la fatiga y la fatiga auto-informada. Los primeros cinco minutos se etiquetaron como estado normal y los últimos cinco minutos como estado de fatiga. Se utilizó el algoritmo de clasificación AdaBoost y se logró una precisión del 97,5 % [25].

Otros métodos de detección exitosos son aquellos realizados mediante la implementación de redes complejas, donde destacan las investigaciones de los artículos “Assessment of driver drowsiness using electroencephalogram signals based on multiple functional brain networks”, donde se extrajeron tres características de red complejas (grado, correlación de grados y kappa) para cada banda de frecuencia ( $\delta$ ,  $\theta$ ,  $\alpha$  y  $\beta$ ). La verdad fundamental se basó en la puntuación de la escala de somnolencia de Karolinska (Escala de Somnolencia de Karolinska (Karolinska Sleepiness Scale) (KSS)) y realizaron una clasificación binaria. La precisión más alta del 98,6 % se logró utilizando el algoritmo k vecino más cercano (KNN) [26].

Para optimizar aún más la detección, se utiliza la red cerebral funcional (FBN) y la densidad del espectro de potencia (PSD) en una fusión de características (FBN-PSD-FF). Un sistema de detección de fatiga automatizado que combina la característica de fusión (FBN-PSD-FF) con una máquina de aprendizaje extremo (ELM) complementa esta estrategia. Se lleva a cabo un experimento de simulación de conducción con escalas de somnolencia para validar el sistema propuesto y verificar los resultados. La sensibilidad (95,71 %), la especificidad (94,29 %), la precisión (95,00 %) y un área bajo la curva operativa del receptor (AUC-ROC=0,98) fueron los hallazgos del experimento. El uso de ELM para detectar el fatiga también reduce el tiempo requerido [27].

Se presentan de manera detallada en la Tabla 3.1 las consideraciones y características pertinentes de los estudios. Incluye los electrodos utilizados, la cantidad de participantes, el ámbito de las características, el método utilizado para etiquetar los datos, el algoritmo empleado, la cantidad de clases y los resultados finales de precisión.

**Tabla 3.1:** Resumen de resultados de detección de somnolencia. El significado de las abreviaturas es el siguiente: TD: dominio del tiempo, FD: dominio de la frecuencia, N: no lineal, EN: entropías, CN: redes complejas. SIG: etiquetado basado en señales, BE3: primeros y últimos tres minutos como dos etiquetas, BE5: primeros y últimos cinco minutos como dos etiquetas. LSTM: memoria a largo y corto plazo, KNN: K vecino más cercano, SVM: Support vector machine, ELM: Extreme Learning Machine, NN: red neuronal, EBE: Elemento por elemento.

<b>Autor</b>	<b>Electrodos</b>	<b>N° Part.</b>	<b>Caract.</b>	<b>Etiq.</b>	<b>Algoritmo</b>	<b>N°clases</b>	<b>Precisión</b>
Hong et al.[22]	Canal oreja	16	FD, N y EN	EBE	SVM	5	99.5
Chen et al.[26]	30 canales	15	CN	KSS	KNN	2	98.60
Min et al.[23]	32 canales	12	FD y EN	BE5	NN	2	98.30
Yingying et al.[24]	O1 y O2	12	FD	SIG	LSTM	2	98.14
Hu[25]	32 canales	28	EN	BE5	AdaBoost	2	97.50
Chen et al.[27]	40 canales	12	CN	BE3	ELM	2	95.00

**Fuente:** Elaboración propia. Información obtenida de [22], [26], [23], [24], [25] y [27].

### 3.2.2 Enfoque en ECG

Como parte de las señales complementarias a la detección de somnolencia, las señales de ECG se destacan por su singularidad rítmica, descrita por sus ondas y segmentos extensamente estudiados.

La gran mayoría de estos estudios no prescinden únicamente de esta señal, sino que contemplan señales como EEG, EMG, EOG y registros de video, que ayudan a la validación de eventos. Además, se han considerado otros indicadores de percepción de somnolencia, como la calificación observacional de somnolencia (ORD) (identificada por un investigador remoto) y escalas de somnolencia mediante verbalizaciones (Karolinska (KSS) y cuestionario de somnolencia de Stanford (SSS) [28]), consiste en una pregunta sobre cómo siente la somnolencia el paciente, es una escala numérica.

Se han identificado características relevantes, referidas a la variabilidad de la frecuencia cardiaca (VFC) tanto en el dominio del tiempo como en frecuencia, que podemos resumir en ocho características, mencionadas en el capítulo anterior:

- Características en el dominio temporal: media del intervalo RR (RRI), desviación estándar del RRI, raíz cuadrada de la media de las diferencias cuadradas sucesivas del RRI (RMS RRI), proporción de la potencia de alta frecuencia a la potencia total.
- Características en el dominio de la frecuencia: potencia total, potencia de baja frecuencia, potencia

de alta frecuencia y la relación entre la potencia de baja frecuencia y la potencia de alta frecuencia. El control estadístico multivariante de procesos (MSPC) es utilizado para monitorizar y controlar la variabilidad de varias variables en un proceso al mismo tiempo.

En el marco del algoritmo propuesto para detectar la somnolencia del conductor, se utiliza MSPC para monitorizar las anomalías en las características de la variabilidad de la frecuencia cardíaca (VFC) obtenidas a partir de los datos de intervalo RR (RRI) de los conductores.

La implementación de este método ha sido concluyente respecto a sus resultados, obteniendo una tasa de falsos positivos de 1,7 veces por hora, lo que indica una capacidad efectiva del algoritmo para detectar la somnolencia del conductor con una baja tasa de errores [29].

Otras alternativas relevantes integran las extracciones de características basadas en FFT y wavelet. La gran ventaja comparativa de estas transformaciones radica en la identificación de eventos, la transformada wavelet ofrece una representación en el dominio tiempo-frecuencia, lo que significa que puede identificar tanto las frecuencias presentes en la señal como su localización en el tiempo. Esto permite capturar cambios locales en la frecuencia y la amplitud a lo largo del tiempo. Sin embargo, la FFT es más adecuada para señales estacionarias, ya que asume que la señal es estacionaria en el tiempo y no captura cambios temporales en la frecuencia [30].

### **3.2.3 Estudio de EMG**

Durante la conducción, la transición del estado de alerta a la somnolencia provoca un cambio en las características fisiológicas. Se ha establecido la relación entre la relajación muscular y la somnolencia, por lo cual, se estudia la relajación y contracción de los grupos musculares referidos a la conducción misma, refiriéndonos a los miembros superiores (fuerza de agarre) e inferiores (Frecuencia y potencia).

En el desarrollo de un sistema de detección de somnolencia del conductor investigando la señal de electromiografía (EMG), se pueden considerar los músculos involucrados en el agarre del volante durante la conducción. El algoritmo detecta la actividad muscular débil al detectar la caída en la magnitud de la señal EMG debido a un aumento en la somnolencia del conductor.

Una combinación integral propone el análisis en el dominio del tiempo y la frecuencia para examinar la respuesta en el tiempo y la frecuencia de las señales EMG resultantes. Herramientas como STFT y espectrograma evalúan la distribución de frecuencia de las señales resultantes a lo largo del tiempo.

Se ha indicado que durante la tarea de conducir, el nivel de somnolencia de los participantes aumentó mientras que la actividad de los músculos involucrados en el agarre del volante disminuyó simultáneamente con el tiempo, por lo cual, se propone un algoritmo de detección de somnolencia del conductor basado en cambios de amplitud [17].

### 3.2.4 Estudio de GSR

La gran problemática son los movimientos que se lleva el sensor mientras se conduce y las pérdidas indeseables del contacto entre la piel y los electrodos pueden afectar fuertemente la calidad de la señal de conductancia de la piel (SC) y, en consecuencia, disminuir la precisión de los algoritmos para detectar el movimiento del conductor. Los métodos de eliminación de artefactos de movimiento basados en Transformadas Wavelet han ganado popularidad en diferentes campos relacionados con señales fisiológicas ruidosas, y han estado en la literatura durante varios años gracias a su capacidad de localización tiempo-frecuencia. La detección de cambios en la señal SC típicamente atribuibles a artefactos de movimiento y su eliminación real se aborda mediante la Transformada Wavelet Estacionaria (SWT) que elimina el ruido con la Wavelet madre de Haar (7 niveles de descomposición) [31].

Las características de la señal SC que la describen considerar aquellas obtenidas en el tiempo / frecuencia (Desviación Estándar, mínimo / máximo, curtosis, asimetría, varianza, rango, media y mediana) y componentes (número de picos de la respuesta de conductancia de la piel (SCR), Desviación estándar de nivel de conductancia de la piel (SCL) y SCL mínimo).

Según esta selección de características, la precisión de la detección de somnolencia fue del 89,3 % para Random Forest, del 89,4 % para Bagging y del 88,4 % para Boosting, considerando un sobre-muestreo de la señal SC [32].

## 3.3 Discusión

Los estudios reciente que involucran el estado del arte actual han demostrado ser prometedores para la detección precisa y temprana de la somnolencia. La integrar varias señales fisiológicas, es posible obtener información sobre diferentes aspectos del estado físico de la persona. Diferentes señales pueden complementarse entre sí, compensando las limitaciones individuales de cada una, lo que puede llevar a una detección más robusta y precisa de la somnolencia. Cada tipo de señal fisiológica proporciona información única sobre el estado del conductor.

Respecto a uso en específico del EEG, se destaca primeramente la gran significancia que posee en la detección, siendo la señal más recurrente dentro de este campo, con mayores índices de precisión. La selección y subselección de los canales en la identificación de los cambios importantes de la bandas de frecuencia es enfocada en gran parte a la zona occipital, ya que es una zona de importancia fisiológica destacada. Queda demostrado que la inclusión de características de diferentes dominio enriquece en gran medida los resultados finales, como el estudio de Hong et al. [22], que logró una precisión final del 99.5 %. Es digno de mencionar que los autores incorporaron características de tres distintas categorías. Los autores emplearon bandas de frecuencia estándar e índices de relación, el exponente no lineal generalizado de Hurst y HFD, así como las entropías SEN y PE. A pesar de que no son muchas características, es lógico pensar que su diversidad resulta en una detección altamente precisa de la somnolencia. Sin embargo, es discutible respecto a la cantidad de participantes, intuyendo un alto ajuste respecto a los datos.

El detectar la somnolencia del conductor a través de la variabilidad de la frecuencia cardíaca (VFC) involucra monitorear las anomalías en sus características estadísticas y de potencia tanto en el tiempo como en la frecuencia, lo cual se considera como criterios descriptivos óptimos. Se emplearán herramientas de análisis de datos adquiridos previamente, siendo la Transformada Rápida de Fourier (FFT) una opción adecuada para esto. Asimismo, el uso de señales electromiográficas (EMG) y actividad electrodermal (EDA) posibilitará la diferenciación de factores en términos de tiempo/frecuencia y potencia relacionados con la tendencia a la relajación muscular y la respuesta del sistema nervioso durante el paso del estado despierto al somnoliento. Sin embargo, estas señales a menudo están expuestas a un gran nivel de ruido, lo que conlleva la necesidad de identificarlas y tratarlas para determinar si son adecuadas en el desarrollo de la detección.

## Capítulo 4. Datos del estudio

---

### 4.1 Introducción

En este capítulo se inspecciona el contenido de los datos brindados de el experimento de simulación realizado en el estudio "Predicción de eventos tempranos de somnolencia mediante un conjunto de datos multifactoriales en conductores de vehículos" y se da contexto de la adquisición de las señales.

### 4.2 Descripción de los datos

Se utilizarán los datos obtenidos del proyecto de tesis doctoral titulado "Predicción de eventos tempranos de somnolencia mediante un conjunto de datos multifactoriales en conductores de vehículos" presentado por el Sr. Hermes Javier Mora Pantoja [3]. En esta sección se llevará a cabo una revisión sobre el origen de los datos, su contenido y la evaluación de su calidad en términos de su relación con artefactos y ruido para su posterior selección.

#### 4.2.1 Descripción del circuito

El experimento se divide en tres bloques en diferentes escenarios virtuales, el primer bloque presenta un circuito de obstáculos virtuales con 4 tipos distintos, con la frecuencia de aparición determinada por la cantidad de vueltas y la distancia según el tipo de obstáculo. Los bloques 2 y 3 fueron diseñados para inducir somnolencia, estos constaban de un escenario interurbano asfaltado con un carril por sentido vehicular y un escenario por autopista dispuso dos carriles por sentido, respectivamente. Ambos recorridos no tenían tráfico y debían ser recorridos a una velocidad constante de 30 Km/Hora, haciendo que los participantes pudieran experimentar somnolencia por desactivación de la carga de trabajo.

#### 4.2.2 Descripción de voluntarios y adquisición de datos

Se contó con un total de treinta sujetos sanos (23 hombres, edad:  $24,5 \pm 2$  y 7 mujeres, edad:  $21,5 \pm 1$ ) participaron en el experimento de conducción virtual durante al menos 85 minutos en el Laboratorio de Simulación de Conducción (GESITRAN).

Se considerarán señales fisiológicas tales como EEG, ECG, EMG y GSR (EDA) en adición de las señales de sensores de presión de fuerza resistivo (FSR). A continuación, se describen las condiciones de adquisición de las señales:

- Equipo g.Nautilus PRO para el registro de Electroencefalografía: este dispositivo tiene 16 electrodos con cables que se ubican en un gorro semitransparente que luego se colocan en su cabeza (Sistema protocolo 10-20). En cada uno de los 16 electrodos se aplica una sustancia de gel.
- Equipo Biopac Student Lab PRO para el registro de:
  - Electrocardiografía: este dispositivo tiene tres electrodos que se ubican en su pecho (II-derivación según estándar de ECG en 12 derivaciones, Clavícula cerca del hombro derecho (-), parte inferior del abdomen izquierdo (+)) que registran la actividad eléctrica de su corazón.
  - Electromiografía: este dispositivo tiene dos sensores que se ubican sobre los músculos de su pierna derecha y registran la actividad eléctrica de esa pierna, para los músculos tibial anterior (TA) y el gastrocnemio (Gn).
  - Resistencia galvánica para registrar la actividad sobre antebrazo izquierdo mediante dos sensores.
- Sensores FSR: Estos sensores fueron dispuestos tanto en el volante y pedales del simulador (sensores FSR tipo parche de 5 x 5 cm), por lo cual, se considerarán solamente aquellos ubicados en el volante para la evaluación de la fuerza de agarre. Se utilizaron en total 4 sensores flexibles de 45 x 1.5 cm adheridos en el exterior e interior del volante.

Además de estos registros, se cuenta con los datos obtenidos del sensor acelerómetro MPU9250 [33], ubicado en el espacio superior posterior del volante.

### 4.2.3 Datos obtenidos

Los archivos de cada voluntario se encuentran en formato con extensión ".mat", diferenciados por la hora de registro. Cada archivo proveniente del equipo g.Nautilus PRO contiene los siguientes datos:

- Samples: Contiene los datos relacionados a 16 canales y valores de str, obt1, obt2, obt3 y obt4 (str= start, obt#= obstacle number).

- TimeLenSegments: Arreglo con la cantidad de muestras por segmento (Total de tres segmentos).
- Samples Labels: Títulos de los canales, señal de inicio y obstáculos (ch1 al ch16, str, obt1, obt2, obt3 y obt4).
- Segments Labels: Títulos correspondidos con los segmentos del arreglo TimeLenSegments (Segment 1: (str (obts) end), Segment 2: (str - end), Segment 3: (str - end)).
- Obstacles Labels: Lista de aparición de obstáculos.
- Units: Unidades métricas de [uV] y [V]
- Device Description: Contiene el nombre de los canales (enumeración del 1 al 16), Valores máximo/mínimo, offset, Número de canal físico, Frecuencia, Sensibilidad al valor alto, Sensibilidad al valor bajo y unidades métricas.

Cada archivo proveniente del equipo Biopac Student Lab PRO contiene los siguientes datos:

- Data: Arreglo que contiene los datos correspondidos con el arreglo Labels, que simbolizan el registro de ECG, EDA, EMG (Registró en tibial anterior (TA) y el gastrocnemio (Gn) en la pierna derecha), señal de inicio y aparición de obstáculos.
- TimeLenSegments: Arreglo con la cantidad de muestras por segmento (Total de tres segmentos).
- Sample Rate: Frecuencia de muestreo de 500 [Hz].
- Segments Labels: Títulos correspondidos con los segmentos del arreglo TimeLenSegments (Segment 1: (str (obts) end), Segment 2: (str - end), Segment 3: (str - end)).
- Obstacles Labels: Lista de aparición de obstáculos.
- Units: Unidades métricas de [mV], [micro Mho] y [V] correspondientes a cada señal
- Labels: Títulos de la señal correspondiente con el orden del arreglo data (ECG (.05 - 150 Hz), EDA (GSR) (0 - 35 Hz), EMG (5 - 1000 Hz), EMG (5 - 1000 Hz), str, D2-obt1, D3-obt2, D4-obt3, D5-obt4).

Cada archivo proveniente de los registros de los sensores FSR contiene los siguientes datos:

- **Data:** Arreglo que contiene los datos correspondidos con el arreglo "Header", que simbolizan el tiempo, registro de los 7 sensores FSR (S1 al S7, S1 al S3 sensores tipo parche en los pedales (Acelerador, freno y embriague) y S4 al S7 sensores flexibles distribuidos en el volante), velocidad ( $ax$ ,  $ay$ ,  $az$ ), velocidad angular ( $axAngle$ ,  $ayAngle$ ,  $azAngle$ ), aceleración ( $gx$ ,  $gy$ ,  $gz$ ), señal de inicio/final y aparición de obstáculos ( $obt1$ ,  $obt2$ ,  $obt3$  y  $obt4$ ).
- **TimeLenSegments:** Arreglo con la cantidad de muestras por segmento (Total de tres segmentos).
- **Header:** Títulos de la señal correspondiente (Time, S1, S2, S3, S4, S5, S6, S7,  $ax$ ,  $ay$ ,  $az$ ,  $axAngle$ ,  $ayAngle$ ,  $azAngle$ ,  $steeringAngle$ ,  $gx$ ,  $gy$ ,  $gz$ ,  $star/end$ ,  $obt1$ ,  $obt2$ ,  $obt3$ ,  $obt4$ )
- **Fs:** Frecuencia de muestre de 3.9165
- **SamplesLabels:** Títulos de las señales en forma agrupada (time[S], S1...S7, acc, gyro,  $obt1$ ,  $obt2$ ,  $obt3$ ,  $obt4$ ).
- **SegmentsLabels:** Títulos correspondidos con los segmentos del arreglo TimeLenSegments (Segment 1: (str (obts) end), Segment 2: (str - end), Segment 3: (str - end)).
- **Units:** Unidades de medida de [ms], [KgF], [ $^{\circ}/s$ ], [m/s<sup>2</sup>], [uT] y títulos de la señales de suceso (str/end,  $obt1$ ,  $obt2$ ,  $obt3$  y  $obt4$ ).

### 4.3 Herramientas y programas utilizados

MATLAB será empleado como plataforma para procesar y visualizar datos. MATLAB es una herramienta muy popular entre ingenieros y científicos para analizar datos, crear algoritmos y modelos, gracias a su capacidad de programación y cálculo numérico. Proporciona una amplia y variada selección de toolboxes que incluyen campos como el procesamiento de imágenes y señales, control de sistemas, comunicaciones inalámbricas, finanzas computacionales, robótica, deep learning e inteligencia artificial [34]. En este proyecto se utilizarán los siguientes toolbox y software:

- **Signal Processing Toolbox:** Proporciona funciones y aplicaciones para el análisis y procesamiento de señales muestreadas, incluyendo diseño de filtros, remuestreo, suavizado y estimación espectral. Herramientas destacadas como Signal Analyzer y Filter Designer permiten analizar señales en dominios de tiempo, frecuencia y tiempo-frecuencia, y diseñar filtros digitales FIR e IIR. Además, genera scripts automatizables en MATLAB[35].

- **EEGLAB:** Toolbox interactiva para procesar datos EEG, MEG y otras señales fisiológicas. Incluye análisis de componentes independientes, tiempo-frecuencia, eliminación de artefactos y visualización. Proporciona una interfaz gráfica amigable y permite compartir métodos mediante plug-ins, ampliando su funcionalidad para la comunidad científica [36]
- **Classification Learner:** Aplicación dentro del entorno de Matlab que facilita la creación de modelos de clasificación, ofreciendo herramientas para explorar datos, seleccionar características, definir validaciones, entrenar modelos y evaluar su desempeño. Incluye un modo de entrenamiento automatizado para identificar el mejor modelo, soportando técnicas como árboles de decisión, análisis discriminante, SVM, regresión logística, vecinos más cercanos, Naive Bayes, aproximaciones con kernel, ensamblados y redes neuronales [37].
- **Parallel Computing Toolbox:** Permite escalar aplicaciones MATLAB a procesadores multinúcleo, GPU y clusters sin modificar el código. Facilita cálculos paralelos, simulaciones en Simulink y manejo de grandes matrices mediante workers locales o MATLAB Parallel Server [38].

## Capítulo 5. Desarrollo del Algoritmo

---

### 5.1 Introducción

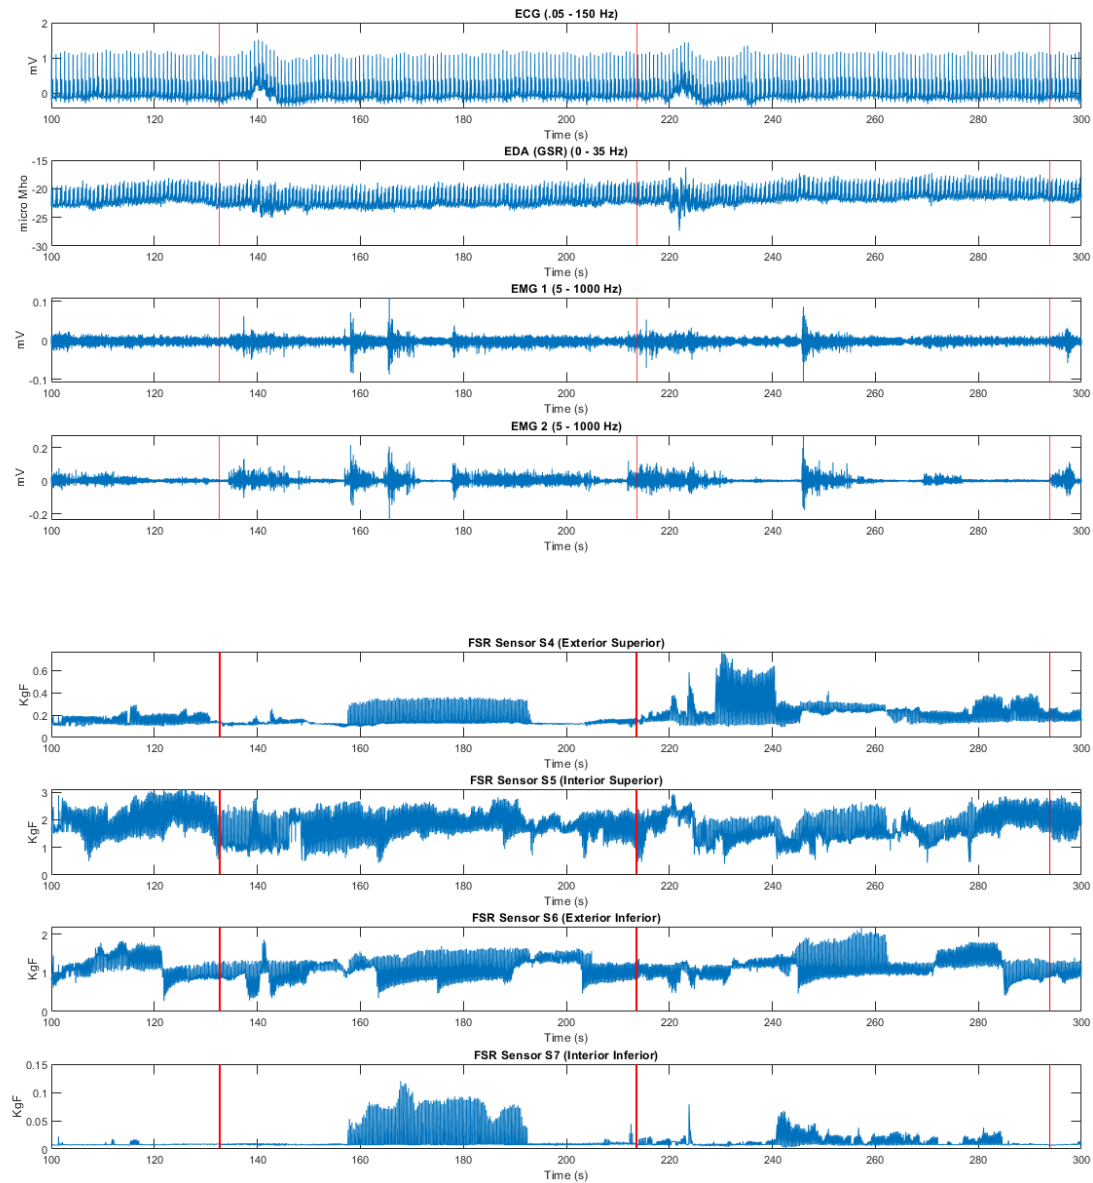
En este capítulo se aborda el tratamiento de los datos y la implementación del algoritmo de clasificación. Se exploran en detalle las etapas clave del proceso, que incluyen la selección de las señales, su preprocesamiento, la extracción de características relevantes y su integración en el algoritmo. Además, se describe la construcción del modelo de clasificación utilizando señales multivariantes, presentando los principales resultados obtenidos.

### 5.2 Preprocesamiento de los datos

En esta sección, se identificará la presencia de valores faltantes y datos atípicos en cada señal considerada. A continuación, se realizarán las transformaciones y normalizaciones necesarias para la posterior selección de características.

#### 5.2.1 Inspección visual

Primero, se realiza una visualización conjunta de las señales, incluyendo las adquiridas del equipo Biopac y de los sensores FSR, además de identificar la aparición de los obstáculos. Respecto a las señales EEG se visualizan mediante el software EEGLAB, la cual también, contempla la aparición de los obstáculos como eventos. Este proceso se llevó a cabo con todos los sujetos, por lo que se describirán las anomalías detectadas de manera transversal en todos ellos (Figura 5.1). Esta visualización incluye las señales de ECG, EDA, EMG y los sensores FSR vinculados al volante.



**Figura 5.1:** Visualización de datos Biopack y FSR en conjunto con la aparición de obstáculos (Visualización mediante Matlab).

## Revisión visual de la señal EEG

Respecto a las señales de EEG obtenidas, las señales exhiben una apariencia bastante constante con ligeras fluctuaciones en la amplitud, lo cual es característico en EEG normales. Existe nivel basal de ruido, pero parece estar dentro de un intervalo normal para registros de EEG. Se observan descensos

y aumentos abruptos en la amplitud de la señal en múltiples canales simultáneamente, lo cual podría indicar artefactos o cambios bruscos en la actividad cerebral. Además, se denota una coordinación entre los canales en eventos de gran amplitud, lo que sugiere que estas áreas del cerebro se activan de forma sincronizada durante dichos eventos (Anexo A.1).

## **Revisión visual de la señal ECG**

Las señales de ECG presentan anomalías en algunos segmentos específicos, identificados por un aumento considerable en su magnitud (peak anormales) y cambios en su línea base notorios (Anexo A.2). La señal exhibe una frecuencia constante de picos (los cuales representan los latidos cardíacos) alrededor de un evento central resaltado. Los latidos parecen mantener una frecuencia constante, lo que sugiere un ritmo cardíaco regular. Este evento se caracteriza por un aumento veloz y notable en la extensión. Un descenso repentino tras alcanzar el punto máximo, seguido de un vaivén y tras la actividad principal, la señal regresa a un ritmo parecido al original, aunque con una leve modificación en la amplitud y la forma de las ondas.

## **Revisión visual de la señal EMG y FSR**

Se puede apreciar que las señales adquiridas tanto de EMG y FSR presentan una buena adquisición, con cambios notables en la actividad e inactividad de los sensores. El registro de EMG no presenta desviación de la línea base, exhibe una fluctuación significativa en su amplitud a lo largo del tiempo, con picos notables que pueden indicar momentos de gran actividad muscular o contracciones fuertes. La señal presenta variaciones rápidas y variables de menor magnitud en todo el registro, lo cual podría señalar la existencia de ruido de fondo o actividad muscular de intensidad reducida. Respecto al análisis en frecuencia, se denota una mejor distribución de frecuencias en la adquisición del músculo Gastrocnemio, obteniendo una mejor diferenciación en la identificación de actividad, además, comprende magnitudes mayores a las obtenidas del registro del músculo Tibial Anterior (Anexo A.3).

Las señales de los sensores FSR tienen una distribución de frecuencias con predominancia hacia las bajas frecuencias, mostrando cambios consistentes en el tiempo con una leve desviación de los valores mínimos y muchas irregularidades de alta frecuencia contenidos en las activaciones fácilmente identificables. Además, una diferencia en las magnitudes máximas consistentes con su distribución, observando mayores magnitudes en los sensores del área superior externa e área internas (Anexo A.4).

## Revisión visual de la señal EDA

La señal de EDA (GSR) adquirida durante el período observado, presenta un aumento progresivo en la conductancia de la piel. La señal presenta muchas variaciones a lo largo del tiempo, con picos y valles marcados. Durante el registro se pueden notar múltiples picos elevados, que señalan periodos de alta conductancia dérmica. Asimismo, se aprecian caídas abruptas en la señal, que evidencian momentos de baja conductancia. La señal presenta una notable variabilidad, con cambios rápidos y a veces bruscos en la amplitud. (Anexo A.5).

Además, presenta una sincronización con la señal de ECG (Anexo A.6). Estas anomalías de grandes cambios en magnitud y alta presencia de ruido, atribuible a problemas en su adquisición (se reportó el mal funcionamiento de uno de los electrodos del dispositivo de adquisición).


### 5.2.2 Transformaciones y normalización

Para garantizar la uniformidad en las dimensiones de las señales, se optó por realizar un resampleo a una frecuencia común de 250 Hz. Las transformaciones se llevaron a cabo de manera independiente para cada tipo de señal, con el objetivo de generar archivos de resultados finales correspondientes a cada señal específica. Se guardando los resultados de todos los participantes en archivos únicos para mejor manipulación de los datos.


## Señal de EEG

Las señales de EEG fueron procesadas mediante el software EEGLAB, que cuenta con herramientas específicas de EEG. Primeramente, se integró la localización espacial de los canales a los registros, el orden de los mismo corresponde a la distribución estándar 10-20 (Figura 5.2). Una vez asociada a los canales, la señal fue re-muestreada a la mitad de su frecuencia de muestreo de adquisición, reduciendo consistentemente su costo computacional. Posteriormente, se utilizó un filtro pasa banda que incluye las frecuencias que se desean estudiar, por términos de practicidad, se delimitó el filtrado de frecuencia en un rango de 0.1 a 40 [Hz], reduciendo el rango del ritmo gamma (Anexo A.7). Para la selección de los canales se utilizó el trazar espectros y mapas de canales, que evalúan la potencia de la densidad espectral de cada canal. Cada señal de color representa la actividad espectral de un canal de datos. En la figura del cuero cabelludo a la izquierda se representa la potencia a 6 [Hz], que está principalmente en la línea media frontal. Los mapas adicionales del cuero cabelludo muestran cómo se distribuye la potencia a 10

[Hz] y 22 [Hz] (Figura 5.3). Se puede observar de acuerdo a la escala de colores y la distribución de los canales, donde se hace notar la diferencia del trazado de canales puntuales.



**Figura 5.2:** Visualización de la distribución de los 16 canales mediante su nombre y número (Visualización mediante Matlab EEGLAB).



**Figura 5.3:** Visualización de la densidad de potencia espectral de los canales de la señal de EEG (Visualización mediante Matlab EEGLAB).

## Señal de ECG

Las señales de ECG fueron preprocesadas mediante un filtro pasa banda (2 a 15 [Hz]), las frecuencias a considerar se decidieron mediante el estudio de las frecuencias presentes en las señales, de las cuales se escogió un segmento que contaba con menores anomalías, permitiendo la eliminación de artefacto notorios que afectan la señal en su línea base. Podemos observar la comparación de las señales (Anexo A.8), en donde se logra eliminar la anomalía consistentemente, conservando las ondas representativas de una señal normal.

## Señal de EMG y FSR

Para las señales de EMG se realiza un filtrado pasa banda (10 a 60 [Hz]), priorizando la forma base de la señal respecto a su actividad, por lo tanto, luego de evaluar las frecuencias presente en esta se selecciona un segmento hasta lograr una eliminación de las altas frecuencias, sin embargo, se nota una diferencia en las magnitudes (Anexo A.9). En el caso de las señales FSR se aplica un filtro pasa bajos, ya que este presenta una concentración a las bajas frecuencias, suavizando las fluctuaciones dentro de las actividades notables y manteniendo los cantos de subida y baja (Anexo A.10).

## Señal de EDA

La señal EDA fue preprocesada mediante el filtro de suavizado "Smooth" de media móvil aplicado mediante Signal Processing Toolbox, obteniendo el registro de baja frecuencia presente en la señal, recuperando parcialmente la variabilidad de la señal EDA registrada, eliminando además la sincronización de la señal de ECG visualizada anteriormente (Anexo A.11). Sin embargo, se debe considerar que esta reconstrucción no es del todo fidedigna, debido a la alta presencia de ruido en la señal adquirida, observando una gran variabilidad en la gran mayoría de los registros de los sujetos.

### 5.2.3 Selección de Datos

Los criterios de selección se llevaron a cabo a través del análisis después del preprocesamiento inicial, normalización y visualización tanto de manera conjunta como individualmente. Se puede observar que las señales EDA fueron las señales más difíciles de seleccionar, debido al alto nivel de interferencias atribuibles a problemas de adquisición. Por ello, se propondrá la exclusión de todas las señales EDA. El resto

de las señales disponibles muestran un nivel de ruido aceptable que se puede corregir mediante la utilización de filtros convencionales y herramientas de identificación de eventos importantes. En consecuencia, se analizan todas las señales de ECG, EMG y FSR (sensores del volante) de todos los participantes.

En el caso de la selección de canales de la señal de EEG, se utilizó como herramienta de selección el gráfico de densidad de potencia espectral de los canales, de donde se detectaron anomalías con mayor notoriedad. Se logra destacar el registro anormal de los canales T8 (Canal 10), Cz (Canal 8), Fp2 (Canal 2) y Oz (Canal 16), con mayor anormalidad espectral el canal T8, por lo cual, no fue considerado en ninguno de los sujetos. Los resultados finales de selección se describen en el Anexo B.1. Se completaron los valores faltantes con el valor promedio por ventana de los canales existentes.

### 5.3 Análisis de datos

Una vez realizados todas las consideraciones de preprocesamiento se realiza el cálculo de las características descriptivas de cada señal. Este se realiza de forma particular para cada tipo de señal, finalizando en un único archivo de resultados, que contempla todos los participante.

#### 5.3.1 Señal de EEG

Dentro del preprocesamiento de las señales EEG sugerido por EEGLAB, se realizaron los pasos siguientes: se detectaron y descartaron los canales con irregularidades, se realizó una re-referencia al promedio, se realizó un filtrado de banda (0.5 a 40 [Hz]) para eliminar ruido, se extrajeron características a través de ICA (Análisis de Componentes Independientes) y se escogieron únicamente los componentes vinculados a la actividad cerebral.

Luego, las señales se dividieron en las cinco bandas de frecuencia principales (Delta: 0.5 a 4 [Hz]; Theta: 4 a 8 [Hz]; Alpha: 8 a 13 [Hz]; Beta: 13 a 30 [Hz]; Gamma: 30 a 45[Hz]). De estas bandas, se consideraron solamente las cuatro primeras, que tienen una relación más directa con los estados de vigilia y somnolencia. Luego, se calcula potencia de las bandas de frecuencia en las ventanas de EEG, considerando la ecuación 5.3.1, donde  $P_{\text{banda}}(c, w)$  es la potencia de la banda en el canal  $c$  y la ventana  $w$ ,  $N$  es el número de muestras en la ventana y  $x(c, n)$  representa el valor de la señal filtrada en la banda de interés, para el canal  $c$  en la muestra  $n$ .

$$P_{\text{banda}}(c, w) = \frac{1}{N} \sum_{n=1}^N (x(c, n))^2 \quad (5.3.1)$$

Además, se determinaron vínculos extra entre las bandas relacionados a la detección de somnolencia [39], reflejadas en las ecuaciones (5.3.2 a 5.3.3).

$$\text{indice 1} = \frac{P_{\text{banda theta}}(c, w)}{P_{\text{banda alpha}}(c, w)} \quad (5.3.2)$$

$$\text{indice 2} = \frac{P_{\text{banda theta}}(c, w) + P_{\text{banda alpha}}(c, w)}{P_{\text{banda alpha}}(c, w) + P_{\text{banda beta}}(c, w)} \quad (5.3.3)$$

$$\text{indice 3} = \frac{P_{\text{banda theta}}(c, w) + P_{\text{banda alpha}}(c, w)}{P_{\text{banda beta}}(c, w)} \quad (5.3.4)$$

Los resultados logrados se unificaron y guardaron en un archivo de resultados, especificando el nombre del archivo proveniente.


- `somnolence_indices`: Contiene el cálculo de las relaciones entre canales, calculados para cada canal.
- `band_powers`: Contiene el calculo de la potencia de los canales, agrupados en sus respectivas bandas de frecuencia.
- `channels`: Arreglo que contiene el nombre de los canales a considerar de cada sujeto.

### 5.3.2 Señal de ECG

Respecto a las señales de ECG, se desea analizar la variabilidad de las señales de ECG, para este es necesario identificar los intervalos R-R de la señal. Se importan los archivos `.mat` que incluyen las señales de ECG y la información adicional de cada participante. Cada documento incluye un struct con los atributos: `data`, `TimeLenSegments`, `SampleRate`, `SegmentsLabels`, `ObstaclesLabels`, `Units` y `Labels`. Se utiliza un filtro pasa banda para filtrar la señal de ECG y eliminar el ruido (Anexo A.2). Se emplea el algoritmo de Pan-Tompkins [40] para identificar los picos QRS en la señal de ECG después de ser filtrada. La frecuencia cardíaca en latidos por minuto (lpm) se determina a partir de los intervalos RR,

que representan el tiempo entre picos sucesivos. La desviación estándar de los valores de lpm se utiliza para estimar la variabilidad de la frecuencia cardíaca. La señal de ECG se representa visualmente con los picos identificados y la variabilidad de la frecuencia cardíaca a lo largo del tiempo (en minutos) (Figura 5.4). El archivo resultante almacena los siguientes campos:

- heartRate: Arreglo de frecuencias cardíacas (lpm) calculadas a partir de los intervalos RR. Se obtuvo un rango de 60 a 111 - 118 (lpm)
- heartRateVariability: Desviación estándar de las frecuencias cardíacas, representando la variabilidad de la frecuencia cardíaca. Se obtuvo un rango de 0.0017889 a 0.36897 - 0.37079



**Figura 5.4:** Visualización aumentada en un segmento. Gráfica del cálculo de latidos por minuto de toda la señal y variabilidad (HRV) (Visualización mediante Matlab).

### 5.3.3 Señal de EMG y FSR

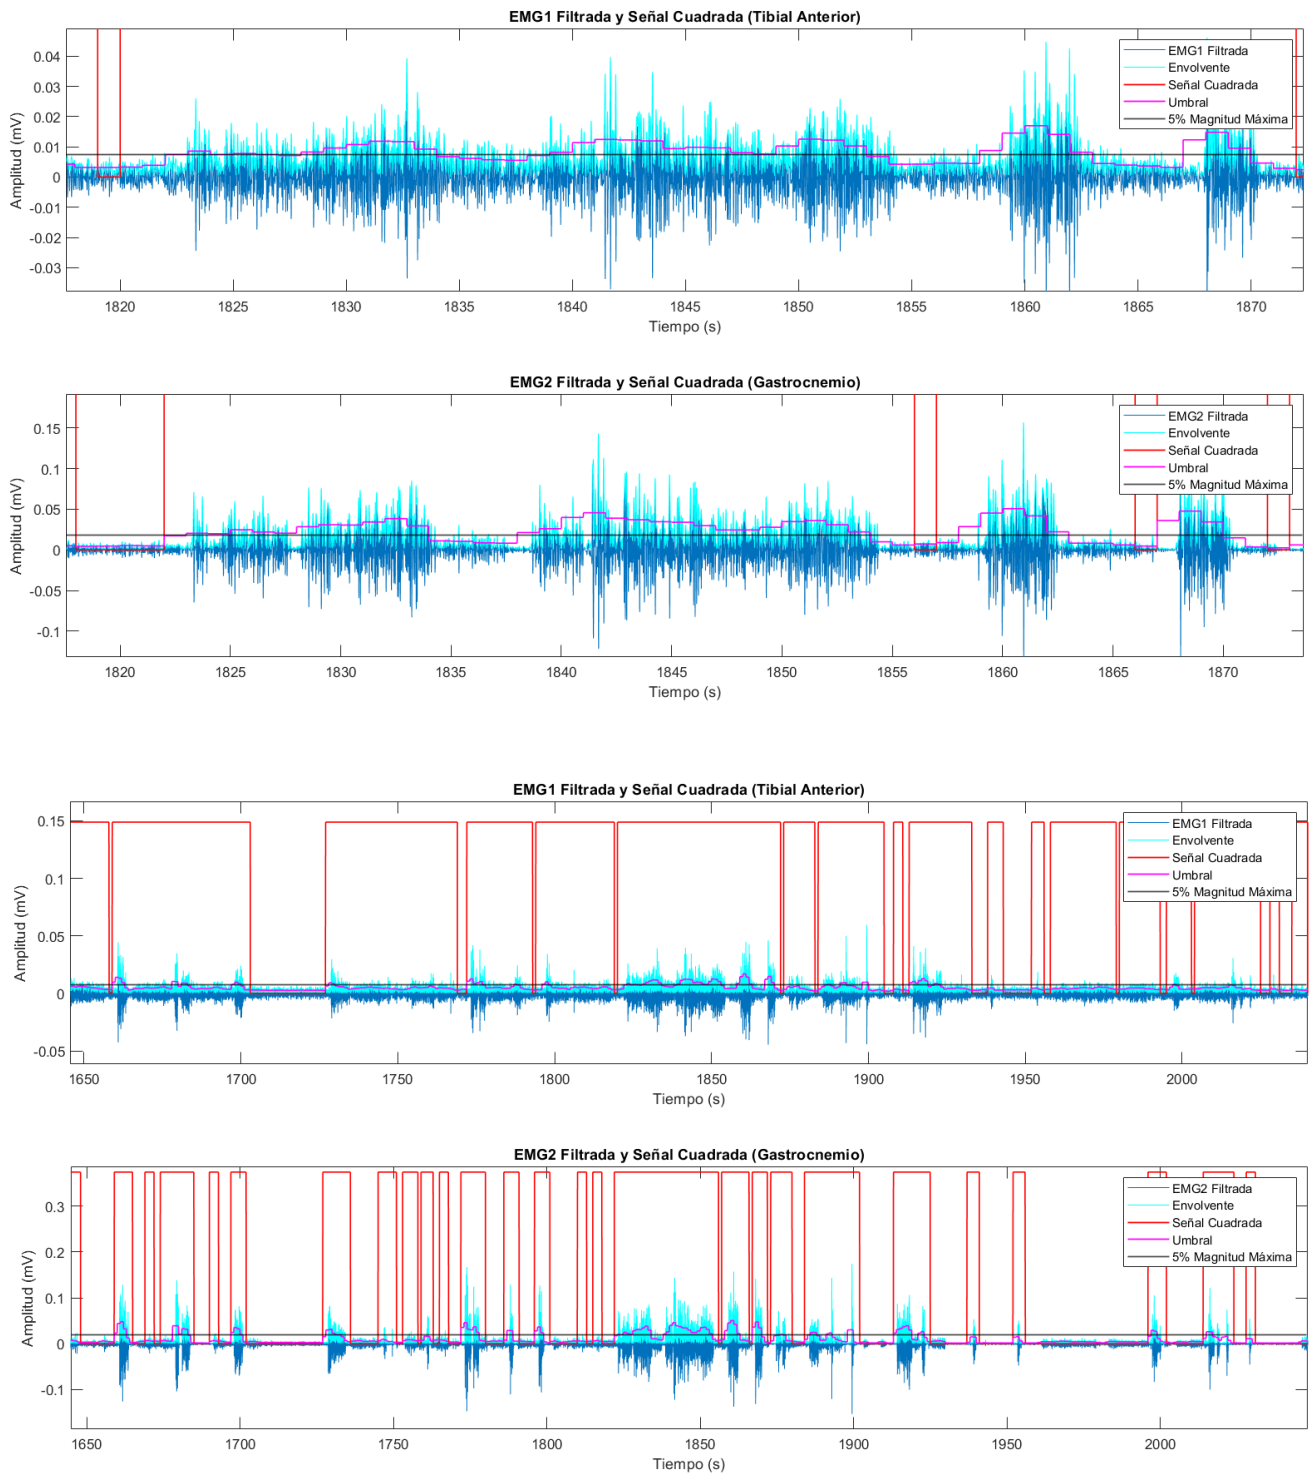
Las señales de EMG fueron analizadas mediante un enfoque basado en ventanas. Para cada ventana, se definen los índices de inicio y fin, se extraen los datos correspondientes y se calcula la envolvente de la señal utilizando la transformación de Hilbert. El umbral se establece en el valor RMS de cada ventana, junto con un porcentaje mínimo de la magnitud máxima de la señal completa. Este umbral fue ajustado experimentalmente hasta coincidir visualmente con las actividades observadas. Si algún valor

en la ventana supera el umbral, se marca la señal cuadrada correspondiente con un 1. Se visualizan las señales de EMG junto con las señales cuadradas resultantes para ambos canales de cada archivo. Estas señales cuadradas se superponen sobre las señales envolventes, facilitando la visualización de la actividad detectada. Para mejorar la claridad, la señal de actividad se escala al valor máximo de la magnitud de la señal (Figura 5.5). El archivo resultante almacena los siguientes campos:


- squareSignal: Señal cuadrada de identificación de actividad.
- envelope: Señal envolvente de la señal de EMG.
- threshold: Umbral de actividad.
- avgActivationMagnitud: Magnitud de la señal de actividad.

De manera similar, las señales FSR se analizan mediante un enfoque basado en ventanas, utilizando como umbral el valor RMS de cada ventana, junto con un factor de magnitud mínima. Este factor es mayor que el empleado en las señales EMG, debido a los cambios abruptos en los picos de activación de las FSR. Este umbral fue ajustado experimentalmente hasta que coincidió visualmente con las actividades observadas. Además de la detección de actividad, se considera la magnitud de la activación como una característica clave en el análisis (Figura 5.6). El archivo resultante almacena los siguientes campos:

- avgActivationMagnitud: Señal de actividad considerando la magnitud de la ventana.
- totalActivation: Arreglo combinado de la actividad de los 4 sensores FSR.



**Figura 5.5:** Reconocimiento de activación en señal de EMG, tanto del músculo tibial anterior (TA) (EMG1) y el gastrocnemio (Gn)(EMG2) (Visualización mediante Matlab)



**Figura 5.6:** Visualización de señal de sensores de presión FSR (Visualización mediante Matlab)

Una vez calculadas las características, se genera un archivo final que combina los resultados y los organiza por participante. Cada archivo incluye las bandas de frecuencia (delta, theta, alfa, beta, índices 1, índices 2 y índices 3) con sus respectivos canales, la frecuencia cardíaca, variabilidad de la frecuencia cardíaca y las señales de activación (EMG del Tibial Anterior y Gastrocnemio, y FSR).

## 5.4 Balance de clases

Se toman en cuenta tres clasificaciones (Alertness-0, Drowsiness-1, Drowsiness-2) basándose en tres criterios conjuntos: Periodo de interrupción (Método Brunauer–Emmett–Teller (Brunauer–Emmett–Teller method, BET), indica cuánto tiempo dura un parpadeo); Escala de somnolencia (DLs), derivado de Karolinska Sleepiness Scale (KSS), considerando un estado de alerta y dos estados de somnolencia (prematura y establecida); y Porcentaje de Cierre de Ojos (Percentage of Eye Closure) (PERCLOS), se emplea esta métrica para indicar cuánto tiempo están cerrados los párpados en un minuto. Cada segmento (de un minuto) recibe una categoría conforme a los criterios establecidos. Estos se proporcionaron a través del estudio [3]. Se extrapolan estos etiquetados a ventanas de 0.5 segundos, obteniendo un mayor rango de

datos etiquetados.

Se tiene una notable variación en el número de muestras categorizadas como niveles de somnolencia frente a las que se identificaron como estado de alerta, con proporciones del 21 % (Drowsiness-1) y 6 % (Drowsiness-2) para el bloque 2 y 30 % (Drowsiness-1) y 18 % (Drowsiness-2) para el bloque 3, en relación con el total de etiquetas de alerta. El desarrollo de un modelo de clasificación con un conjunto de datos desequilibrado puede llevar al modelo a aprender a partir de la cantidad de datos en vez de las propiedades inherentes de los datos.

**Tabla 5.2:** Cantidad de muestras de cada etiqueta antes y después de los métodos de balanceo.

Dataset	Etiqueta	Cantidad de muestras inicial	Tipo de balanceo	Cantidad de muestras final
Bloque 2	0	67800	Random	33900
	1	14280	Random	33900
	2	4320	Random	33900
Bloque 2	0	67800	SMOTE Tomek	33900
	1	14280	SMOTE Tomek	33689
	2	4320	SMOTE Tomek	33900
Bloque 2	0	67800	SMOTE ENN	16131
	1	14280	SMOTE ENN	25862
	2	4320	SMOTE ENN	33806
Bloque 3	0	49420	Random	49420
	1	29580	Random	49420
	2	17900	Random	49420
Bloque 3	0	49420	SMOTE Tomek	49420
	1	29580	SMOTE Tomek	49336
	2	17900	SMOTE Tomek	48530
Bloque 3	0	49420	SMOTE ENN	23469
	1	29580	SMOTE ENN	29224
	2	17900	SMOTE ENN	44293

**Fuente:** Elaboración propia.

Se experimentó con 3 métodos de balanceo de datos diferentes, Random Over Sampler, Técnica de

Sobresampling Synthetico de Minoridades (Técnica de Sobremuestreo de Minorías Sintéticas (Synthetic Minority Over-sampling Technique) (SMOTE)) - Edited Nearest Neighbor (Vecinos más Cercanos Editados (Edited Nearest Neighbors) (ENN)) y SMOTE - Tomek Links. Mientras que Random Over Sampler simplemente replica las muestras existentes, SMOTE-Tomek y SMOTE-ENN generan nuevas muestras y aplican técnicas de limpieza para mejorar la calidad del conjunto de datos. La diferencia entre estos ultimo dos modelos radica en la técnica de depuración de ejemplos problemáticos, mientras Tomek Links elimina las instancias de la clase mayoritaria que son cercanas a las instancias de la clase minoritaria, mejorando la separación entre las clases, mejorando el rendimiento del clasificador al reducir el ruido en los datos; ENN elimina las instancias de ambas clases que son mal clasificadas por sus vecinos más cercanos, lo que puede ayudar a mejorar la precisión del modelo [41].

## 5.5 Implementación del modelo de clasificación

Se genera un dataset final de 107 características, constituido por características extraídas de las señales fisiológicas EEG y ECG, revelando mayor eficiencia en la detección de somnolencia. Mediante la aplicación Classification Learner se crean los diferentes modelos a entrenar, teniendo la ventaja comparativa en un mismo ambiente de ejecución. Se utiliza un porcentaje de test de 20 % de los datos, división realizada mediante validación cruzada de k iteraciones, considerando  $k = 5$ . Además, se compara la selección de características al usar todas ellas y utilizando análisis de componentes principales (Análisis de Componentes Principales (Principal Component Analysis) (PCA)), esta opción mantiene suficientes componentes para explicar el 95 % de la variación. Se mantuvo la matriz de costo de clasificación errónea por defecto, donde los costos por error es uniforme.

### 5.5.1 Modelo de redes neuronales

Se configuraron 4 modelos utilizando redes neuronales, de las cuales se varia la cantidad de capas de conexión total (Fully connected layers), tamaño de la capa (Layes size, considerando una configuración media y amplia) y uso de optimizadores (Anexo B.2). A continuación, se tiene una selección reducida de los mejores resultados obtenidos por este modelo representados en las tablas 5.3 y 5.4, donde se clasifican por el tipo de balanceo empleado, uso de PCA y los valores de las métricas de precisión descuerdo a la etiqueta de somnolencia. Consultar los Anexos B.3 al B.7 para el detalle de todos los modelos.

Respecto a sus curvas de perdida, exhiben una disminución progresiva con una rápida disminución inicial y una estabilización en las últimas iteraciones, lo que señala un aprendizaje eficaz y convergencia

estable, con diferencias mínimas que reflejan un desempeño consistente entre ellos. Estos resultados sugieren que los modelos están bien entrenados (Anexo A.12). Se denota un aumento porcentual de éxito de identificación para el bloque 3, superando en una mayor cantidad de modelos propuestos la precisión global del bloque 2. Estos resultados pueden ser atribuibles a una mejor distribución de datos etiquetas de somnolencia antes del balance de clases.

**Tabla 5.3:** Modelos con mejor rendimiento de los modelos de redes neuronales para el bloque 2 (extraídos de los anexos B.3 y B.4 ) según los estados de somnolencia (Validación).

N°	Dataset	PCA	Et.	Precisión	Recall	Especificidad	F1-Score	Precisión Global
1	SMOTE ENN	-	0	85.50 %	80.10 %	96.28 %	82.71 %	86.3 %
			1	82.57 %	82.04 %	89.14 %	82.31 %	
			2	90.09 %	93.14 %	93.14 %	91.87 %	
3	SMOTE ENN	-	0	84.74 %	80.39 %	96.03 %	82.51 %	86.4 %
			1	83.25 %	81.11 %	89.77 %	82.17 %	
			2	89.9 %	94.61 %	92.93 %	92.2 %	
5	SMOTE ENN	-	0	86.41 %	79.2 %	96.59 %	82.65 %	86.7 %
			1	83.61 %	81.59 %	89.97 %	82.59 %	
			2	89.54 %	95.65 %	92.57 %	92.5 %	
<b>23</b>	<b>Random</b>	-	0	82.07 %	78.57 %	91.42 %	80.28 %	<b>86.76 %</b>
			1	80.12 %	81.80 %	89.85 %	80.95 %	
			2	97.79 %	99.91 %	98.87 %	98.84 %	

**Fuente:** Elaboración propia.

**Tabla 5.4:** Modelos con mejor rendimiento de los modelos de redes neuronales para el bloque 3 (extraídos de los anexos B.6 y B.7) según los estados de somnolencia (Validación).

N°	Dataset	PCA	Et.	Precisión	Recall	Especificidad	F1-Score	Precisión Global
8	SMOTE ENN	Si	0	92.24 %	90.38 %	97.57 %	91.3 %	90.66 %
			1	85.73 %	85.5 %	93.86 %	85.62 %	
			2	93.06 %	94.22 %	94.09 %	93.64 %	
9	SMOTE ENN	-	0	92.5 %	91.02 %	97.64 %	91.75 %	<b>91.23 %</b>
			1	86.71 %	86.21 %	94.3 %	86.46 %	
			2	93.5 %	94.65 %	94.47 %	94.07 %	
10	SMOTE ENN	Si	0	91.17 %	90.41 %	97.20 %	90.79 %	89.41 %
			1	83.9 %	83.4 %	93.10 %	83.65 %	
			2	92.08 %	92.86 %	93.29 %	92.47 %	

**Fuente:** Elaboración propia.

## 5.5.2 Modelo clasificadores de aproximación de kernel

Los clasificadores de aproximación de kernel realizan una clasificación no lineal de datos con muchas observaciones. Para datos grandes almacenados en memoria, los clasificadores basados en kernel tienden a entrenar y predecir más rápido que los clasificadores de máquinas de soporte vectorial (SVM) con kernels gaussianos.

Los modelos de clasificación con kernel gaussiano mapean los predictores de un espacio de baja dimensión a un espacio de alta dimensión y luego ajustan un modelo lineal a los predictores transformados en el espacio de alta dimensión. En este caso, se eligió ajustar a un modelo lineal SVM.

Se utiliza el método de codificación multiclase *One-vs-One*, el cual descompone un problema de clasificación con múltiples clases en una serie de subproblemas binarios. Para cada par de clases posibles, se entrena un clasificador independiente que aprende a distinguir entre esas dos clases específicas. En total, se entrenan  $c(c-1)/2$  clasificadores, donde  $c$  es el número de clases. Durante la etapa de predicción, cada subclasificador emite un voto, y la clase con el mayor número de votos es seleccionada como la predicción final. Este enfoque es eficiente y escalable, especialmente en problemas donde el número de clases no es excesivamente alto [42].

Los resultados respecto a los bloques 2 y 3 se encuentran en los Anexos B.8 y B.9, donde se describen todos los modelos implementados. Los mejores resultados se pueden visualizar en las tablas de resumen 5.5 y 5.6, donde se clasifican por el tipo de balanceo empleado, uso de PCA y los valores de las métricas de precisión descuerdo a la etiqueta de somnolencia.

**Tabla 5.5:** Modelos con mejor rendimiento de modelos de Kernel para el bloque 2 (extraído del anexo B.8) según los estados de somnolencia (Validación).

N°	Dataset	PCA	Et.	Precisión	Recall	Especificidad	F1-Scores	Precisión Global
1	SMOTE ENN	-	0	81.38 %	74.34 %	95.34 %	77.7 %	83.19 %
			1	79.32 %	78.14 %	87.22 %	78.72 %	
			2	87.49 %	92.82 %	91.17 %	90.08 %	

**Fuente:** Elaboración propia.

**Tabla 5.6:** Modelos con mejor rendimiento de modelos de Kernel para el bloque 3 (extraído del anexo B.9) según los estados de somnolencia (Validación).

N°	Dataset	PCA	Et.	Precisión	Recall	Especificidad	F1-Scores	Precisión Global
1	SMOTE ENN	-	0	86.65 %	85.17 %	95.8 %	85.9 %	85.14 %
			1	81.52 %	76.19 %	92.52 %	78.77 %	
			2	86.52 %	91.06 %	88.15 %	88.74 %	

**Fuente:** Elaboración propia.

### 5.5.3 Modelos SVM

Un SVM clasifica los datos encontrando el mejor hiperplano que separa los puntos de datos de una clase de los de la otra clase. El mejor hiperplano para un SVM es aquel que tiene el margen más grande entre las dos clases. El margen se refiere a la anchura máxima de la franja paralela al hiperplano que no contiene puntos de datos en su interior. Se implementaron dos modelos de clasificación basados en máquinas de vectores de soporte (SVM) que emplean un kernel gaussiano para manejar problemas de clasificación no lineal. La principal diferencia entre ellos radica en el parámetro de escala del kernel, el cual controla la forma de la función de decisión y, en consecuencia, la precisión y generalización del modelo:

- SVM Gaussiano Medio: Este modelo utiliza un kernel gaussiano cuya escala está definida como  $\sqrt{P}$ , donde  $P$  es el número de predictores o variables independientes del conjunto de datos. En este caso, la escala del kernel tiene un valor aproximado de 10, lo que implica que el modelo realiza distinciones más moderadas entre las clases. Es decir, el clasificador tiende a ajustarse a las relaciones generales entre los datos sin enfocarse en detalles demasiado específicos. Esto reduce el riesgo de sobreajuste en conjuntos de datos con cierto nivel de ruido, proporcionando una solución más robusta para problemas con alta variabilidad entre las observaciones.
- SVM Gaussiano Grueso: Este modelo emplea un kernel gaussiano con una escala definida como  $\sqrt{P} \times 4$ , lo que da un valor aproximado de 41. Una escala más grande significa que el modelo crea límites de decisión más amplios y realiza distinciones más generales entre las clases. Este enfoque puede ser útil en escenarios donde las diferencias entre las clases son más evidentes y no se requiere capturar variaciones más sutiles en los datos. Como resultado, el modelo se enfoca en la generalización global, sacrificando detalles en los límites de decisión [43].

La combinación del kernel gaussiano con el método One-vs-One asegura que los modelos puedan abordar tanto problemas de clasificación complejos como situaciones en las que las clases tienen relaciones más simples o lineales. Esto proporciona flexibilidad para adaptarse a distintos escenarios de datos y necesidades analíticas.

Los resultados respecto a los bloques 2 y 3 se encuentran en los Anexos B.10 y B.11, donde se describen todos los modelos implementados. Los mejores resultados se pueden visualizar en las tablas de resumen 5.7 y 5.8, donde se clasifican por el tipo de balanceo empleado, uso de PCA, tipo de distinción (media o gruesa) y los valores de las métricas de precisión descuerdo a la etiqueta de somnolencia.

**Tabla 5.7:** Modelos con mejor rendimiento de modelos de SVM para el bloque 2 (extraídos del anexo B.10) según los estados de somnolencia (Validación).

N°	Dataset	PCA	Dist.	Et.	Precisión	Recall	Especificidad	F1-Score	Precisión Global
1	<b>SMOTE ENN</b>	-	Media	0	87.45 %	80.11 %	96.85 %	83.62 %	<b>86.04 %</b>
				1	83.17 %	80.18 %	89.82 %	81.65 %	
				2	87.86 %	94.88 %	91.28 %	91.24 %	
2	SMOTE ENN	Sí	Media	0	85.07 %	68.94 %	96.68 %	76.16 %	81.02 %
				1	74.85 %	78.1 %	83.54 %	76.44 %	
				2	85.22 %	90.35 %	89.58 %	87.71 %	

**Fuente:** Elaboración propia.

**Tabla 5.8:** Modelos con mejor de rendimiento de modelos de SVM para el bloque 3 (extraídos del anexo B.11) según los estados de somnolencia (Validación).

N°	Dataset	PCA	Dist.	Et.	Precisión	Recall	Especificidad	F1-Score	Precisión Global
1	<b>SMOTE ENN</b>	-	Media	0	92.54 %	91.16 %	97.65 %	91.85 %	<b>89.13 %</b>
				1	84.72 %	80.12 %	93.77 %	82.35 %	
				2	90.06 %	93.99 %	91.28 %	91.99 %	
2	SMOTE ENN	Sí	Media	0	92.07 %	86.03 %	97.63 %	88.95 %	87.08 %
				1	82.02 %	77.98 %	92.63 %	79.95 %	
				2	87.73 %	93.64 %	89.0 %	90.59 %	
3	SMOTE ENN	-	Gruesa	0	91.14 %	73.42 %	97.72 %	81.33 %	81.46 %
				1	77.51 %	70.63 %	91.16 %	73.91 %	
				2	79.94 %	92.85 %	80.92 %	81.46 %	

**Fuente:** Elaboración propia.

## 5.6 Características relevantes

Los gráficos de dependencia parcial muestran cómo afecta cada variable o predictor a las predicciones del modelo, nos permiten visualizar la relación entre una característica específica y las predicciones del

modelo, manteniendo todas las demás características constantes, podemos ver cómo cambia el valor de la salida del modelo con distintos valores del predictor.

Mediante el cálculo de las dependencias parciales de las características, se ha determinado que las características más relacionadas con el estado de somnolencia respecto a las bandas de frecuencia. Los puntajes de cada canal respecto a su etiquetado son mostrados en la figura 5.7. Donde se puede observar una gran contribución de los canales frontales y occipitales en la determinación de los estados de somnolencia, siendo de mayor relevancia en el cálculo de potencia de las delta y theta, siendo resultados esperados de acuerdo a estudios anteriormente mencionados.

Además, se destaca la relación de los índices 1 y índices 2, que obtuvieron puntajes de relación con las etiquetas de somnolencia mayores al 0.5 de dependencia en la mayoría de los canales. El índice 3 logró una relación superior con las etiquetas para cinco canales (canales 2, 3, 9, 11 y 13), mientras que el índice 1 tuvo una relación marcada para nueve canales (canales 1, 2, 3, 4, 6, 7, 8, 14 y 16) y el índice 2 para ocho canales (canales 2, 5, 6, 11, 12, 13, 14 y 15). Sin embargo, esto significaría que los índices 1 y 2 no son tan específicos especialmente al relacionar las etiquetas con la relación de la potencia de los canales, por lo cual, se tiene un mejor definición al considerar el índice 3.

Respecto a la frecuencia cardíaca y variabilidad de la frecuencia cardíaca, muestran una relación mayor al etiquetado de somnolencia (Drowsiness-1 y Drowsiness-2) cuando los participantes se encuentran en el 70 % del rango de la frecuencia cardíaca (de 95- 102 [lpm] aproximadamente) y una variabilidad menor al 20 % del rango de variabilidad de frecuencia cardíaca (de 0.0734 a 0.0738), sin embargo, la tasa de etiquetado es compartida, con un 45.08 % (Drowsiness-2), 30.58 % (Drowsiness-1) y 24.34 % (Alertness-0).



**Figura 5.7:** Puntajes relacionados de dependencia parcial a los canales EEG y etiquetas de somnolencia, separados en las bandas de frecuencia.

## 5.7 Discusión

El informe examina los métodos de clasificación utilizados para identificar la somnolencia, poniendo especial atención en la comparación de resultados entre los bloques 2 y 3, y en la valoración de distintas técnicas y métricas de desempeño. Varios temas importantes son discutidos:

Las Redes Neuronales fueron señaladas como los más eficaces en cuanto a precisión y métricas de evaluación, obteniendo una precisión global de todos los modelos de redes neuronales 82.085 % (Bloque 2: 84.52 %, Bloque 3: 79.65 %). Las métricas de precisión, recall y especificidad se mantuvieron constantemente elevadas, lo que confirma la validez de los modelos, teniendo los mejores resultados las redes neuronales del bloque 3 (Tabla 5.9). Además, presentaron los modelos con mayores porcentajes de precisión, seguido de los modelos de SVM y basados en kernel que logran ser destacados igualmente (Tabla 5.10).

**Tabla 5.9:** Comparación de resultados de los modelos por bloque respecto su precisión global.

Modelo	Bloque 2	Bloque 3
Redes Neuronales (Global)	84.52 %	79.65 %
SVM (Global)	73.16 %	75.23 %
Kernel (Global)	75.47 %	73.74 %

**Fuente:** Elaboración propia.

**Tabla 5.10:** Comparación de los mejores resultados de los modelos por bloque respecto su precisión global.

Modelo	Bloque 2	Bloque 3
Redes Neuronales (Global)	86.76 %	91.23 %
SVM (Global)	86.04 %	89.13 %
Kernel (Global)	83.19 %	85.14 %

**Fuente:** Elaboración propia.

La manera en la que se asignan las etiquetas al principio es fundamental para el desempeño de los modelos. En el bloque 2, se notó una distribución que pudo haber restringido la capacidad de generalización de los modelos. Sin embargo, se realizaron mejoras en la distribución de datos en el bloque 3, lo que se tradujo en un aumento notable de la precisión global. En el bloque 3, los modelos de redes neuronales lograron una precisión del 91.23 % (tabla 5.12), mientras que en el bloque 2 obtuvieron un 86.76 % (tabla 5.11).

**Tabla 5.11:** Matriz de confusión del modelo con mejor precisión (modelo 23: precisión global 86.76 %) de redes de neuronales del bloque 2.

True Class \ Predicted Class	0	1	2
0	26634	6856	410
1	5814	27730	356
2	4	26	33870

**Tabla 5.12:** Matriz de confusión del modelo con mejor precisión (modelo 9: precisión global 91.23 %) de redes de neuronales del bloque 3.

True Class \ Predicted Class	0	1	2
0	17089	1424	262
1	1156	20154	2069
2	230	1665	33540

Analizando los modelos de redes neuronales, la aplicación de PCA produjo resultados variados. En ciertos casos, la precisión fue mejorada por la reducción de la dimensionalidad, aunque en otros casos, la eliminación de características clave resultó en una disminución del rendimiento. Los modelos con PCA obtuvieron una precisión del 77.51 % y 79.51 %, en contraste, el modelo sin PCA logró un 79.55 % y 79.13 %, de los bloques 2 y 3 respectivamente. Esto subraya la importancia de elegir características de manera meticulosa para conservar los patrones importantes en los datos, el detalle de cada dataset se encuentra en la tabla 5.13.

Se ha determinado, mediante el cálculo de dependencias parciales, que las características más relacionadas con el estado de somnolencia son las bandas de frecuencia delta y theta, especialmente en los canales frontales y occipitales. Los índices 1 y 2 presentan una relación moderada con las etiquetas de somnolencia (mayor a 0.5) en la mayoría de los canales, mientras que el índice 3 muestra una relación más específica con las etiquetas en cinco canales. En comparación, los índices 1 y 2 son menos específicos, por lo que se considera que el índice 3 tiene una mejor capacidad para identificar el estado de somnolencia.

**Tabla 5.13:** Comparación de resultados (precisión) de los modelos de redes neuronales por bloque, respecto al método de balanceo y uso de PCA.

Dataset	Bloque 2	Bloque 3
SMOTE ENN (sin PCA)	81.525 %	87.746 %
SMOTE ENN (con PCA)	82.7575 %	89.042 %
SMOTE Tomek (sin PCA)	75.85 %	73.9075 %
SMOTE Tomek (con PCA)	73.32 %	75.3875 %
Random (sin PCA)	81.272 %	75.746 %
Random (con PCA)	76.462 %	74.108 %

**Fuente:** Elaboración propia.

## Capítulo 6. Conclusiones

---

### 6.1 Conclusiones

Este informe ha proporcionado un análisis sobre la detección de somnolencia en conductores utilizando diferentes métodos de clasificación, incluyendo Máquinas de Soporte Vectorial (SVM), redes neuronales y modelos basados en kernel. A través de la evaluación de los resultados obtenidos, se ha podido observar que cada método presenta ventajas y desventajas en términos de precisión y efectividad.

Los modelos de redes neuronales demostraron ser los más efectivos, alcanzando una precisión del 91.23 % en el bloque 3, lo que resalta su capacidad para manejar datos complejos y no lineales. En comparación, los modelos de SVM lograron una precisión del 86.65 % en el bloque 2 y 85.17 % en el bloque 3, mientras que los modelos basados en kernel alcanzaron una precisión de 81.38 % en el bloque 2 y 86.65 % en el bloque 3. Esto sugiere que, aunque SVM y kernel son métodos robustos, las redes neuronales superan a ambos en este contexto específico.

El tipo de balanceo de datos también tuvo un impacto significativo en los resultados. La implementación de técnicas como SMOTE permitió mejorar la precisión de los modelos, alcanzando un notable 91.17 % en el bloque 3. Esto subraya la importancia de una adecuada preparación de los datos para optimizar el rendimiento del modelo.

En cuanto al uso de PCA (Análisis de Componentes Principales), se observó que, en general, los modelos que no utilizaron PCA tendieron a obtener mejores resultados en términos de precisión global. Por ejemplo, en el bloque 3, los modelos sin PCA lograron una precisión del 81.272 %, en comparación con el 79.13 % de aquellos que sí utilizaron PCA. Esto indica que, aunque PCA puede ser útil para reducir la complejidad del modelo, su aplicación debe ser considerada cuidadosamente para no sacrificar la información crítica contenida en los datos.

Se pudieron identificar canales con mayor relevancia de acuerdo a los niveles de somnolencia, destacando los canales de la región occipital (PO7, PO8, Oz, Pz) y medial frontal (Fp1, Fp2, Fz), con una mayor relación en el estado de somnolencia medio y profundo. Además, el índice con mayor relación general a los estados de somnolencia resultó ser los índices 1 y 2 en la relación con las etiquetas Drowsiness-1 y Drowsiness-2, sin embargo, se generalizan en la mayoría de los canales, por lo cual, no hay una identificación puntual de los canales más relevantes.

En conclusión, los resultados presentados en este informe han demostrado la efectividad de las redes neuronales en la detección de somnolencia, la importancia del balanceo de datos en términos de precisión, así como la necesidad de la selección cuidadosa de características de entrada en términos de rendimiento. Estos resultados, por lo tanto, forman una base sólida para experimentos y mejoras adicionales junto con la futura investigación y desarrollo de somnolencia en el campo de la detección de somnolencia en el conductor.

## 6.2 Trabajo Futuro

Para continuar mejorando los resultados obtenidos en este informe, se sugieren las siguientes líneas de trabajo futuro:

1. **Ampliación del Conjunto de Datos:** Recolectar un conjunto de datos más amplio y diverso que incluya diferentes condiciones de conducción y variaciones en las características demográficas de los participantes. Esto podría ayudar a mejorar la generalización de los modelos y generar comparaciones respecto a experiencia de conducción, rangos etarios y sexo.

2. **Exploración de Nuevas Técnicas de Clasificación:** Investigar y aplicar técnicas de aprendizaje profundo, como redes neuronales convolucionales (CNN) o redes neuronales recurrentes (RNN), que podrían ofrecer mejoras en la detección de patrones complejos en las señales fisiológicas o modelos simples de bajo costo computacional.

3. **Optimizar la cantidad de características necesarias:** Es conveniente reducir y seleccionar el conjunto de funciones y canales requeridos. Es muy importante para distinguir entre estados de vigilia y somnolencia. En este sentido, puede resultar útil utilizar técnicas como el análisis de componentes principales (PCA). Teniendo en cuenta que este estudio demostró resultados similares o incluso mejores que el uso de todas las funciones.

4. **Integración de Datos Multimodales:** La incorporación de datos contextuales además de marcadores fisiológicos aumenta la precisión y utilidad del modelo. Variables como la velocidad del vehículo, el tiempo de conducción, la hora del día y las condiciones simuladas pueden ser un factor importante en la atención del conductor y pueden enriquecer el análisis realizado.

## Glosario

---

- ApEn** Entropía Aproximada (Approximate Entropy)
- BET** Método Brunauer–Emmett–Teller (Brunauer–Emmett–Teller method)
- BP** Propagación hacia Atrás (Back Propagation)
- ECG** Electrocardiograma
- EDA** Actividad Electrodermica
- EEG** Electroencefalograma
- EMG** Electromiografía
- ENN** Vecinos más Cercanos Editados (Edited Nearest Neighbors)
- FFT** Transformada Rápida de Fourier (Fast Fourier Transform)
- FuzzyEn** Entropía Difusa (Fuzzy Entropy)
- HF** Potencia en la Banda de Alta Frecuencia
- HFD** Dimensión Fractal de Higuchi (Higuchi Fractal Dimension)
- HOS** Estadísticas de Orden Superior (Higher-Order Statistics)
- KNN** K-Vecinos Más Cercanos (K-Nearest Neighbors)
- KSS** Escala de Somnolencia de Karolinska (Karolinska Sleepiness Scale)
- LF** Potencia en la Banda de Baja Frecuencia
- LSTM** Memoria a corto-largo plazo (Long Short-Term Memory)
- MDF** Frecuencia Mediana (Median Frequency)
- MNF** Frecuencia Media (Mean Frequency)
- NSSCR** Respuestas de Conductancia de la Piel No Específicas
- PCA** Análisis de Componentes Principales (Principal Component Analysis)

**PERCLOS** Porcentaje de Cierre de Ojos (Percentage of Eye Closure)

**PSD** Densidad Espectral de Potencia (Power Spectral Density)

**RF** Bosques Aleatorios (Random Forest)

**RMS** Valor Cuadrático Medio (Root Mean Square)

**RRI** Intervalo entre Ondas R

**SampEn** Entropía Muestral (Sample Entropy)

**SCL** Nivel de Conductancia de la Piel (Skin Conductance Level)

**SCR** Respuestas de Conductancia Cutánea (Skin Conductance Response)

**SEN** Sample Entropy Normalizada (Sample Entropy Normalized)

**SMOTE** Técnica de Sobremuestreo de Minorías Sintéticas (Synthetic Minority Over-sampling Technique)

**SpEN** Entropía Espectral (Spectral Entropy)

**STFT** Transformada de Fourier de Corto Tiempo (Short-Time Fourier Transform)

**SVM** Máquinas de Soporte Vectorial (Support Vector Machines)

**TP** Potencia Total

**VFC** Variabilidad de la Frecuencia Cardíaca

## Referencias

---


- [1] S. Unidad de Estudios y Estadísticas, “Estadísticas de accidentabilidad 2023,” SUSESO, Tech. Rep., 2024.
- [2] M. P. H. Gonzalez, “Causa de siniestros (2000-2023),” Carabineros de Chile, Tech. Rep., 2024. [Online]. Available: [https://www.conaset.cl/wp-content/uploads/2024/05/Causas\\_desgregadas\\_conaset\\_carabineros2000-2023.xlsx](https://www.conaset.cl/wp-content/uploads/2024/05/Causas_desgregadas_conaset_carabineros2000-2023.xlsx)
- [3] M. P. H. Javier, “Predicción de eventos tempranos de somnolencia mediante un conjunto de datos multifactoriales en conductores de vehículos.” 2024. [Online]. Available: <https://repositorio.udec.cl/handle/11594/1475>
- [4] C. N. de Seguridad de Tránsito (CONASET), *Libro del Nuevo Conductor*. Ministerio de Transportes y Telecomunicaciones, 2019.
- [5] L. C. Mayor, J. Burneo, and J. Ochoa, *Manual de electroencefalografía: Handbook of Electroencephalography*. Ediciones Uniandes-Universidad de los Andes, 2013.
- [6] M. E. Uribe W, Duque M, *Electrocardiografía y arritmias*, E. E. L. Bogotá, Ed., 2008.
- [7] J. DiGiacinto and J. Seladi-Schulman, “Frecuencia cardíaca: Rangos, cuándo es peligroso y más,” <https://www.healthline.com/health/es/ritmo-cardiaco-peligroso>, Dec. 2021, accessed: 2024-10-10.
- [8] B. D. Carrillo Coronado and K. A. Hermida Hernández, *Principios básicos de las señales electrofisiológicas*. Bogotá :: Universidad ECCI, 2015.
- [9] S. A. Shields, K. A. MacDowell, S. B. Fairchild, and M. L. Campbell, “Is mediation of sweating cholinergic, adrenergic, or both? a comment on the literature,” *Psychophysiology*, vol. 24, no. 3, pp. 312–319, 1987. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1469-8986.1987.tb00301.x>
- [10] S. for Psychophysiological Research Ad Hoc Committee on Electrodermal Measures, “Publication recommendations for electrodermal measurements,” *Psychophysiology*, vol. 49, no. 8, pp. 1017–1034, 2012. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1469-8986.2012.01384.x>

- [11] H. F. Posada-Quintero and K. H. Chon, “Innovations in electrodermal activity data collection and signal processing: A systematic review.” *Sensors (Basel, Switzerland)*, vol. 20, Jan 2020.
- [12] G. Li and W.-Y. Chung, “Electroencephalogram-based approaches for driver drowsiness detection and management: A review.” *Sensors (Basel, Switzerland)*, vol. 22, Jan 2022.
- [13] ———, “Estimation of eye closure degree using eeg sensors and its application in driver drowsiness detection.” *Sensors (Basel, Switzerland)*, vol. 14, pp. 17 491–515, Sep 2014.
- [14] I. Stancin, N. Frid, M. Cifrek, and A. Jovic, “Eeg signal multichannel frequency-domain ratio indices for drowsiness detection based on multicriteria optimization.” *Sensors (Basel, Switzerland)*, vol. 21, Oct 2021.
- [15] I. Stancin, M. Cifrek, and A. Jovic, “A review of eeg signal features and their application in driver drowsiness detection systems.” *Sensors (Basel, Switzerland)*, vol. 21, May 2021.
- [16] E. Tobaldini, L. Nobili, S. Strada, K. R. Casali, A. Braghiroli, and N. Montano, “Heart rate variability in normal and pathological sleep.” *Frontiers in physiology*, vol. 4, p. 294, Oct 2013.
- [17] A. T. Satti, J. Kim, E. Yi, H.-Y. Cho, and S. Cho, “Microneedle array electrode-based wearable emg system for detection of driver drowsiness through steering wheel grip.” *Sensors (Basel, Switzerland)*, vol. 21, Jul 2021.
- [18] R. Merletti and D. Farina, *Single-Channel Techniques for Information Extraction from the Surface EMG Signal*, 2016, pp. 91–125.
- [19] H. F. Posada-Quintero, N. Reljin, C. Mills, I. Mills, J. P. Florian, J. L. VanHeest, and K. H. Chon, “Time-varying analysis of electrodermal activity during exercise.” *PloS one*, vol. 13, p. e0198328, 2018.
- [20] T. Chaspari, A. Tsiartas, L. I. Stein Duker, S. A. Cermak, and S. S. Narayanan, “Eda-gram: designing electrodermal activity fingerprints for visualization and feature extraction.” *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference*, vol. 2016, pp. 403–406, Aug 2016.
- [21] D. Looney, P. Kidmose, C. Park, M. Ungstrup, M. L. Rank, K. Rosenkranz, and D. P. Mandic, “The in-the-ear recording concept: User-centered and wearable brain monitoring,” *IEEE Pulse*, vol. 3, no. 6, pp. 32–42, 2012.


- [22] S. Hong, H. Kwon, S. H. Choi, and K. S. Park, "Intelligent system for drowsiness recognition based on ear canal electroencephalography with photoplethysmography and electrocardiography," *Information Sciences*, vol. 453, pp. 302–322, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0020025518302561>
- [23] J. Min, P. Wang, and J. Hu, "Driver fatigue detection through multiple entropy fusion analysis in an eeg-based system." *PloS one*, vol. 12, p. e0188756, 2017.
- [24] Y. Jiao, Y. Deng, Y. Luo, and B.-L. Lu, "Driver sleepiness detection from eeg and eog signals using gan and lstm networks," *Neurocomputing*, vol. 408, pp. 100–111, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0925231220303325>
- [25] J. Hu, "Automated detection of driver fatigue based on adaboost classifier with eeg signals." *Frontiers in computational neuroscience*, vol. 11, p. 72, 2017.
- [26] J. Chen, H. Wang, and C. Hua, "Assessment of driver drowsiness using electroencephalogram signals based on multiple functional brain networks," *International Journal of Psychophysiology*, vol. 133, pp. 120–130, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167876018302939>
- [27] —, "Electroencephalography based fatigue detection using a novel feature fusion and extreme learning machine," *Cognitive Systems Research*, vol. 52, pp. 715–728, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1389041718303681>
- [28] B. M. Gimbada and D. Rodenstein, "[assessment of sleepiness]." *Archivos de bronconeumologia*, vol. 45, pp. 349–51, Jul 2009.
- [29] K. Fujiwara, E. Abe, K. Kamata, C. Nakayama, Y. Suzuki, T. Yamakawa, T. Hiraoka, M. Kano, Y. Sumi, F. Masuda, M. Matsuo, and H. Kadotani, "Heart rate variability-based driver drowsiness detection and its validation with eeg," *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 6, pp. 1769–1778, 2019.
- [30] G. Li and W.-Y. Chung, "Detection of driver drowsiness using wavelet analysis of heart rate variability and a support vector machine classifier." *Sensors (Basel, Switzerland)*, vol. 13, pp. 16 494–511, Dec 2013.
- [31] J. Shukla, M. Barreda-Ángeles, J. Oliver, and D. Puig, "Efficient wavelet-based artifact removal for electrodermal activity in real-world applications," *Biomedical Signal Processing and Control*, vol. 42, pp. 45–52, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1746809418300090>

- [32] A. Amidei, S. Spinsante, G. Iadarola, S. Benatti, F. Tramarin, P. Pavan, and L. Rovati, “Driver drowsiness detection: A machine learning approach on skin conductance,” *Sensors*, vol. 23, no. 8, 2023. [Online]. Available: <https://www.mdpi.com/1424-8220/23/8/4004>
- [33] I. Inc., *MPU-9250 Product Specification Revision 1.1*, 2016.
- [34] “MATLAB,” <https://la.mathworks.com/products/matlab.html>, accessed: 2024-6-7.
- [35] “Signal Processing Toolbox Add-On,” 7 2021. [Online]. Available: <https://www.mathworks.com/matlabcentral/fileexchange/96108-signal-processing-toolbox-add-on>
- [36] F. C. Feed, Manage Following, and Communication Preferences, “EEGLAB,” [https://la.mathworks.com/matlabcentral/fileexchange/56415-eeglab?s\\_tid=ta\\_fx\\_results](https://la.mathworks.com/matlabcentral/fileexchange/56415-eeglab?s_tid=ta_fx_results), May 2024, accessed: 2024-6-7.
- [37] “Classification learner.” [Online]. Available: <https://la.mathworks.com/help/stats/classificationlearner-app.html>
- [38] “Parallel Computing Toolbox.” [Online]. Available: <https://la.mathworks.com/products/parallel-computing.html>
- [39] B. T. Jap, S. Lal, P. Fischer, and E. Bekiaris, “Using eeg spectral components to assess algorithms for detecting fatigue,” *Expert Systems with Applications*, vol. 36, no. 2, Part 1, pp. 2352–2359, 2009. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0957417407006914>
- [40] G. Seguimiento and P. De comunicación, “ECG QRS detection,” [https://la.mathworks.com/matlabcentral/fileexchange/57836-ecg-qrs-detection?s\\_tid=prof\\_contriblnk](https://la.mathworks.com/matlabcentral/fileexchange/57836-ecg-qrs-detection?s_tid=prof_contriblnk), Jun. 2016, accessed: 2024-10-10.
- [41] R. Ghorbani and R. Ghousi, “Comparing different resampling methods in predicting students’ performance using machine learning techniques,” *IEEE access*, vol. 8, pp. 67 899–67 911, 2020.
- [42] J. Milgram, M. Cheriet, and R. Sabourin, ““One Against One” or “One Against All”: Which One is Better for Handwriting Recognition with SVMs?” in *Tenth International Workshop on Frontiers in Handwriting Recognition*, G. Lorette, Ed., Université de Rennes 1. La Baule (France): Suvisoft, Oct. 2006, <http://www.suvisoft.com>. [Online]. Available: <https://inria.hal.science/inria-00103955>
- [43] “Choose Classifier Options.” [Online]. Available: [https://la.mathworks.com/help/stats/choose-a-classifier.html#mw\\_cdbdc267-a5ed-419b-a46f-7217cc1132ef](https://la.mathworks.com/help/stats/choose-a-classifier.html#mw_cdbdc267-a5ed-419b-a46f-7217cc1132ef)

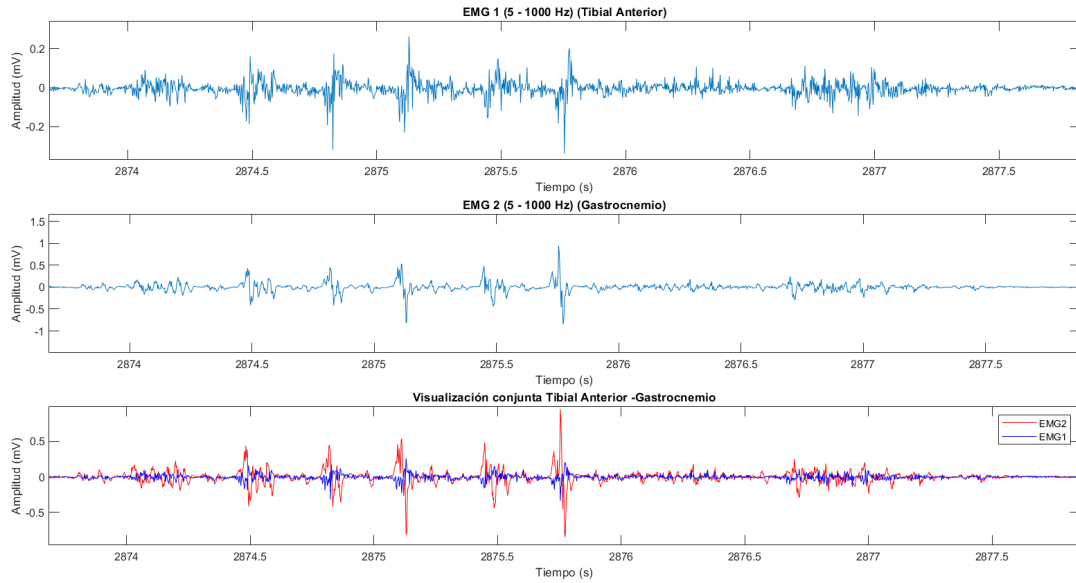
## Anexo A. Imágenes de Preprocesamiento



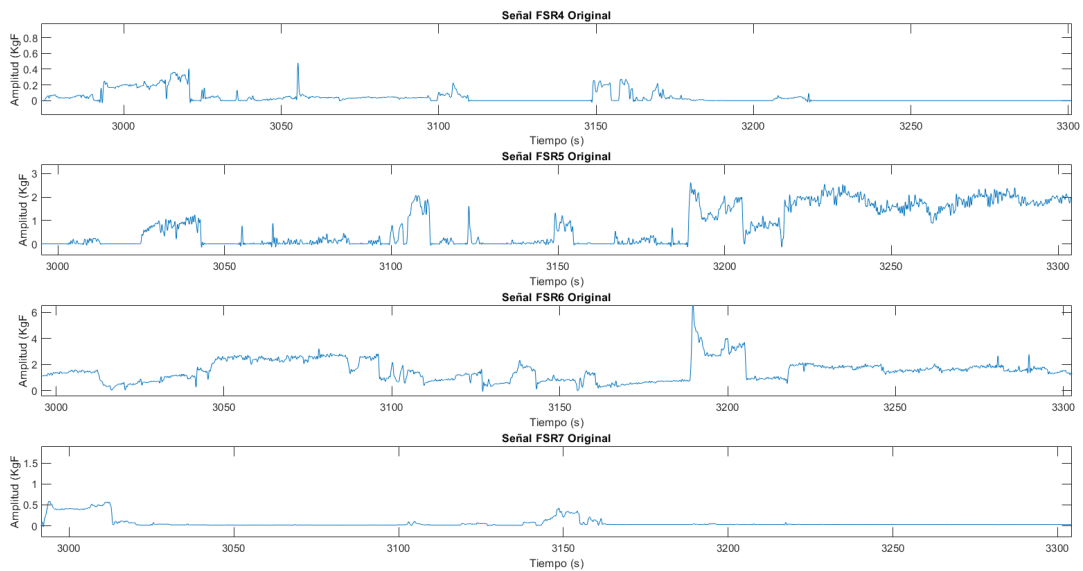
**Figura A.1:** Visualización de señal EEG sin procesar, con sus 16 canales simultáneamente. Visualización aumentada en un segmento de 5 segundos (Visualización mediante Matlab EEGLAB)




**Figura A.2:** Visualización de anomalías identificadas en de señal de ECG (Visualización mediante Matlab)




**Figura A.3:** Visualización de ambas señales de EMG de forma conjunta (Visualización mediante Matlab)




**Figura A.4:** Visualización inicial de las señales FSR (Visualización mediante Matlab)



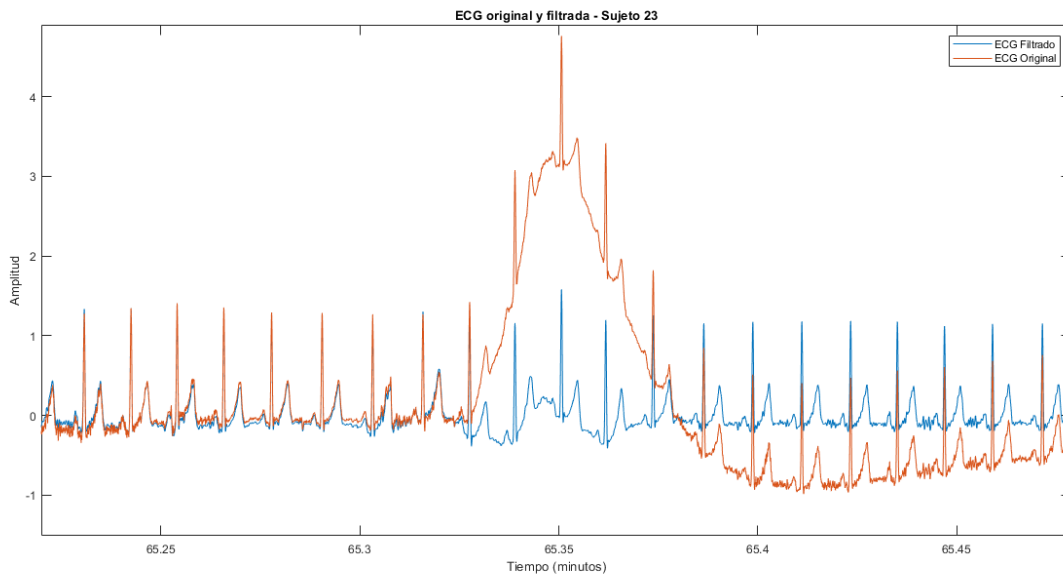
**Figura A.5:** Visualización de la señal EDA (GSR) completa (Visualización mediante Matlab)



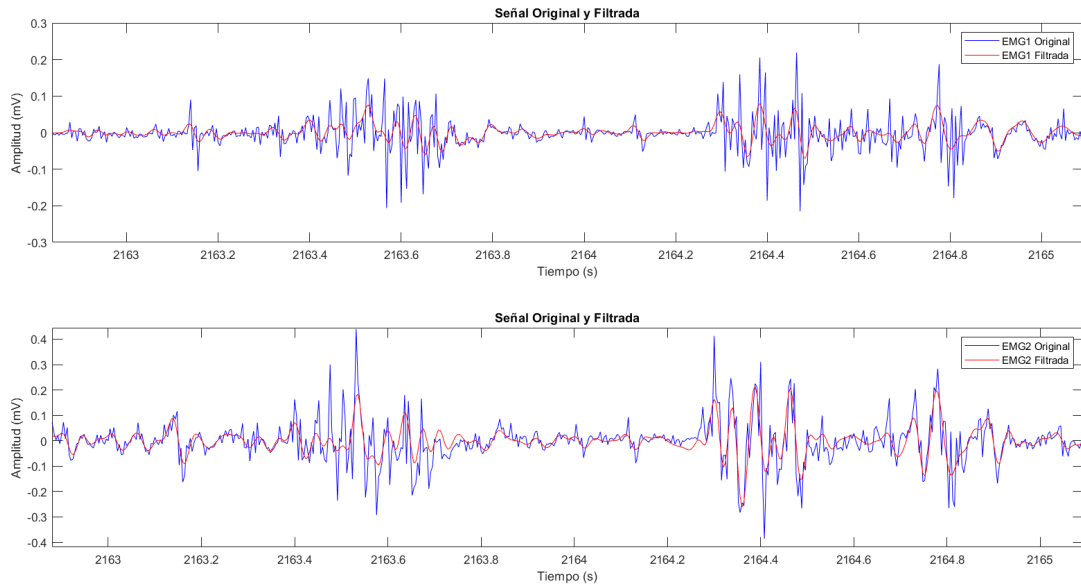
**Figura A.6:** Visualización comparativa de las señales de ECG (señal superior) y EDA (GSR) (señal inferior) en un segmento aumentado de 10 segundos (Visualización mediante Matlab)




**Figura A.7:** Visualización de las señales de EEG Pre-procesada (Visualización mediante Matlab EEGLAB).



**Figura A.8:** Visualización de la señal de ECG original y filtrada respecto a anomalía (Visualización mediante Matlab).



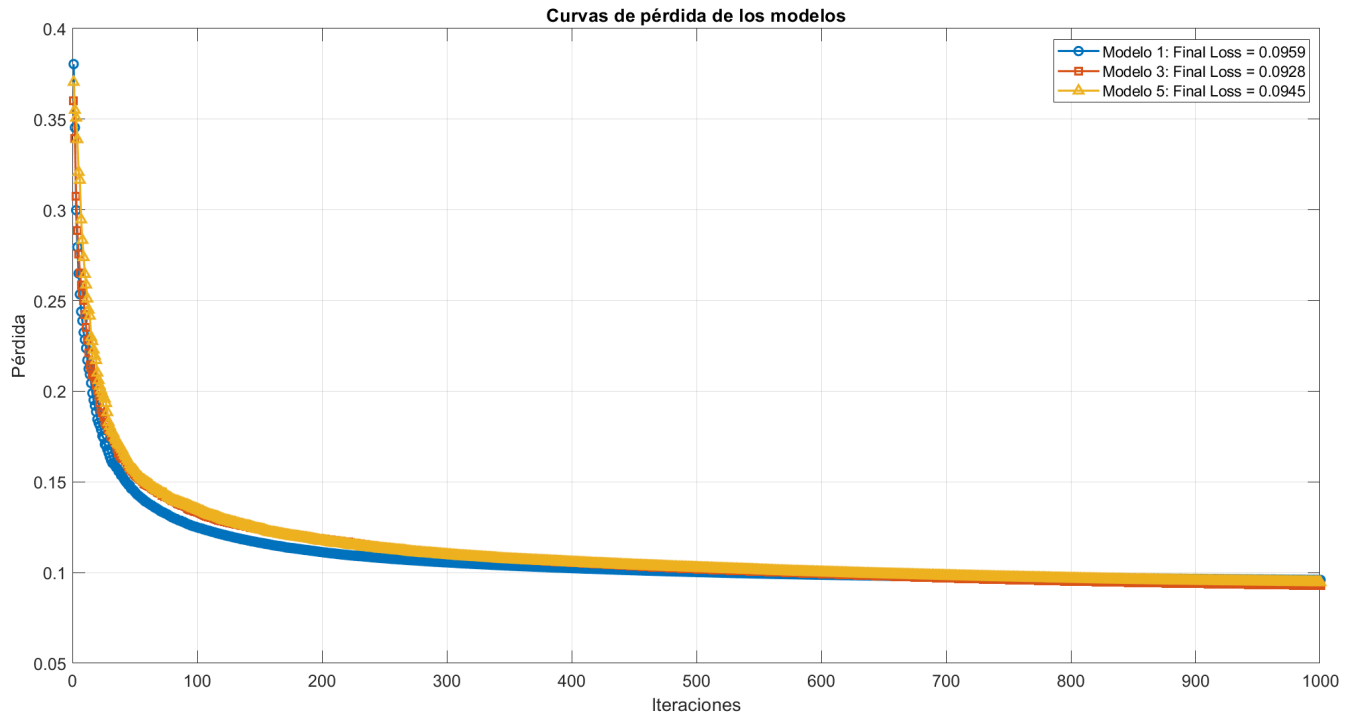
**Figura A.9:** Visualización comparativa de las señales de EMG en su versión original y una vez filtrada (Visualización mediante Matlab).



**Figura A.10:** Visualización comparativa de las señales de FSR en su versión original y una vez filtrada (Visualización mediante Matlab).



**Figura A.11:** Visualización comparativa de las señales de EDA original completa (amarillo) y preprocesada (azul). Visualización aumentada en un segmento de 18 segundos (Visualización mediante Matlab).



**Figura A.12:** Curvas de pérdida de los modelos de redes neuronales del bloque 2 (Visualización mediante Matlab).



## Anexo B. Tablas

**Tabla B.1:** Datos por archivo. Revisión de datos contenidos en los archivos del equipo Nautilus, donde "x" corresponde a los seleccionados y " - " a los no seleccionados

Nombre Archivo	Canales															
	Fp1	Fp2	F3	Fz	F4	T7	C3	Cz	C4	T8	P3	Pz	P4	PO7	PO8	Oz
record_nt																
20220811_am	x	-	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20220818_am	x	x	x	x	x	x	x	-	x	-	x	x	x	x	x	x
20220822_am	x	x	x	x	x	x	x	x	-	x	x	x	x	x	x	x
20220823_am	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20220829_pm	x	x	x	x	x	x	x	-	x	-	x	x	x	x	-	x
20220906_am	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20220908_am	x	x	x	x	x	x	x	-	x	x	x	x	x	x	x	x
20220909_pm	x	-	x	x	x	-	x	x	x	x	x	x	x	x	x	-
20220912_am	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	-
20220915_am	x	x	x	x	x	x	x	x	x	-	x	x	x	-	-	-
20220923_pm	x	x	-	x	x	x	x	x	x	-	x	-	x	x	x	-
20220930_pm	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	-
20221007_pm	-	x	x	x	x	-	x	x	x	-	x	x	x	-	-	x
20221011_am	x	x	x	x	x	x	x	-	x	-	x	x	x	x	x	x
20221013_am	x	-	x	x	x	x	x	-	x	x	x	x	x	x	x	x
20221014_pm	x	-	x	x	x	x	x	-	x	x	x	x	x	x	x	x
20221018_am	x	-	x	x	x	x	x	-	x	x	x	x	x	x	x	x
20221020_am	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20221020_pm	x	x	x	x	x	x	x	x	-	-	x	x	x	x	x	x
20221021_pm	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20221024_am	x	x	x	x	x	x	x	-	x	x	x	x	x	x	x	x
20221024_pm	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20221025_am	x	x	x	x	x	x	x	-	x	-	x	x	x	x	x	x
20221027_am	x	x	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20221027_pm	-	-	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20221103_am	x	-	x	x	x	x	x	x	x	x	x	x	x	x	x	x
20221107_am	-	-	x	x	x	x	x	x	x	-	x	x	x	x	x	x
20221107_am	-	-	x	x	x	-	x	x	x	-	x	x	x	x	x	x
20221110_pm	x	x	x	x	x	x	x	x	x	-	x	x	x	x	-	x
20221111_pm	x	x	x	x	x	x	x	x	x	-	x	x	x	-	x	x

Fuente: Elaboración propia.

**Tabla B.2:** Tabla resumen de hiperparámetros de los modelos de Redes Neuronales Bloque 2

Nº	Dataset	PCA	Fully connected layers	Layes size	Optimizado, Activación
1	SMOTE ENN	-	1	25	-
2	SMOTE ENN	Si	1	25	-
3	SMOTE ENN	-	2	25, 10	-
4	SMOTE ENN	Si	2	25, 10	-
5	SMOTE ENN	-	3	25, 10, 10	-
6	SMOTE ENN	Si	3	25, 10, 10	-
7	SMOTE ENN	-	2	2,1	Bayesiano, Tanh
8	SMOTE ENN	Si	1	34	Bayesiano, ReLU
9	SMOTE Tomek	-	1	25	-
10	SMOTE Tomek	Si	1	25	-
11	SMOTE Tomek	-	2	25, 10	-
12	SMOTE Tomek	Si	2	25, 10	-
13	SMOTE Tomek	-	3	25, 10, 10	-
14	SMOTE Tomek	Si	3	25, 10, 10	-
15	SMOTE Tomek	-	3	17, 153, 93	Bayesiano, Ninguno
16	SMOTE Tomek	Si	3	17,153,97	Bayesiano, Ninguno
17	Random	-	1	25	-
18	Random	Si	1	25	-
19	Random	-	2	25, 10	-
20	Random	Si	2	25, 10	-
21	Random	-	3	25, 10, 10	-
22	Random	Si	3	25, 10, 10	-
23	Random	-	1	100	-
24	Random	Si	1	100	-
25	Random	-	2	64, 2	Bayesiano, Sigmoid
26	Random	Si	2	13, 89	Bayesiano, Sigmoid

**Fuente:** Elaboración propia.

**Tabla B.3:** Rendimiento de los Modelos de Redes Neuronales Bloque 2 (Validación) - Parte 1

N°	Precisión	Recall	Especificidad	F1-Score	Precisión Global
1	85.50 %	80.10 %	96.28 %	82.71 %	86.3 %
	82.57 %	82.04 %	89.14 %	82.31 %	
	90.09 %	93.14 %	93.14 %	91.87 %	
2	83.25 %	76.83 %	95.76 %	79.91 %	82.0 %
	77.49 %	75.60 %	86.23 %	76.54 %	
	85.34 %	90.88 %	89.61 %	88.02 %	
3	84.74 %	80.39 %	96.03 %	82.51 %	86.4 %
	83.25 %	81.11 %	89.77 %	82.17 %	
	89.9 %	94.61 %	92.93 %	92.2 %	
4	82.43 %	78.03 %	95.44 %	80.17 %	82.8 %
	79.06 %	75.89 %	87.39 %	77.44 %	
	86.31 %	92.13 %	90.28 %	89.13 %	
5	86.41 %	79.2 %	96.59 %	82.65 %	86.7 %
	83.61 %	81.59 %	89.97 %	82.59 %	
	89.54 %	95.65 %	92.57 %	92.5 %	
6	83.55 %	75.94 %	95.9 %	79.56 %	82.9 %
	78.64 %	76.52 %	86.96 %	77.56 %	
	86.22 %	92.69 %	90.14 %	89.33 %	
7	58.38 %	41.32 %	91.93 %	48.39 %	66.7 %
	57.16 %	59.71 %	71.93 %	58.4 %	
	78.1 %	87.04 %	83.77 %	82.33 %	
8	83.26 %	77.77 %	95.71 %	95.71 %	83.33 %
	79.14 %	77.58 %	87.17 %	78.35 %	
	87.11 %	91.87 %	90.96 %	89.43 %	
9	78.41 %	76.64 %	89.44 %	77.52 %	79.6 %
	70.87 %	68.32 %	85.97 %	69.57 %	
	88.55 %	93.73 %	93.94 %	91.06 %	
10	75.37 %	75.51 %	87.66 %	75.44 %	75.9 %
	66.34 %	60.66 %	84.62 %	63.37 %	
	84.34 %	91.40 %	91.51 %	87.73 %	
11	79.77 %	74.68 %	90.53 %	77.14 %	79.6 %
	70.25 %	69.97 %	85.20 %	70.11 %	
	88.16 %	94.14 %	93.68 %	91.05 %	
12	75.87 %	74.19 %	88.20 %	75.02 %	76.4 %
	67.22 %	61.70 %	84.96 %	64.34 %	
	84.44 %	93.23 %	91.41 %	88.62 %	

Fuente: Elaboración propia.

**Tabla B.4:** Rendimiento de los Modelos de Redes Neuronales Bloque 2 (Validación) - Parte 2

N°	Precisión	Recall	Especificidad	F1-Score	Precisión Global
13	79.21 %	75.53 %	90.08 %	77.32 %	79.4 %
	70.42 %	68.38 %	85.64 %	69.38 %	
	87.75 %	94.36 %	93.41 %	90.93 %	
14	75.79 %	75.25 %	87.98 %	75.52 %	76.2 %
	66.81 %	61.39 %	84.76 %	63.99 %	
	84.58 %	92.04 %	91.60 %	88.15 %	
15	64.06 %	66.92 %	81.22 %	65.46 %	64.8 %
	53.71 %	49.22 %	78.80 %	51.37 %	
	75.25 %	78.18 %	87.14 %	76.68 %	
16	64.06 %	66.92 %	81.22 %	65.46 %	64.78 %
	53.71 %	49.22 %	78.80 %	51.37 %	
	75.25 %	78.18 %	87.14 %	76.68 %	
17	76.42 %	75.87 %	88.29 %	76.14 %	78.5 %
	70.05 %	65.26 %	86.05 %	67.57 %	
	87.77 %	94.39 %	93.42 %	90.96 %	
18	73.24 %	75.09 %	86.28 %	74.16 %	73.9 %
	64.25 %	55.89 %	84.45 %	59.78 %	
	82.19 %	90.80 %	90.16 %	86.28 %	
19	76.29 %	76.25 %	88.15 %	76.27 %	78.5 %
	70.25 %	64.40 %	86.36 %	67.20 %	
	87.42 %	94.73 %	93.19 %	90.93 %	
20	73.30 %	76.47 %	86.03 %	74.85 %	75.62 %
	67.98 %	55.94 %	86.90 %	61.38 %	
	83.29 %	94.35 %	90.51 %	88.48 %	
21	76.82 %	74.53 %	88.76 %	75.66 %	78.6 %
	69.99 %	65.54 %	85.95 %	67.69 %	
	87.52 %	95.70 %	93.18 %	91.43 %	
22	73.50 %	74.69 %	86.54 %	74.09 %	75.1 %
	66.37 %	57.16 %	85.52 %	61.42 %	
	83.37 %	93.59 %	90.67 %	88.19 %	
23	82.07 %	78.57 %	91.42 %	80.28 %	86.76 %
	80.12 %	81.80 %	89.85 %	80.95 %	
	97.79 %	99.91 %	98.87 %	98.84 %	
24	76.66 %	76.26 %	88.39 %	76.46 %	83.4 %
	76.72 %	74.35 %	88.72 %	75.51 %	
	96.07 %	99.52 %	97.96 %	97.76 %	
25	77.25 %	77.65 %	88.57 %	77.45 %	83.6 %
	77.86 %	73.52 %	89.54 %	75.63 %	
	94.87 %	99.66 %	97.31 %	97.21 %	
26	73.69 %	75.68 %	86.49 %	74.67 %	74.29 %
	64.62 %	56.64 %	84.49 %	60.37 %	
	82.58 %	90.53 %	90.45 %	86.37 %	

Fuente: Elaboración propia.

**Tabla B.5:** Tabla resumen de hiperparámetros de los modelos de Redes Neuronales Bloque 3

Nº	Dataset	PCA	Fully connected layers	Layes size	Optimizado , Activación
1	SMOTE ENN	-	1	25	-
2	SMOTE ENN	Si	1	25	-
3	SMOTE ENN	-	2	25, 10	-
4	SMOTE ENN	Si	2	25, 10	-
5	SMOTE ENN	-	3	25, 10, 10	-
6	SMOTE ENN	Si	3	25, 10, 10	-
7	SMOTE ENN	-	3	17,153,97	Bayesiano, Ninguna
8	SMOTE ENN	Si	2	49,138	Bayesiano, ReLu
9	SMOTE ENN	-	1	100	-
10	SMOTE ENN	Si	1	100	-
11	SMOTE Tomek	-	1	25	-
12	SMOTE Tomek	Si	1	25	-
13	SMOTE Tomek	-	2	25, 10	-
14	SMOTE Tomek	Si	2	25, 10	-
15	SMOTE Tomek	-	3	25, 10, 10	-
16	SMOTE Tomek	Si	3	25, 10, 10	-
17	SMOTE Tomek	-	2	2, 9	Bayesiano, ReLU
18	SMOTE Tomek	Si	3	62, 177, 16	Bayesiano, ReLU
19	Random	-	1	25	-
20	Random	Si	1	25	-
21	Random	-	2	25, 10	-
22	Random	Si	2	25, 10	-
23	Random	-	3	25, 10, 10	-
24	Random	Si	3	25, 10, 10	-
25	Random	-	1	100	-
26	Random	Si	1	100	-
27	Random	-	2	6, 218	Bayesiano, ReLU
28	Random	Si	3	3, 25, 15	Bayesiano, ReLU

**Fuente:** Elaboración propia.

**Tabla B.6:** Rendimiento de los Modelos de Redes Neuronales Bloque 3 (Validación) - Parte 1

N°	Precisión	Recall	Especificidad	F1-Score	Precisión Global
1	91.52 %	91.81 %	97.28 %	91.66 %	88.8 %
	83.63 %	80.66 %	93.19 %	82.12 %	
	90.64 %	90.64 %	92.62 %	91.62 %	
2	90.98 %	91.80 %	97.10 %	91.39 %	88.37 %
	83.36 %	79.22 %	93.18 %	81.24 %	
	90.07 %	92.59 %	91.41 %	91.31 %	
3	91.62 %	91.69 %	97.32 %	91.65 %	88.97 %
	84.0 %	80.53 %	93.38 %	82.23 %	
	90.68 %	93.11 %	91.95 %	91.88 %	
4	90.61 %	92.24 %	96.95 %	91.42 %	88.23 %
	84.09 %	78.0 %	93.64 %	80.93 %	
	89.43 %	92.85 %	90.77 %	91.11 %	
5	91.0 %	92.46 %	97.08 %	91.72 %	88.85 %
	84.67 %	79.2 %	93.82 %	81.84 %	
	90.22 %	93.3 %	91.5 %	91.73 %	
6	90.57 %	92.76 %	96.92 %	91.65 %	88.54 %
	84.7 %	78.05 %	93.92 %	81.24 %	
	89.72 %	93.22 %	91.03 %	91.44 %	
7	86.22 %	76.59 %	96.09 %	81.12 %	80.88 %
	75.63 %	72.25 %	89.96 %	73.9 %	
	81.61 %	88.85 %	83.17 %	85.07 %	
8	92.24 %	90.38 %	97.57 %	91.3 %	90.66 %
	85.73 %	85.5 %	93.86 %	85.62 %	
	93.06 %	94.22 %	94.09 %	93.64 %	
9	92.5 %	91.02 %	97.64 %	91.75 %	91.23 %
	86.71 %	86.21 %	94.3 %	86.46 %	
	93.5 %	94.65 %	94.47 %	94.07 %	
10	91.17 %	90.41 %	97.2 % 93.1 %	90.79 %	89.41 %
	83.9 %	83.4 %	93.29 %	83.65 %	
	92.08 %	92.86 %		92.47 %	
11	78.78 %	74.27 %	89.90 %	76.46 %	75.65 %
	67.75 %	65.80 %	84.61 %	66.77 %	
	79.87 %	86.71 %	88.99 %	83.15 %	
12	78.78 %	73.54 %	90.0 %	76.07 %	75.14 %
	67.40 %	65.29 %	84.48 %	66.33 %	
	78.77 %	86.45 %	88.26 %	75.14 %	

Fuente: Elaboración propia.

**Tabla B.7:** Rendimiento de los Modelos de Redes Neuronales Bloque 3 (Validación) - Parte 2

N°	Precisión	Recall	Especificidad	F1-Score	Precisión Global
13	79.45 %	74.04 %	90.33 %	76.65 %	76.01 %
	68.81 %	65.72 %	85.36 %	67.23 %	
	79.21 %	88.10 %	88.35 %	83.42 %	
14	79.44 %	73.53 %	90.39 %	76.37 %	75.46 %
	68.04 %	65.21 %	84.95 %	66.60 %	
	78.42 %	87.48 %	87.88 %	82.7 %	
15	79.38 %	74.99 %	90.17 %	77.13 %	75.99 %
	68.62 %	65.60 %	85.26 %	67.08 %	
	79.38 %	87.21 %	88.59 %	83.11 %	
16	78.99 %	73.44 %	90.13 %	76.11 %	75.15 %
	67.8 %	64.58 %	84.93 %	66.15 %	
	78.12 %	87.27 %	87.69 %	82.44 %	
17	76.76 %	62.35 %	90.47 %	68.81 %	67.98 %
	57.68 %	60.78 %	78.09 %	59.19 %	
	71.09 %	80.71 %	83.47 %	75.60 %	
18	77.56 %	71.23 %	89.60 %	74.26 %	75.80 %
	67.17 %	69.72 %	83.25 %	68.42 %	
	82.68 %	86.35 %	90.89 %	84.48 %	
19	78.49 %	73.56 %	89.92 %	75.95 %	75.23 %
	67.62 %	65.48 %	84.32 %	66.53 %	
	79.16 %	86.64 %	88.59 %	82.73 %	
20	78.22 %	72.63 %	89.89 %	75.32 %	74.5 %
	66.99 %	64.36 %	84.14 %	65.65 %	
	77.89 %	86.51 %	87.97 %	81.97 %	
21	79.81 %	72.66 %	90.81 %	76.06 %	75.70 %
	68.69 %	65.71 %	85.02 %	67.17 %	
	78.33 %	88.75 %	87.73 %	83.22 %	
22	78.91 %	72.26 %	90.34 %	75.44 %	74.84 %
	67.82 %	64.34 %	84.74 %	66.04 %	
	77.42 %	87.92 %	87.18 %	82.34 %	
23	78.95 %	73.83 %	90.16 %	76.31 %	76.01 %
	69.5 %	65.53 %	85.62 %	67.46 %	
	79.04 %	88.68 %	88.24 %	83.58 %	
24	79.57 %	72.58 %	90.68 %	75.91 %	75.24 %
	67.91 %	65.24 %	84.58 %	66.55 %	
	77.98 %	87.89 %	87.59 %	82.64 %	
25	77.68 %	73.93 %	89.38 %	75.75 %	77.17 %
	70.03 %	69.11 %	85.21 %	69.57 %	
	83.35 %	88.46 %	91.16 %	85.83 %	
26	77.72 %	73.2 %	89.5 %	75.39 %	75.78 %
	68.04 %	67.32 %	84.19 %	67.68 %	
	81.23 %	86.81 %	89.97 %	83.93 %	
27	78.41 %	72.5 %	90.02 %	75.34 %	74.62 %
	67.87 %	64.43 %	84.75 %	66.1 %	
	77.2 %	86.94 %	87.16 %	81.78 %	
28	75.91 %	64.98 %	89.69 %	70.02 %	70.18 %
	64.3 %	58.21 %	83.84 %	61.1 %	
	70.51 %	87.35 %	81.74 %	78.03 %	

Fuente: Elaboración propia.

**Tabla B.8:** Tabla resumen de rendimiento de modelos de Kernel para el Bloque 2 según los estados de somnolencia (Validación)

N°	Dataset	PCA	Precisión	Recall	Especificidad	F1-Scores	Precisión Global
1	SMOTE ENN	-	81.38 %	74.34 %	95.34 %	77.7 %	83.19 %
			79.32 %	78.14 %	87.22 %	78.72 %	
			87.49 %	92.82 %	91.17 %	90.08 %	
2	SMOTE ENN	Sí	73.27 %	64.33 %	93.57 %	68.51 %	76.16 %
			70.5 %	72.94 %	80.86 %	71.7 %	
			82.96 %	85.64 %	88.3 %	84.28 %	
3	SMOTE Tomek	-	77.1 %	75 %	87.5 %	74.94 %	77.1 %
			68.9 %	64.96 %	85.35 %	66.87 %	
			86.53 %	91.57 %	92.87 %	88.98 %	
4	SMOTE Tomek	Sí	67.56 %	70.21 %	83.14 %	68.86 %	70.1 %
			60.72 %	57.69 %	81.35 %	59.17 %	
			81.51 %	82.39 %	90.65 %	81.95 %	
5	Random	-	75.38 %	73.46 %	88.0 %	74.41 %	76.78 %
			68.31 %	63.47 %	85.28 %	65.8 %	
			85.2 %	93.42 %	91.89 %	89.13 %	
6	Random	Sí	68.56 %	66.86 %	84.67 %	67.7 %	69.51 %
			59.4 %	56.77 %	80.6 %	58.05 %	
			79.41 %	84.9 %	88.99 %	82.06 %	

**Fuente:** Elaboración propia.

**Tabla B.9:** Tabla resumen de rendimiento de modelos de Kernel para el Bloque 3 según los estados de somnolencia (Validación)

N°	Dataset	PCA	Precisión	Recall	Especificidad	F1-Scores	Precisión Global
1	SMOTE ENN	-	86.65 %	85.17 %	95.8 %	85.9 %	85.14 %
			81.52 %	76.19 %	92.52 %	78.77 %	
			86.52 %	91.06 %	88.15 %	88.74 %	
2	SMOTE ENN	Sí	81.57 %	75.5 %	94.56 %	78.42 %	79.15 %
			74.28 %	69.84 %	89.57 %	71.99 %	
			80.84 %	87.22 %	82.63 %	83.91 %	
3	SMOTE Tomek	-	72.27 %	70.82 %	86.28 %	71.54 %	71.78 %
			64.69 %	62.28 %	83.3 %	63.46 %	
			77.67 %	82.08 %	88.11 %	79.81 %	
4	SMOTE Tomek	Sí	67.01 %	66.66 %	83.43 %	66.83 %	67.28 %
			60.28 %	59.17 %	80.84 %	59.72 %	
			74.15 %	75.88 %	86.67 %	75.0 %	
5	Random	-	73.66 %	69.39 %	87.59 %	71.46 %	71.89 %
			64.82 %	63.32 %	82.82 %	64.06 %	
			76.74 %	82.96 %	87.43 %	79.73 %	
6	Random	Sí	69.24 %	64.90 %	85.58 %	67.0 %	67.20 %
			59.83 %	60.18 %	79.8 %	60.0 %	
			72.41 %	76.53 %	85.42 %	74.41 %	

**Fuente:** Elaboración propia.

**Tabla B.10:** Tabla resumen de rendimiento de modelos de SVM para el Bloque 2 según los estados de somnolencia (Validación)

N°	Dataset	PCA	Distinción	Precisión	Recall	Especificidad	F1-Score	Precisión Global
1	SMOTE ENN	-	Media	87.45 %	80.11 %	96.85 %	83.62 %	86.04 %
				83.17 %	80.18 %	89.82 %	81.65 %	
				87.86 %	94.88 %	91.28 %	91.24 %	
2	SMOTE ENN	Sí	Media	85.07 %	68.94 %	96.68 %	76.16 %	81.02 %
				74.85 %	78.1 %	83.54 %	76.44 %	
				85.22 %	90.35 %	89.58 %	87.71 %	
3	SMOTE ENN	-	Gruesa	80.59 %	50.82 %	96.65 %	62.33 %	72.12 %
				62.64 %	79.32 %	70.33 %	70.0 %	
				81.37 %	76.65 %	88.33 %	78.94 %	
4	SMOTE ENN	Sí	Gruesa	77.96 %	31.33 %	97.57 %	44.69 %	67.61 %
				57.29 %	83.53 %	60.95 %	67.97 %	
				81.56 %	71.78 %	89.2 %	76.36 %	
5	SMOTE Tomek	-	Media	81.51 %	78.26 %	91.12 %	79.22 %	80.7 %
				73.24 %	69.30 %	87.35 %	71.22 %	
				86.43 %	94.53 %	92.58 %	90.30 %	
6	SMOTE Tomek	Sí	Media	76.97 %	75.55 %	88.69 %	76.26 %	76.3 %
				67.22 %	63.15 %	84.61 %	65.12 %	
				83.69 %	90.29	91.20 %	86.86 %	
7	SMOTE Tomek	-	Gruesa	67.48 %	70.40 %	83.03 %	68.91 %	67.3 %
				55.05 %	56.52 %	76.94 %	55.77 %	
				80.67 %	75.03 %	91.01 %	77.75 %	
8	SMOTE Tomek	Sí	Gruesa	61.63 %	71.34 %	77.78 %	66.13 %	64.5 %
				52.75 %	50.45 %	77.42 %	51.58 %	
				80.93 %	71.70 %	91.55 %	76.04 %	
9	Random	-	Media	79.0 %	79.77 %	89.40 %	79.38 %	79.34 %
				73.17 %	64.0 %	88.26 %	68.27 %	
				84.48 %	94.25 %	91.34 %	89.1 %	
10	Random	Sí	Media	73.60 %	77.73 %	86.06 %	75.61 %	74.72 %
				66.64 %	57.44 %	85.62 %	61.7 %	
				82.25 %	88.99 %	90.40 %	85.49 %	
11	Random	-	Gruesa	63.13 %	73.5 %	78.53 %	67.92 %	65.71 %
				55.28 %	50.03 %	79.76 %	52.53 %	
				79.07 %	73.59 %	90.26 %	76.23 %	
12	Random	Sí	Gruesa	56.97 %	74.89 %	71.72 %	64.72 %	62.54 %
				53.99 %	42.25 %	82.0 %	47.4 %	
				78.04 %	70.47 %	90.08 %	74.06 %	

Fuente: Elaboración propia.

**Tabla B.11:** Tabla resumen de rendimiento de modelos de SVM para el Bloque 3 según los estados de somnolencia (Validación)

Nº	Dataset	PCA	Distinción	Precisión	Recall	Especificidad	F1-Score	Precisión Global
1	SMOTE ENN	-	Media	92.54 %	91.16 %	97.65 %	91.85 %	89.13 %
				84.72 %	80.12 %	93.77 %	82.35 %	
				90.06 %	93.99 %	91.28	91.99	
2	SMOTE ENN	Sí	Media	92.07 %	86.03 %	97.63 %	88.95 %	87.08 %
				82.02 %	77.98 %	92.63 %	79.95 %	
				87.73 %	93.64 %	89.0	90.59 %	
3	SMOTE ENN	-	Gruesa	91.14 %	73.42 %	97.72 %	81.33 %	81.46 %
				77.51 %	70.63 %	91.16 %	73.91 %	
				79.94 %	92.85 %	80.92 %	81.46 %	
4	SMOTE ENN	Sí	Gruesa	88.65 %	66.7 %	97.27 %	76.12 %	79.17 %
				75.96 %	69.75 %	90.48 %	72.73 %	
				77.63 %	92.0 %	77.72 %	84.2 %	
5	SMOTE Tomek	-	Media	79.77 %	75.18 %	90.37 %	77.41 %	76.71 %
				70.52 %	66.23 %	86.39 %	68.31 %	
				79.24 %	88.55 %	88.31 %	83.63 %	
6	SMOTE Tomek	Sí	Media	79.93 %	70.1 %	91.11 %	74.69 %	74.24 %
				66.18 %	66.15 %	83.39 %	66.17 %	
				76.83 %	86.33 %	86.89 %	81.31 %	
7	SMOTE Tomek	-	Gruesa	68.61 %	65.23 %	84.93 %	66.88 %	67.94 %
				62.45 %	59.79 %	82.34 %	61.09 %	
				72.08 %	78.65 %	84.66 %	75.22 %	
8	SMOTE Tomek	Sí	Gruesa	63.73 %	64.75 %	81.4 %	64.24 %	65.2 %
				60.97 %	56.8 %	82.13 %	58.81 %	
				70.32 %	73.93 %	84.28 %	72.08 %	
9	Random	-	Media	79.35 %	74.58 %	90.3 %	76.89 %	76.44 %
				70.31 %	66.62 %	85.94 %	68.42 %	
				79.21 %	88.13 %	88.43 %	83.43 %	
10	Random	Sí	Media	78.61 %	70.22 %	90.44 %	74.18 %	73.62 %
				66.12 %	65.59 %	83.19 %	65.85 %	
				76.3 %	85.04 %	86.79 %	80.43 %	
11	Random	-	Gruesa	67.51 %	65.3 %	84.28 %	66.39 %	67.29 %
				61.91 %	59.3 %	81.76 %	60.57 %	
				71.89 %	77.27 %	84.89 %	74.49 %	
12	Random	Sí	Gruesa	62.65 %	64.59 %	80.75 %	63.61 %	64.53 %
				60.25 %	56.54 %	81.35 %	58.33 %	
				70.31 %	72.46 %	84.7 %	71.37 %	

Fuente: Elaboración propia.

**UNIVERSIDAD DE CONCEPCIÓN – FACULTAD DE INGENIERÍA**  
**RESUMEN DE MEMORIA DE TÍTULO**

<b>Departamento</b>	: Departamento de Ingeniería Civil Eléctrica
<b>Carrera</b>	: Ingeniería Civil Biomédica
<b>Nombre del memorista</b>	: Mariana Antonia Rivera Montalba
<b>Título de la memoria</b>	: Detección de somnolencia en conductores: Análisis de señales fisiológicas durante la simulación de conducción
<b>Fecha de la presentación oral</b>	: 13/01/25
<b>Profesor(es) Guía</b>	: Esteban Pino Quiroga
<b>Profesor(es) Revisor(es)</b>	: Gerónimo Bolado López, Sebastián Godoy Medel
<b>Concepto</b>	:
<b>Calificación</b>	:

### **Resumen**

La somnolencia y el cansancio son factores significativos en los accidentes de tráfico, especialmente en carreteras. En 2022, Chile registró 86,050 accidentes de tráfico con 1,745 muertes, de las cuales 820 se atribuyeron a condiciones físicas como fatiga. Este problema impulsa investigaciones en seguridad vial, enfocadas en tecnologías automáticas que detecten somnolencia en conductores mediante sensores y análisis de datos. Este proyecto busca identificar señales tempranas de somnolencia utilizando datos fisiológicos como EEG, ECG, EMG y EDA, con el objetivo de desarrollar un algoritmo capaz de relacionar estas señales con estados de somnolencia en simulaciones de conducción.

En la etapa inicial, se describieron los principios fisiológicos y de adquisición de señales, además de realizar una revisión del estado del arte para identificar características, modelos y algoritmos relevantes. Se analizaron datos del estudio de Hermes Javier Mora, enfocado en eventos de somnolencia usando señales de EEG y ECG de bloques 2 y 3 de simulaciones de conducción.

Tres modelos de clasificación fueron implementados: redes neuronales, SVM y kernel. Las redes neuronales destacaron con una precisión del 91.23 % en el bloque 3 y 86.76 % en el bloque 2. Las características empleadas incluyeron potencia de bandas de frecuencia (delta, theta, alpha, beta), índices de potencia entre bandas, frecuencia cardíaca y su variabilidad. Los canales frontales y occipitales demostraron una alta relevancia, especialmente en las bandas delta y theta, alineándose con investigaciones previas.

Entre los índices utilizados, el índice 3 mostró una relación más precisa y fuerte con la somnolencia, sobresaliendo frente a los índices 1 y 2. Esto resalta su utilidad en la detección del estado de somnolencia en canales específicos, lo que lo convierte en un elemento clave para un análisis más exacto.