

**DESARROLLO DE UN MÉTODO DE SELECCIÓN DE CARACTERÍSTICAS  
BASADO EN EL ANÁLISIS DE SEÑALES ELECTROENCEFALOGRÁFICAS  
PARA LA DETECCIÓN DE SOMNOLENCIA**

**SANDRA SOFÍA DEL PILAR VÁSQUEZ JIMÉNEZ.**

**PROGRAMA DE BIOINGENIERÍA  
FACULTAD DE INGENIERÍA  
UNIVERSIDAD EL BOSQUE  
BOGOTÁ, COLOMBIA  
2020**

**DESARROLLO DE UN MÉTODO DE SELECCIÓN DE CARACTERÍSTICAS  
BASADO EN EL ANÁLISIS DE SEÑALES ELECTROENCEFALOGRÁFICAS  
PARA LA DETECCIÓN DE SOMNOLENCIA**

**SANDRA SOFÍA DEL PILAR VÁSQUEZ JIMÉNEZ.**

**Trabajo de grado presentado como requisito para optar al título de  
BIOINGENIERA**

**Director: ARMANDO QUIÑONES QUIÑONES**

**PROGRAMA DE BIOINGENIERÍA  
FACULTAD DE INGENIERÍA  
UNIVERSIDAD EL BOSQUE  
BOGOTÁ, COLOMBIA**

**2020**

## DEDICATORIA

*Dedico esta tesis a mi madre quien a pesar de las adversidades siempre ha estado presente en todo mi proceso académico. Su amor, sabiduría, dedicación, entrega y fortaleza afianzaron mi confianza y ánimo de seguir adelante ante cualquier inconveniente en el camino.*

*A mi tío que con su apoyo, paciencia y enseñanza me guio hasta este punto de mi vida. A mis hermanos que junto con mi madre y tío son mi motor de vida, mi razón de ser y mi mayor motivación.*

*A mis jefes por su paciencia y comprensión. A la familia Parra porque gracias a ellos el camino fue menos pesado de lo que esperaba. Y por último a Parrita, quien me animó y guio en los momentos difíciles y que con su ayuda pude superar retos y encontrar habilidades que no pensé que tenía.*

## AGRADECIMIENTOS

*Agradezco a Dios por mi vida y la vida de todos quienes hicieron parte de este gran proceso. A mi madre por nunca faltar en mi camino; a pesar de la distancia sus oraciones y palabras fueron la fuerza que necesitaba para seguir adelante. Gracias a ella soy quien soy hoy en día y me siento absolutamente orgullosa del trabajo que ella, con su inmenso amor, ha realizado con mis hermanos y conmigo. Gracias a mi tío que desde el comienzo de esta aventura estuvo ahí conmigo, como siempre, como un padre, guiándome a un mejor futuro. A mis hermanos que son mi motor de vida, gracias por siempre animarme, por la compañía, la unión y la fuerza que me brindan día a día.*

*Infinitas gracias a la familia Parra por el inmenso apoyo brindado en momentos de adversidad. Creo que las personas llegan a la vida de otras por una razón en especial y ellos llegaron a la mía para abrir mis ojos hacia el mundo y a enseñarme que las barreras con motivación, esfuerzo y disciplina se pueden superar.*

*Gracias a mis amigos por estar pendientes del proceso, al igual que todas aquellas personas que durante la realización de mi proyecto se cruzaron en mi vida para darme ánimos y motivación. A mis docentes por sus asesorías y enseñanzas y muy especialmente, a mi tutor Armando Quiñones, pues sin su asesoría y conocimiento no habría sido posible culminar con el desarrollo del presente proyecto.*

*¡Gracias!*

## CONTENIDO

1.	<b>LISTA DE TABLAS</b> .....	7
2.	<b>LISTA DE FIGURAS</b> .....	8
3.	<b>GLOSARIO</b> .....	9
4.	<b>RESUMEN</b> .....	10
5.	<b>INTRODUCCIÓN</b> .....	12
6.	<b>DEFINICIÓN DEL PROBLEMA</b> .....	15
7.	<b>JUSTIFICACIÓN</b> .....	18
8.	<b>OBJETIVOS</b> .....	21
8.1.	OBJETIVO GENERAL .....	21
8.2.	OBJETIVOS ESPECÍFICOS .....	21
9.	<b>MARCO REFERENCIAL</b> .....	22
9.1.	MARCO TEÓRICO .....	22
9.2.	ESTADO DEL ARTE .....	33
10.	<b>METODOLOGÍA</b> .....	37
10.1.	SELECCIÓN DE LA BASE DE DATOS .....	37
10.2.	PROCESAMIENTO DE LAS SEÑALES EEG .....	40
10.2.1.	Selección y aplicación del filtro implementado .....	41
10.2.2.	Normalización de las señales .....	44
10.2.3.	Segmentación .....	45
10.2.4.	Estimación espectral mediante el Método de Welch .....	46
10.2.5.	Obtención del área bajo la curva mediante el Método de integración trapezoidal .....	47
10.2.6.	Obtención del área bajo la curva de cada una de las bandas de frecuencia de interés: $\beta$ , $\alpha$ , $\theta$ .....	49
10.3.	DEFINICIÓN DE LAS CARACTERÍSTICAS .....	50
10.3.1.	Centroide .....	50
10.3.2.	Entropía .....	51
10.3.3.	Movilidad de Hjort .....	52
10.3.4.	Asimetría Espectral .....	53
10.3.5.	Envergadura espectral .....	54
10.3.6.	Curtosis Espectral .....	56
10.3.7.	Relación potencia media entre las áreas de Theta y Alpha; índice propuesto .....	57

10.3.8. Relación de potencia entre las áreas de Alpha y Theta; índice propuesto .....	57
10.3.9. Relación $\alpha + \theta\beta$ .....	58
10.3.10. Relación entre bandas de vigilia y banda de somnolencia $\alpha + \beta\theta$ ; índice propuesto.....	60
10.3.11. Relación entre bandas de somnolencia y bandas de vigilia $\theta\alpha + \beta$ .....	61
10.3.12. Relación entre las áreas de $\theta\beta$ .....	61
10.3.13. Relación $\alpha + \theta\beta - \theta$ ; índice propuesto .....	62
10.3.14. Cambio del área bajo la curva de Alpha respecto a Theta $\alpha - \theta\theta$ ; índice propuesto.....	63
10.4. ANÁLISIS DE DISTRIBUCIÓN DE LOS DATOS .....	64
10.4.1. Kolmogorov-Smirnov.....	64
10.4.2. Shapiro-Wilk .....	65
10.5. SELECCIÓN DE LAS CARACTERÍSTICAS.....	66
10.5.1. Discriminancia: Prueba de los rangos con Signo de Wilcoxon.....	66
10.5.2. Correlación de Spearman .....	68
10.6. CLASIFICACIÓN.....	69
10.6.1. Análisis discriminante lineal (LDA).....	69
10.6.2. Support Vector Machine (SVM) .....	70
10.6.3. Selección del clasificador .....	71
10.7. VALIDACIÓN DE LA CLASIFICACIÓN .....	71
10.7.1. K-Fold.....	71
<b>11. RESULTADOS Y DISCUSIÓN.....</b>	<b>73</b>
11.1. PROCESAMIENTO DE LAS SEÑALES EEG .....	73
11.1.1. Selección del filtro adecuado y Normalización.....	73
11.2. CARACTERÍSTICAS A EVALUAR.....	75
11.3. SELECCIÓN DE LAS CARACTERÍSTICAS .....	75
11.3.1. Normalidad.....	76
11.3.2. Discriminancia de las características.....	76
11.3.3. Correlación de Spearman .....	77
11.3.4. Características seleccionadas.....	79
11.4. CLASIFICACIÓN Y VALIDACIÓN.....	84
11.5. DISCUSIÓN.....	89
<b>12. CONCLUSIONES .....</b>	<b>92</b>
<b>13. RECOMENDACIONES .....</b>	<b>95</b>
<b>14. REFERENCIAS .....</b>	<b>96</b>
<b>15. ANEXOS .....</b>	<b>1</b>

## 1. LISTA DE TABLAS

Tabla 1. Antecedentes detección de somnolencia a través de la electroencefalografía .....	36
Tabla 2. Trabajos que implementaron MIT-BIH Polysomnographic Database .....	38
Tabla 3. Sujetos seleccionados de la base de datos MIT-BIH Polysomnographic Database	40
Tabla 4. Descripción del nivel de correlación (Ellis et al., 2011).....	68
Tabla 5. Exactitud de los clasificadores evaluados.....	71
Tabla 6. Características extraídas.....	75
Tabla 7. Prueba de Rangos con Signo de Wilcoxon .....	77
Tabla 8. Prueba de correlación de Spearman .....	78
Tabla 9. Características por esta metodología y por trabajos previos.....	81
Tabla 10. Resultados clasificación con LDA y K-Fold de 50 iteraciones.....	85
Tabla 11. Comparación entre metodologías de detección de somnolencia .....	86

## 2. LISTA DE FIGURAS

Figura 1. Diagrama del planteamiento del problema .....	17
Figura 2. Diagrama de la justificación de la realización del proyecto .....	20
Figura 3. Información de transmisión por sinapsis de una neurona.....	24
Figura 4. Tipos de montajes de electroencefalografía .....	28
Figura 5. Ondas Cerebrales Electroencefalográficas .....	30
Figura 6. Denominación y ubicación de electrodos .....	31
Figura 7. Diagrama de metodología.....	37
Figura 8. Respuesta en frecuencia del filtro pasa banda de 4° orden.....	42
Figura 9. Respuesta en frecuencia del filtro pasa banda de 8vo orden. ....	43
Figura 10. Señal filtrada sin corrección y con corrección de fase .....	44
Figura 11. Función sinusoidal dividida en trapezoides para hallar su área.....	48
Figura 12. Asimetría negativa y asimetría positiva.....	53
Figura 13. Proceso realizado hasta el análisis de discriminancia.....	67
Figura 14. Proceso realizado hasta el análisis de correlación .....	69
Figura 15. Sección de evaluación de las características.....	72
Figura 16. Señal normalizada y filtrada .....	73
Figura 17. Señal normalizada y filtrada con corrección de fase. ....	74
Figura 18. Diagrama de cajas del comportamiento del Centroide .....	79
Figura 19. Boxplot de la razón entre las áreas de $\alpha - \theta\theta$ .....	80
Figura 20. Discriminancia entre Centroide y $\alpha - \theta\theta$ en el sujeto 8 .....	82
Figura 21. Discriminancia entre Centroide y $\alpha - \theta\theta$ en los sujetos 7 .....	83
Figura 22. Resultados de clasificación en ventanas de diferentes tamaños .....	87
Figura 23. ROC para ventanas de diferentes tamaños .....	88
Figura 24. Comparación entre órdenes del filtro Butterworth respecto a la señal original. ...	1
Figura 25. Resultado diagrama de cajas del Centroide en todos los sujetos. ....	2
Figura 26. Resultado diagrama de cajas del Cambio del área bajo la curva de Alpha respecto a Theta $\alpha - \theta\theta$ .....	3

### 3. GLOSARIO

**Brain Computer Interface (BCI):** sistema de comunicación entre hardware y software que basa su funcionamiento en señales cerebrales. El objetivo de estos sistemas es interpretar las intenciones del usuario con el monitoreo de su actividad cerebral (Alonso L., 2012).

**Electroencefalografía (EEG):** es el registro de la actividad eléctrica cerebral. Está formada por un conjunto de señales superpuestas que se clasifican en “delta ( $\delta$ ), theta ( $\theta$ ), alfa( $\alpha$ ), beta ( $\beta$ ), y gamma ( $\gamma$ )” (Alonso L., 2012).

**Onda Alpha ( $\alpha$ ):** Presentan actividad eléctrica entre los 8 y 12 Hz. Esta onda se relaciona con estados de relajación. Poseen mayor amplitud y son más lentas que las ondas Beta (Carlson N., 2006).

**Ondas Cerebrales:** el cerebro genera impulsos que viajan a través de neuronas, esos impulsos generan ritmos diferentes los cuales son conocidos como ondas cerebrales (Carlson N., 2006).

**Onda Theta ( $\theta$ ):** estas ondas se generan tras un estado de calma profunda, tienen mayor actividad en las etapas de sueño ligero y sueño lento. Su frecuencia oscila entre 4 Hz a 8 HZ (Carlson N., 2006).

**Somnolencia:** es conocida como la tendencia de la persona a quedarse dormido o la transición entre la vigilia y el sueño; en el ciclo del sueño corresponde a la primera etapa (Rosales E., 2010).

**Vigilia:** es la etapa que antecede a la somnolencia y en donde los ritmos Beta y Alpha predominan; según el nivel de concentración cada uno de los ritmos tendrá mayor actividad que el otro (Shliapochnik J., S.F.)..

#### 4. RESUMEN

El sueño es un estado que aísla a las personas de la realidad. Cuando no se descansa lo suficiente en la noche, las actividades del día comienzan a verse afectadas por etapas de somnolencia las cuales enlentecen los resultados de las tareas ejecutadas y, según el tipo de actividad que se esté realizando, pueden poner en riesgo la vida. La detección de somnolencia se ha realizado mediante análisis de imágenes y de señales electroencefalográficas. Los primeros suelen verse afectados por variables externas a los estudios realizados y los segundos suelen ser incómodos para los usuarios debido a la cantidad de electrodos y el sistema utilizado para la detección. Es por eso por lo que se planteó el desarrollo de un método de selección de características para la detección oportuna de somnolencia basado en el análisis de un solo canal de electroencefalografía. Este método se basó en el procesamiento de señales electroencefalográficas (EEG) obtenidas de la base de datos MIT-BIH Polysomnographic Database. Se realizó la selección de 14 características obtenidas del canal bipolar C3-O1 para 11 sujetos, todos ellos hombres. Se analizó el tipo de distribución de los datos obtenidos y se aplicó la prueba de discriminancia de Rangos con Signo de Wilcoxon. Posterior a esto se realizó el análisis de correlación de Spearman, utilizada para variables no paramétricas. De las 14 características iniciales se seleccionaron el centroide y el Cambio del área bajo la curva de Alpha respecto a Theta  $((\alpha - \theta) / \theta)$  como aquellos índices que mejor efecto discriminante tenían sobre las dos clases de interés, W y S1. Posterior a la selección se clasificó con un LDA y se obtuvo un 74% de exactitud, 79% de sensibilidad, 69% de especificidad y 72% de precisión.

**Palabras claves:** procesamiento de señales EEG, vigilia, somnolencia, discriminancia de características.

## ABSTRACT

Sleep is a state that isolates people from reality. When you are not getting enough rest at night, the activities of the day will start a line determined by stages of drowsiness, whatever the results of the tasks performed and depending on the type of activity you are doing, they can be life threatening. The detection of drowsiness has been performed through the analysis of images and electroencephalographic signals. The former are usually verses affected by variables in the studies carried out, and the latter are usually uncomfortable for users due to the number of electrodes and the system used for detection. That is why the development of a characteristic selection method for the timely detection of drowsiness based on the analysis of a single channel of electroencephalography was considered. This method was based on the processing of electroencephalographic signals (EEG) obtained from the MIT-BIH Polysomnographic Database. A selection of 14 characteristics obtained from the bipolar channel C3-O1 was made for 11 subjects, all of them men. The type of distribution of the modified data was analyzed and the Wilcoxon Sign Rank discrimination test was applied. After this, Spearman's correlation analysis was performed, they were used for non-parametric variables. Of the 14 initial characteristics, the centroid and the Change of the area under the curve of Alpha with respect to Theta ( $(\alpha - \theta) / \theta$ ) can be selected as those indices that best discriminate effect on the two classes of interest, W and S1. After selection, it was classified with an LDA and 74% precision, 79% sensitivity, 69% specificity and 72% precision were obtained.

**Keywords:** EEG signal processing, wakefulness, drowsiness, characteristic discrimination.

## 5. INTRODUCCIÓN

El sueño se define como un fenómeno fisiológico en el cual se suspende relativamente la actividad física. Es un estado que se alterna cíclicamente con la etapa de vigilia o alerta y se percibe como un proceso de descanso y recuperación (Correa et al., 2018; Talero-Gutiérrez, Durán-Torres, & Pérez-Olmos, 2013). En las neurociencias se conoce como una conducta y en la psicología general como un estado de conciencia (Aguilar et al., 2017). Es un proceso que ocupa la tercera parte de la vida de los seres humanos, inclusive, existen estudios en los que se determina que los animales unicelulares presentan periodos de inmovilidad asociados al reposo al igual que los animales humanos y no humanos (Benavides-endara & Ramos-galarza, 2019). Todos los seres vivos necesitan esos períodos de descanso y de vigilia puesto que tienen un papel fundamental en la homeostasis del organismo. Diferentes autores han manifestado la importancia del sueño no solo para procesos inmunológicos, sino también para evitar alteraciones en las actividades y conductas cotidianas (Rico-Rosillo & Vega-Robledo, 2018).

El sueño se considera un fenómeno periódico que presenta diferentes etapas a medida que pasa el tiempo. Cada una de estas está compuesta por diferentes comportamientos neuronales y corporales que permiten asociarlas a conductas cotidianas (Aguilar et al., 2017; Benavides-endara & Ramos-galarza, 2019). En los estudios neuronales se identifican cinco etapas del sueño precedidas por la vigilia: etapa I (sueño de transición o somnolencia), etapa II (sueño ligero), etapa III y IV (sueño profundo) y etapa de sueño MOR.

La primera etapa, también conocida como somnolencia, se define como la sensación de pesadez y torpeza de los sentidos motivada por el sueño (Garcés, Salgado, Cruz, & Cañon, 2015). Es considerada la etapa donde se presenta enlentecimiento de la actividad muscular, movimiento lento de los ojos, pérdida de conciencia y reducción de la capacidad de responder a estímulos externos (Carlson, 2010). Además, es un estado que en algunas actividades cotidianas como conducir, puede llegar a poner en riesgo la vida de las personas ya que

antecede a eventos como los microsueños, los cuales son conocidos como un estado de somnolencia que dura de dos a tres segundos y causan que el conductor cierre los ojos y pierda la consciencia (CEA, 2015). Es por esto por lo que detectar a tiempo la somnolencia se convierte en una gran necesidad y en el objetivo del presente proyecto.

Algunas estadísticas indican que la cifra de pérdidas humanas, derivada de accidentes de tránsito en carreteras por somnolencia llega a un porcentaje del 35 % sobre el total de accidentes en las vías, dejando en países como Colombia aproximadamente 5693 víctimas por año (Muñoz & Mendez, 2015). Debido a esto, marcas automovilísticas como Nissan y Mazda, han implementado diferentes tecnologías que permiten la detección de somnolencia en sus automóviles. Nissan, por ejemplo, analiza los patrones de dirección y si detecta somnolencia avisa al piloto con un sonido y un icono de una taza de café se muestra en la pantalla (NISSAN, 2019). Por otro lado, Mazda, observa el grado de atención del piloto analizando la apertura de los ojos, el número de parpadeos y ángulos de boca y rostro para identificar cambios faciales que permitan identificar la somnolencia (NISSAN, 2019).

Adicional a las implementaciones previamente mencionadas existe una gran cantidad de trabajos que basándose en el análisis de imágenes buscan identificar la somnolencia. Sin embargo, estos métodos están sujetos a perturbaciones como excesos de luz, sombras, movimientos faciales similares más no relacionados al agotamiento, etc., (Chipugsi, 2017; Muñoz & Mendez, 2015). Es por esto por lo que se siguen realizando estudios para identificar somnolencia con diferentes métodos. Uno de ellos es el estudio de señales electroencefalográficas (EEG) el cual, mediante el análisis de las bandas de frecuencia relacionadas a las etapas del sueño, busca identificar características que alerten a los sujetos de la presencia de somnolencia.

Varios métodos a partir del análisis de señales EEG se han reportado en literatura. Garcés et al., realizaron la detección de somnolencia extrayendo 19 características en tiempo y frecuencia y usaron análisis discriminante lineal para seleccionar las mejores características;

obtuvieron una tasa de aciertos del 85.5% para 20148 épocas de 5 segundos cada una (Garcés et al., 2015). Wei et al., realizaron una evaluación de fatiga del conductor analizando las señales de dos canales EEG (Fp1 y O1) de los que obtuvieron características de 6 índices de relación de frecuencias de los ritmos cerebrales Beta, Alpha y Theta; tuvieron una exactitud del 92.3%. (W. Li, He, Fan, & Fei, 2012). Belakhdar et al., extrajeron cinco características de segmentos de 30 segundos mediante el análisis de Fourier (FFT) obteniendo un 84.29% de exactitud en el sistema embebido, como aporte a la literatura identificaron el pico máximo de Alpha en cada sujeto y realizaron el análisis de un único canal (Belakhdar, Kaaniche, Djemal, & Ouni, 2018).

Con base en lo anterior, el presente trabajo busca desarrollar un método de identificación de somnolencia basado en el análisis de señales EEG el cual aporte a futuro en la prevención de accidentes automovilísticos causados por este estado y también, mostrarlo como una posible rama de investigación y trabajo para los bioingenieros colombianos en donde se pueda aportar con nuevas metodologías a partir del conocimiento biológico y técnico que brinda nuestra carrera, a las demás ramas investigativas que ya se enfocan en áreas relacionadas a la salud y tecnología en pro de los entes biológicos.

Para finalizar, el documento se compone de una sección en la que se presenta el problema y la justificación de la propuesta planteada, una sección referencial en la cual se muestran algunos términos necesarios para el entendimiento del documento. Posteriormente se presenta la metodología implementada y los resultados obtenidos. Finalmente, se discute y concluyen los resultados y se presenta la sección de anexos en donde se podrán encontrar algunas tablas y gráficas generadas para cada uno de los análisis.

## 6. DEFINICIÓN DEL PROBLEMA

Debido a la ausencia de tecnologías que alerten oportunamente la presencia de la somnolencia sigue siendo un reto tanto para conductores como para entidades nacionales reducir la tasa de accidentalidad causada por este evento. Existen algunas propuestas de identificación de somnolencia realizadas bajo el marco de análisis de imágenes. Estas tecnologías tienen un alto porcentaje de aciertos, sin embargo, la detección puede verse afectada por variables externas al sistema como la luz solar y sombras generadas en el vehículo.

Entidades como el Fondo de Prevención Vial menciona que el 80 por ciento de los accidentes de tránsito se deben a errores y descuidos humanos, y abarcan un gran porcentaje de muertes por año (Cerón, 2015). Por ejemplo, entre enero y noviembre del 2017, 5.803 personas perdieron la vida en accidentes de tránsito. Según el Centro de Referencia Nacional sobre Violencia del Instituto Nacional de Medicina Legal 18 personas por día pierden la vida en accidentes relacionados al sueño en las calles y carreteras del país (Justicia., 2018).

Lo anterior hace referencia a la somnolencia que llegan a sentir los conductores lo cual desemboca en la pérdida de conciencia al volante (CEA, 2015) y a su vez en accidentes de tránsito. La Policía de Carreteras colombiana, junto con el fondo de Prevención Vial y la ARL SURA han dado una serie de pautas a los conductores para no dormirse mientras conducen. Descansar bien la noche anterior, parar cada dos horas, no tomar bebidas embriagantes o consumir medicamentos que induzcan sueño son algunas de las recomendaciones que se deben seguir según las entidades mencionadas (Chaparro, 2017). El cabeceo y cierre involuntario de los ojos son algunos síntomas que indican sin lugar a duda que el estado de concentración y vigilia de la persona ha cambiado.

La somnolencia es un estado que lleva a los conductores a realizar acciones sin ser absolutamente conscientes de éstas, condición que, tras la ausencia de dispositivos que

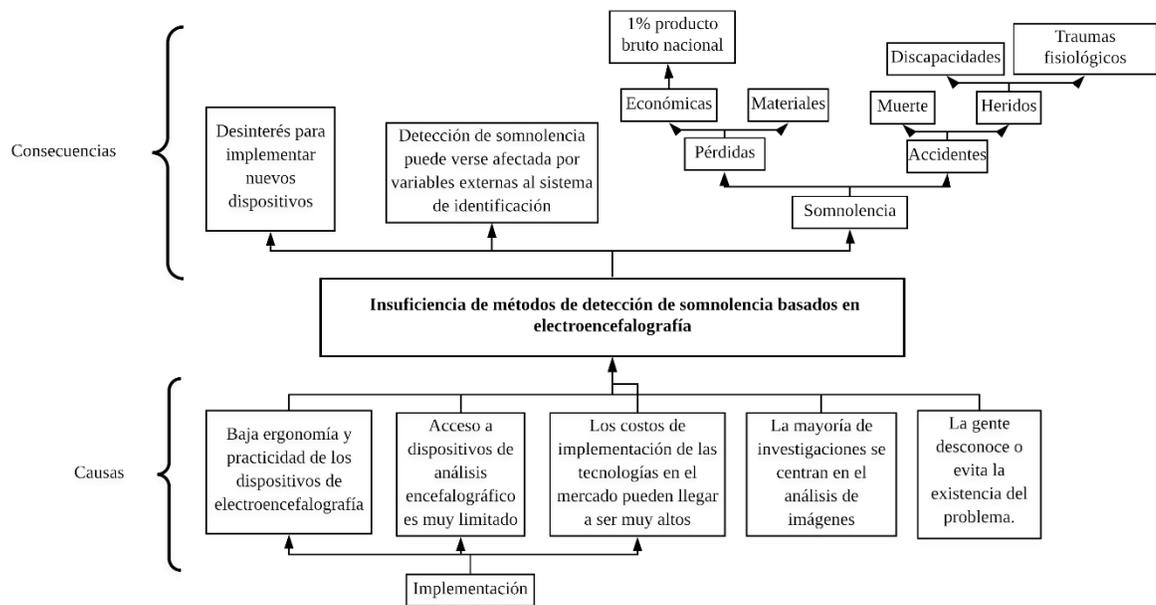
permitan identificarla a tiempo es una de las causas más frecuentes de accidentes automovilísticos (Chaparro, 2017).

Generalmente la somnolencia se presenta cuando la temperatura del automóvil es alta y provoca un efecto relajante en los pilotos, también cuando hay falta de descanso, cuando el viaje se realiza en horarios que por lo general son destinados para descansar (2am-6am) e incluso cuando la velocidad que se lleva es constante. Sin embargo, un estudio realizado recientemente por la Universidad de Melbourne, Australia, indica que otra posible razón por la cual los conductores sienten sueño al conducir es por las vibraciones que el vehículo transmite a su cerebro por medio de los asientos (RevistaTurbo, 2018).

Al respecto, el Instituto de Medicina Legal informó que, en los primeros meses del 2018, se presentaron 607 casos de muerte por choques y 31 por caídas a precipicios. De igual forma, según algunos noticieros nacionales, a octubre del 2019 se presentaron 119 siniestros viales a causa del cansancio producido por conducir excesivamente durante horas seguidas, dejando 184 personas lesionadas y 52 fallecidas (Herrera, 2019). Con base en lo anterior, las autoridades recomiendan tomar las precauciones necesarias para evitar la aparición de la somnolencia en el volante.

Por lo tanto, la ausencia de métodos que permitan detectar a tiempo la somnolencia durante la conducción es una problemática que se debe abarcar ya que se ha convertido en una causa constante de accidentes de tránsito tanto en carreteras como en ciudades conllevando a una pérdida significativa de salud y vidas.

**Figura 1.** Diagrama del planteamiento del problema



**Fuente:** (elaboración propia).

## 7. JUSTIFICACIÓN

Como lo mencionan Rodríguez, C. et al., el índice de accidentalidad causada por somnolencia en algunos países latinoamericanos es de aproximadamente un 35%. En el caso específico de Colombia entre enero y octubre del año 2019 se estimó un total de 119 accidentes de tránsito causados por agotamiento en los conductores (Herrera, 2019). Lo anterior se debe a que los sujetos no son conscientes del estado de somnolencia y llegan a cerrar los ojos en un intervalo de tiempo superior a los 3 segundos. Para ilustrar las dimensiones de las consecuencias de cerrar los ojos al volante, si el conductor lleva una velocidad promedio de 80Km/h y cierra los ojos por tres segundos, alcanzaría a recorrer 50 metros sin observar la vía ni tener control alguno del vehículo terminando en un grave accidente de tránsito (Rosales et al., 2009)

(Rosales Mayor & Rey de Castro Mujica, 2010) mencionan que, según estudios realizados en Perú, eventos consecuentes a la somnolencia son la causa más común en accidentes de tránsito en carreteras atribuyendo esto a los turnos nocturnos que tienen algunos conductores de ómnibus durante toda la semana además de la pérdida y privación del sueño, conllevando así a un déficit de este.

Un estudio realizado en Nueva Zelanda encontró que los factores que aumentan el riesgo de perder la conciencia al conducir son: “conducir sintiéndose con sueño, haber dormido menos de cinco horas en las 24 horas precedentes y conducir entre las 02:00 y las 05:00 de la tarde o entre 02:00 y las 05:00 de la mañana” (Connor et al., 2002). De igual forma, se menciona que, si estos riesgos son evitados se puede llegar a disminuir hasta un 19% la cifra de accidentes de tránsito ocasionados por somnolencia (Connor et al., 2002).

Así mismo, se considera que los accidentes de tránsito representan aproximadamente el 1% del producto nacional bruto en los países con ingresos bajos, 1.55% en países con ingreso medio y el 2% en países con ingresos altos. En cuanto a costos económicos se estimaba hasta

el 2009 un total de US\$ 518.000 millones, de los cuales US\$ 65.000 millones corresponden a los países de bajos ingresos (Rosales et al., 2009, pág. 54).

Además, la cifra de pérdidas humanas derivada de accidentes de tránsito en carreteras que involucra a la somnolencia con un porcentaje del 35 % sobre el total de accidentes en las vías, deja en países como Estados Unidos alrededor de 1500 víctimas por año mientras que en Colombia la cifra asciende aproximadamente a 5693 víctimas (Benavides Muñoz, 2015, pág. 2).

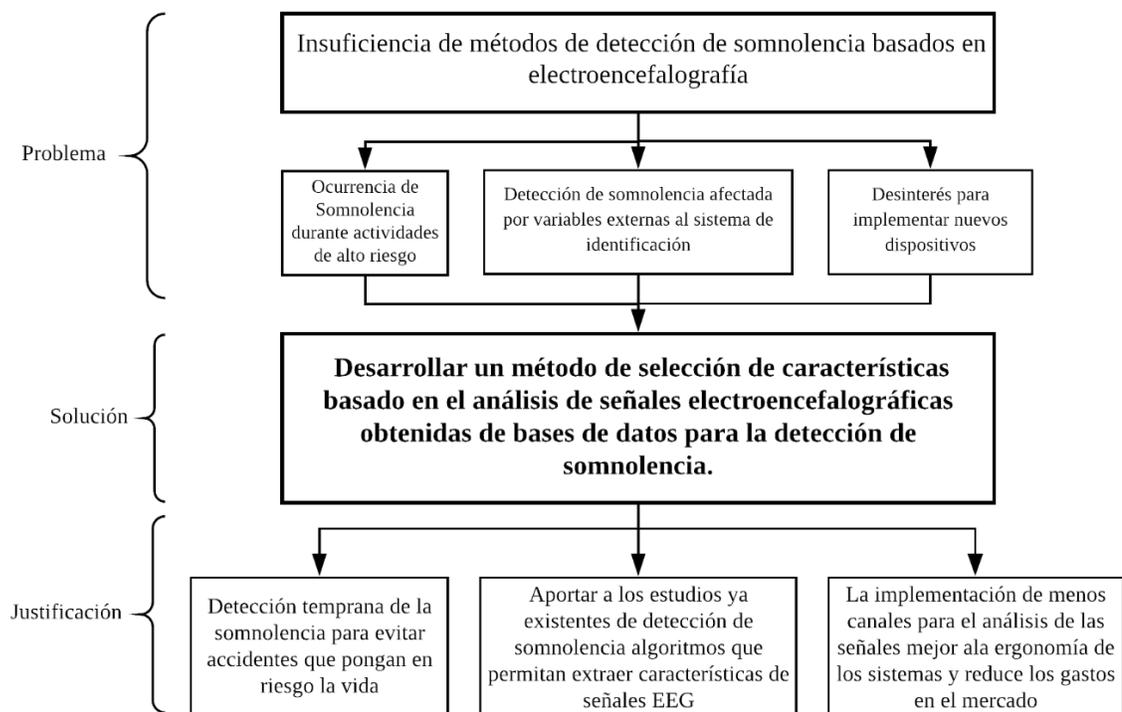
La notoria diferencia entre ambas cifras se podría relacionar con la topografía correspondiente a cada nación. Colombia, se caracteriza por ser un país el cual, debido a su topografía, aumenta el estrés de los conductores al conducir provocando así distracciones o estados que radican en el agotamiento físico. Esto se debe en principio a el bajo inventario de vías, las tortuosas carreteras de montaña como las conocidas Línea, Minas y Fresno, además del desgaste mental ocasionado por las pendientes con curvas cerradas, el sobrepaso de tractomulas a gran velocidad en espacios angostos y curvas, y la falta de cultura de algunos conductores (Pais, 2017).

Sin embargo, a pesar del estrés con el que se llega a conducir y la difícil topografía colombiana, las cuales creería uno son razones suficientes para permanecer alerta, la falta de descanso apropiado es una causa directa sobre la somnolencia la cual puede causar alrededor del 35% de los accidentes viales.

Con base a lo anterior, la presente propuesta tiene como objetivo diseñar un método de identificación de somnolencia a partir de la selección de características de señales electroencefalográficas tomadas de bases de datos. Esto, con el fin de prevenir la ocurrencia de accidentes derivados de este estado a tiempo.

El proyecto se realizó bajo la aplicación de uno de los ejes temáticos de Bioingeniería: tecnología para la salud de entes biológicos, mediante las áreas de conocimiento de análisis de señales biológicas. De igual manera, se busca aportar a los estudios ya existentes de detección de somnolencia con el desarrollo de algoritmos que permitan seleccionar características particulares de las señales EEG para a futuro poder alertar oportunamente a conductores.

**Figura 2.** Diagrama de la justificación de la realización del proyecto



**Fuente:** (elaboración propia).

## **8. OBJETIVOS**

### **8.1. OBJETIVO GENERAL**

Desarrollar un método de selección de características basado en el análisis de señales electroencefalográficas obtenidas de bases de datos para la detección de somnolencia.

### **8.2. OBJETIVOS ESPECÍFICOS**

1. Pre-procesar las señales de electroencefalografía obtenidas de bases de datos en las diferentes fases del sueño para identificar características asociadas a la somnolencia.
2. Seleccionar las características principales de las señales de electroencefalografía que permitan la identificación de la presencia de somnolencia.
3. Evaluar las características seleccionadas para evidenciar su efecto discriminante entre las dos clases de interés, vigilia y somnolencia.

## 9. MARCO REFERENCIAL

### 9.1. MARCO TEÓRICO

#### **Factores biológicos y fisiológicos**

El estudio de la ocurrencia de la somnolencia es necesario para prevenir y evitar que ésta lleve a la persona a entrar en un estado de relajación en medio de actividades que requieren estar con un alto grado de atención, como lo es la conducción de vehículos automotores, especialmente en carretera, donde los trayectos suelen ser más largos con lapsos monótonos y con menores estímulos externos en comparación con las ciudades.

Es común que las personas que descansan menos de lo sugerido, es decir, menos de 8 horas diarias, presente estados de somnolencia en sus actividades cotidianas, aunque esto no desconoce, que personas que no tengan ausencia de sueño también pueden experimentarlos.

Cuando una persona no descansa lo suficiente su actividad cerebral se va reduciendo hasta el momento de no tener mayor actividad alguna de las ondas que tienen baja frecuencia, como la Theta y la Delta.

Según (Behera, Reddy, Behera, & Bhattacharya, 2014) “Los efectos inmediatos de la privación del sueño son: Irritabilidad, discapacidad cognitiva, lapsos o pérdida de memoria, Juicio moral deteriorado, bostezos severos, alucinaciones, síntomas similares al TDAH, Sistema inmunológico deteriorado, riesgo de diabetes tipo 2, riesgo de enfermedad cardíaca, aumento del tiempo de reacción, etc.” (Behera et al., 2014).

La somnolencia puede llegar a ser un estado peligroso cuando ocurre en situaciones que demandan un estado de alerta constante, porque llevan a la persona a descuidar las tareas a

su cargo de modo involuntario, entrando en un estado de pérdida de habilidades y funciones características del dormir.

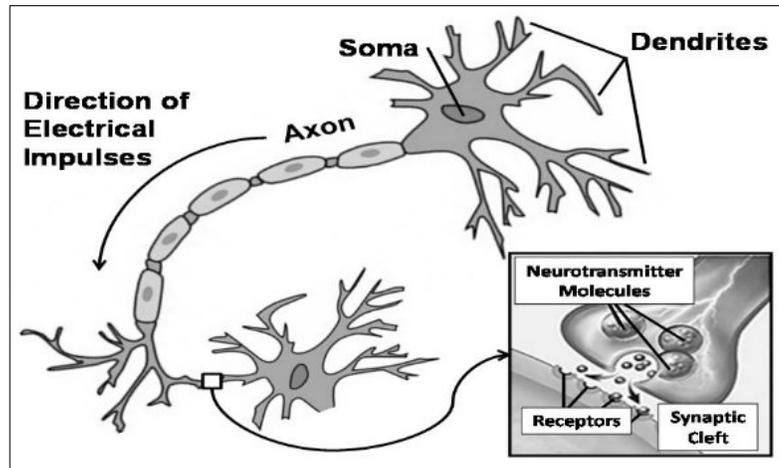
Con base a lo anterior se presenta a continuación la terminología básica que comprende el estudio de las ondas cerebrales para estados de vigilia y de sueño:

## **Neurona**

La neurona es el elemento central del sistema nervioso. Es una célula excitable eléctricamente que recibe, procesa y envía información” (Müller-Putz, Riedl, & Wriessnegger, 2015). Las neuronas están compuestas por el soma, también conocido como cuerpo celular, dendritas y un axón. El soma es la parte encargada de procesar la información recibida por las dendritas mientras que el axón se encarga de enviar información.

La comunicación entre neuronas se da por medio de las dendritas. La información es transmitida por el axón y al final de este hay terminales que reciben señales eléctricas y liberan sustancias químicas a las sinapsis denominadas neurotransmisores; la figura 3 ilustra el proceso de transmisión entre neuronas. Las moléculas de los neurotransmisores son la base para la transmisión de información entre neuronas. Aquella que envía la información genera los neurotransmisores que serán recibidos por receptores para moléculas de neurotransmisores específicos de la otra célula. Las neuronas en conjunto forman redes neuronales con conexiones de aproximadamente diez mil neuronas (Müller-Putz et al., 2015).

**Figura 3.** Información de transmisión por sinapsis de una neurona.



**Fuente:** (Müller-Putz et al., 2015).

La activación de cada neurona registra una actividad eléctrica muy pequeña, por lo tanto, solo es posible realizar la medición del potencial eléctrico de una gran cantidad de neuronas. (Müller-Putz et al., 2015) mencionan la hipótesis de algunos investigadores referente a que “las oscilaciones que se registran en el cuero cabelludo son el resultado de la suma de los potenciales postsinápticos excitadores e inhibitorios en las neuronas piramidales corticales” (Müller-Putz et al., 2015). La suma y propagación de los potenciales hacia la superficie del cuero cabelludo se debe a la orientación de los troncos dendríticos de las neuronas de forma paralela entre sí y perpendicular a la superficie (Müller-Putz et al., 2015).

Existen dos tipos de campos neuronales, abiertos y cerrados. Los campos abiertos son aquellos en los que se generan oscilaciones de electroencefalografía (EEG) que pueden llegar a registrarse en el cuero cabelludo debido al dipolo eléctrico formado por las neuronas. Entre más grande es el número de células recibiendo información de potenciales sinápticos, más grande es la desviación potencial en EEG. En cambio, en estructuras con organización de campo cerrado, como la amígdala, los campos eléctricos de las neuronas suelen cancelarse entre sí debido a la orientación en diferentes direcciones lo cual ocasiona que no se generen grandes dipolos detectables en el cuero cabelludo (Müller-Putz et al., 2015).

## **Fisiología del sueño**

Según (Carlson, 2010) el sueño es una conducta del ser humano y no un estado. Lo que caracteriza a este evento es, según palabras del autor, “la necesidad imperiosa de dormir” (Carlson, 2010). Se tiende a considerar el sueño como un estado de conciencia puesto que lo que se recuerda de lo que sucede mientras se duerme es muy poco. El sueño se divide en dos grandes fases, NO REM y REM (Rapid Eye Movements). La primera de ellas tiene una duración de 90 minutos aproximadamente y se compone por cuatro fases o etapas que son definidas por la actividad EEG.

Al completarse el período del sueño NO REM, las personas entran a la fase de sueño REM el cual se compone por movimientos oculares rápidos, atonía muscular, reactivación a estímulos externos y desincronización del EEG. Es en esta fase en la que se suele tener la mayoría de sueños narrativos (Carlson, 2010).

## **Etapas del sueño presentes en la actividad EEG**

Las etapas del sueño se pueden identificar en la actividad cerebral mediante las bandas de frecuencia que manejan diferentes valores y amplitudes en cada una de las fases. A continuación, se describen las seis fases en las que se suele dividir el proceso de dormir y las bandas de frecuencia que se pueden presenciar en cada una de ellas.

- ***Vigilia***

Durante la vigilia predominan los ritmos Beta y Alpha. Durante la actividad Alpha se forman ondas regulares de frecuencias entre 8Hz a 12Hz. Esto sucede en las regiones occipitales del cerebro. Cuando una persona se encuentra en estado de relajación corporal o se encuentra realizando una actividad de poca concentración mental se hacen más prominentes las ondas Alpha. Cuando se está en estado de alerta o concentración máxima son las ondas Beta las que predominan en el EEG (Carlson, 2010).

- ***Fase I***

En esta fase aparece la actividad Theta con mayor intensidad lo cual indica que “la descarga de las neuronas del neocórtex se va haciendo más sincronizada” (Carlson, 2010). Cuando inicia la somnolencia la onda Alfa es atenuada por la Onda Theta que presenta mayor actividad en el EEG. Se conoce como la fase en la que se presenta la transición entre el sueño y la vigilia. En esta fase los párpados comienzan a cerrarse y abrirse lentamente, los ojos a moverse de arriba hacia abajo y se hace presente el sueño ligero y la respuesta a estímulos auditivos y táctiles comienza a disminuir (Carlson, 2010).

- ***Fase II***

Tras pasar 10 minutos del inicio de la Fase I del sueño se entra a la Fase II la cual es conocida como la fase irregular del sueño. En esta fase se puede ver actividad de la Onda Theta, Spindles o Husos del sueño que son conjuntos de ondas entre 12HZ y 14Hz que ocurren de 2 a 4 veces por minuto durante las fases 1 y 4 del sueño y, Complejos K los cuales se cree son los precursores de las ondas Delta y se presentan únicamente en la Fase II del sueño. Además estudios han demostrado que estos complejos representan un mecanismo de inhibición auditiva lo cual hace que la persona no despierte con tanta facilidad ante ruidos externos (Carlson, 2010).

- ***Fase III***

En esta fase hay entre un 20% y 50% de actividad delta más conocida como sueño profundo. En esta fase no se sueña y es aquella en la que el bloqueo sensorial aumenta, el tono muscular se reduce más que en la Fase II y no hay movimiento ocular (Carlson, 2010).

- **Fase IV**

Al igual que la Fase III es conocida como “sueño de ondas lentas” (SOL). Esto se debe a que la frecuencia presente en esta fase hace referencia a las ondas Delta. Es la fase en la que hay recuperación física. El déficit en las fases III y IV responde a la somnolencia diurna (Carlson, 2010).

- **Fase REM (Sueño paradójico)**

Hace referencia al término en inglés *Rapid Eye Movement*. En esta fase se encuentra presencia de actividad Beta la cual se observa en la etapa 1 del sueño o durante el estado de vigilia. Es conocida también como *Sueño Paradójico* y es en esta fase en la que se dan ensueños, movimientos oculares rápidos y atonía muscular (Carlson, 2010).

## **Somnolencia**

La somnolencia está definida como la sensación de pesadez y torpeza de los sentidos motivada por el sueño (Garcés et al., 2015). Se conoce también como la tendencia de la persona a quedarse dormido o la transición entre la vigilia y el sueño. Según algunos investigadores y clínicos en el área, la somnolencia se puede dividir en somnolencia patológica o somnolencia normal. La segunda hace referencia a la interrupción del ritmo circadiano en cambio la primera suele resultar de un descanso alterado que lleva al déficit del sueño (Rosales Mayor & Rey de Castro Mujica, 2010).

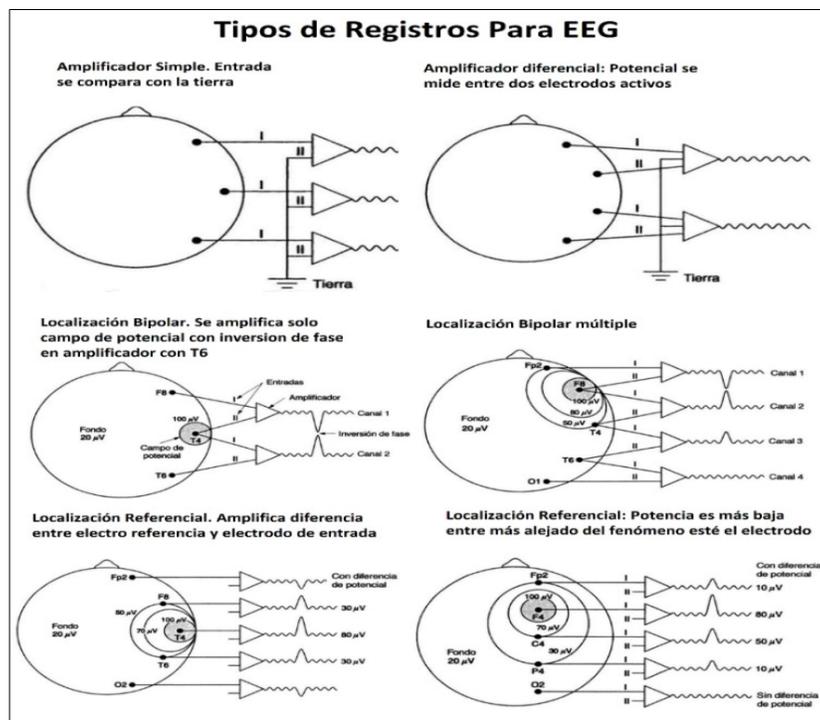
## **Factores técnicos**

### **Electroencefalografía (EEG)**

La electroencefalografía se refiere a las grabaciones de la actividad eléctrica de las neuronas del encéfalo. Dicho registro posee formas muy complejas que varían con la localización de

los electrodos y entre individuos. Esto se debe al gran número de interconexiones que presentan las neuronas y por la estructura no uniforme del encéfalo (Graumann, Allison, & Pfurtscheller, 2010). Normalmente, la amplitud de las señales EEG van desde 10  $\mu\text{V}$  hasta 100  $\mu\text{V}$  cuando se miden en el cuero cabelludo y de 10 a 20 mV cuando se miden en electrodos subdurales (Müller-Putz et al., 2015). Para realizar la toma de señales EEG existen diferentes tipos de registros, la figura 4 muestra cuáles se pueden encontrar.

**Figura 4.** Tipos de montajes de electroencefalografía



**Fuente:**(Rowan & Tolunsky, 2004).

La señal electroencefalográfica está compuesta por un conjunto de ondas cerebrales. Estas ondas se forman gracias a la electricidad que utilizan las neuronas para comunicarse entre sí. Al combinarse millones de neuronas que envían información a la vez, se produce una gran cantidad de actividad eléctrica en el cerebro la cual es censada a través de equipos como los electroencefalógrafos (Pereira & Toro, 2016). El conjunto de ondas electroencefalográficas

está compuesto por ondas gamma ( $\gamma$ ), beta ( $\beta$ ), alfa( $\alpha$ ), Mu o alfa rolándico ( $\mu$ ), theta ( $\theta$ ), delta ( $\delta$ ). A continuación, se presenta la descripción de cada una de ellas.

### **Ondas Gammas ( $\gamma$ )**

Son las ondas con mayor frecuencia en el cerebro, superan los 30 Hz. Su presencia es más fuerte cuando se está en estado de vigilia y se conocen como las ondas que ayudan a tener información en el cerebro. Se relacionan con la buena memoria (Carlson, 2010).

### **Ondas Beta ( $\beta$ )**

Se amplifica cuando hay mayor actividad cerebral. Tiene frecuencias entre 13 y 30Hz que son registradas en el encéfalo y por lo general se relaciona con un estado de activación cortical (Carlson, 2010). Las ondas Beta están presentes en el cerebro en el estado conocido como Vigilia, cuando se realizan tareas de análisis intelectual, en la percepción a través de los cinco sentidos e incluso durante actividades físicas o corporales (Pereira & Toro, 2016).

### **Ondas Alfa ( $\alpha$ )**

Presentan actividad eléctrica entre los 8 y 13 Hz. Esta onda se relaciona con estados de relajación. Poseen mayor amplitud y son más lentas que las ondas Beta (Carlson, 2010). Cuando se presenta emisión de estas ondas la mente racional y los sentidos disminuyen su actividad. Las ondas Alpha pueden influir sobre funciones como el ritmo cardiaco, la circulación, temperatura corporal, resistencia de la piel, el sistema digestivo, entre otras (Pereira & Toro, 2016).

### **Ondas Theta ( $\theta$ )**

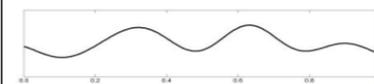
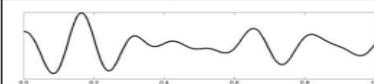
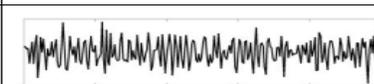
Estas ondas se generan tras un estado de calma profunda. Tienen una actividad electroencefalográfica de 4 a 8 HZ. Cuando una persona se encuentra realizando una actividad y el cerebro se encuentra en estas frecuencias, se dice que la actividad se realiza automáticamente sin que haya concentración o atención mental (Pereira & Toro, 2016).

## Ondas Delta ( $\delta$ )

Su frecuencia se encuentra entre 1 y 4 Hz y hace presencia en las etapas más profundas del sueño, las fases III y IV (Carlson, 2010). Su aparición se considera normal, fuera de las etapas ya mencionadas, en registros EEG de neonatos e infantes. Cuando aparece en adultos fuera de las fases del sueño, se cree que se puede deber a una lesión cerebral (Pereira & Toro, 2016).

La siguiente imagen muestra de forma resumida los tipos de ondas EEG que se conocen por el momento junto con sus respectivas frecuencias, algunos estados mentales a los que se asocian y la forma visual de cada una.

**Figura 5.** Ondas Cerebrales Electroencefalográficas

Frequency band	Bandwidth	Associated mental states	Example illustration
Delta	1-4Hz	Deep sleep, coma	
Theta	4-8Hz	Specific sleep states, meditation, drowsiness	
Alpha	8-13Hz	Relaxation, readiness	
Beta	13-25Hz	Active concentration, anxiety, focused attention	
Gamma	25-200Hz	Arousal, peak performance	

**Fuente:** (McFarland, Anderson, Müller, Schlögl, & Krusienski, 2006).

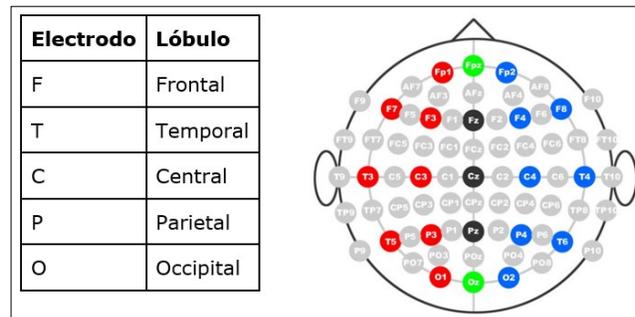
## Sistema 10-20: ubicación de los electrodos

En electroencefalografía los electrodos se localizan en la cabeza siguiendo el sistema internacional 10-20. Este sistema divide el cráneo en una serie de “planos transversales y

meridianos” a partir de dos puntos de referencia, *nasion* ubicado al nivel de los ojos en el punto más alto de la nariz y el *inion* localizado en la base del cráneo (Graimann et al., 2010; Müller-Putz et al., 2015).

Ese sistema se basa en la relación entre la ubicación de un electrodo y el área subyacente de la corteza cerebral. Cada lóbulo es identificado por una letra y cada número identifica la ubicación del hemisferio; números pares en el hemisferio derecho y números impares en el hemisferio izquierdo. El lóbulo central se utiliza sólo para ubicar los electrodos (Graimann et al., 2010; Müller-Putz et al., 2015).

**Figura 6.** Denominación y ubicación de electrodos



**Fuente:** (Graimann et al., 2010)

### Artefactos en señales EEG

Existen artefactos técnicos y biológicos que afectan la toma de señales EEG. Los artefactos técnicos son todos aquellos que se relacionan a la parte electrónica del proceso de toma de señales y a agentes externos como “campos magnéticos, ruidos del preamplificador de entrada, aliasing, cuantificación del convertor A/D, etc.” (Néstor, Culqui, Robin, & Rueda, 2009). Los artefactos biológicos son aquellos inherentes al organismo. Algunos de los artefactos encontrados en las señales EEG se presentan a continuación:

- ***Chasquido del electrodo:*** se da por el contacto deficiente del electrodo. Los movimientos ligeros de la cabeza aumentan la impedancia de este (Néstor et al., 2009).
  
- ***Potenciales de acción muscular:*** el origen de los artefactos musculares suele darse en las regiones frontal y temporal. La duración del potencial es de veinte milisegundos, puede tener amplitudes entre 0-10mV pico a pico y frecuencias desde 50Hz hasta 150Hz; depende del músculo involucrado y del sujeto (Blanco, Mauricio, Bernal, & Torres, 2017; Néstor et al., 2009).
  
- ***Artefacto por la masticación:*** “aparecen potenciales de acción muscular generalizados con una ritmicidad coincidente con los movimientos repetitivos de la masticación” (Néstor et al., 2009).
  
- ***Artefacto por el movimiento de la lengua:*** estos artefactos aparecen lentos y aleatorias semejándose con las ondas lentas (Néstor et al., 2009).
  
- ***Artefacto por la respiración:*** tiene duración de varios segundos y son muy lentos. En este artefacto se puede ver el corte de la corriente en los electrodos debido a la reducción de la impedancia entre ellos (Néstor et al., 2009).
  
- ***Artefacto por el movimiento:*** el movimiento que genera este tipo de artefactos puede modificar el contacto de los electrodos y alterar las posiciones de las derivaciones. Los artefactos por movimiento son potenciales aleatorios y variables “coincidentes con el movimiento del cuerpo o la cabeza y asociados con el artefacto por el músculo” (Néstor et al., 2009).

## 9.2. ESTADO DEL ARTE

Existe un gran número de trabajos realizados con el propósito de aportar analíticamente a los estudios enfocados en el reconocimiento oportuno de la somnolencia. Estos estudios se concentran en identificar las características principales del sueño como el inicio, despertar, la calidad y las consecuencias de la falta de este para poder brindar a conductores diferentes propuestas de seguridad a la hora de conducir. A continuación, se describen algunas tecnologías desarrolladas e implementadas por investigadores y estudiantes de diferentes áreas de conocimiento para identificar somnolencia.

Dey et al., realizaron la detección de somnolencia a partir del análisis en el dominio del tiempo a diferencia de Krishnan y Yaacob, en el 2019, quienes lo realizaron en el dominio de la frecuencia. Para el estudio, los autores tomaron los registros depositados en la base de datos MIT- BIH Polysomnographic Database, la cual cuenta con grabaciones de hombres entre los 32 y los 56 años. A diferencia de la metodología implementada por Krishnan y su compañero, Dey et al., utilizaron tres canales bipolares para extraer características y detectar la somnolencia; C3-O1, C4-A1 y O2-A1 (Dey et al., 2017). Para eliminar los ruidos presentes en las señales utilizaron un filtro Butterworth bidireccional pasa-banda de segundo orden tomando frecuencias desde 0.5 Hz a 60 Hz. Posterior a esto segmentaron las señales en ventanas de 5 segundos y, como características, extrajeron Máximo (Max), Mínimo (Min) y Desviación Estándar (STD), y utilizaron k-vecinos (KNN), análisis discriminante lineal (LDA), árbol de decisión y máquina de soporte vectorial (SVM) como clasificadores. El resultado de su metodología les arrojó una precisión de 83.3% para Max, 85.7% para Min y 79.2% para STD (Dey et al., 2017). El proyecto de Dey et al., se tituló **Automatic Detection of Drowsiness in EEG records based on Time Analysis**. A continuación, se presenta la gráfica con la que los autores sustentan el comportamiento de las características extraídas.

Ese mismo año, 2017, Belakhdar y sus cuatro compañeros trabajaban, al igual que Dey et al., en una metodología que permitiera identificar la somnolencia y, al igual que ellos, utilizaron

la base de datos MIT- BIH Polysomnographic Database para tomar las señales allí almacenadas y filtraron las señales con un filtro pasa-banda de segundo orden con frecuencias de corte de 0.5 Hz y 30 Hz. Belakhdar et al., realizaron el análisis de detección a un solo canal bipolar, C3-O1, tomando ventanas de 30 segundos representadas por una sola frecuencia, es decir, la sub-banda de Alpha en lugar de tomar frecuencias de 8 Hz a 13 Hz, tomó la frecuencia Alpha individual. Los autores argumentan esta decisión en que el uso de una sola frecuencia ayuda a reducir la problemática que genera la variabilidad interpersonal en los análisis (Belakhdar et al., 2018). Las características extraídas por Belakhdar et al., fueron: potencia media en [3 4] Hz, [3 4] Hz/Alpha, Theta/Alpha, relación de potencia media en IAF y análisis con FFT. Como resultado tras la implementación de su metodología obtuvieron una precisión de 89% en MATLAB y 84.2% en un prototipo de sistema integrado que utilizaron. Su proyecto se tituló **Single-channel-based automatic drowsiness detection architecture with a reduced number of EEG features** (Belakhdar et al., 2018).

Otro de los proyectos enfocados a la detección de somnolencia por medio del análisis de señales EEG, pero un poco más antiguo, se denominó **“Support vector machine based detection of drowsiness using minimum eeg features”** y tenía como objetivo hacer clasificadores SVM (máquina de soporte vectorial) para distinguir estados de vigilia y somnolencia incluyendo el análisis de sub-bandas de 1 Hz para tener una detección de la somnolencia más precisa (Rohani. et al., 2013); tal como lo mencionan Belakhdar et al., seis años después. Para esto tomaron señales de sueño CAP del banco de datos de Physiobank de las cuales 16 eran grabaciones de pacientes sin trastornos neuronales y 32 de pacientes con diversos trastornos como insomnio y narcolepsia.

Para iniciar tomaron características con la mejor precisión de clasificación de ambas etapas y definieron el estado de somnolencia como etapa 1 (uniendo la fase 1 y 2 del sueño) y de vigilia como etapa 0. Se realizó la FFT a las señales, se calculó la densidad espectral de potencia para cada época de los 16 conjuntos de datos (569 épocas para la etapa 0, 217 para la fase 1 del sueño y 18787 para la fase 2) y se realizó el entrenamiento del clasificador con

características de sub-bandas de 1 Hz y con 30 características compuestas de potencias de 1 a 30 Hz en resolución de 1 Hz.

Tras evaluar el rendimiento del clasificador observaron que al utilizarse las características compuestas de potencias de 1-30 Hz en sub-bandas de 1 Hz, el clasificador SVM puede lograr una exactitud del 97.91% y una precisión del 98.01%. Además, vieron que la correlación existente entre el número de vectores establecidos y el rendimiento del clasificador SVM indica que si hay un número bajo de vectores de soporte habrá precisión de clasificación muy alta, mientras que si hay un alto número de vectores habrá una predicción baja. Esto se debe, según Rohani et al., a que “a medida que se reduce el vector de características, la dimensión del mapeo también se reduce, lo que significa que, aunque SVM debe trabajar más duro y más tiempo (más vectores de soporte), no podrá lograr una precisión muy alta porque el espacio de dimensión simplemente no es lo suficientemente grande como para encontrar el hiperplano óptimo” (Rohani. et al., 2013, pág. 7).

Con base a las metodologías descritas anteriormente y teniendo en cuenta sus resultados, este proyecto, buscaba al igual que los otros, detectar la somnolencia en señales EEG, sin embargo, se planteó implementar, al igual que Belakhdar et al., el canal C3-O1 de la base de datos MIT- BIH Polysomnographic Database pero analizando ventanas no de 30 segundos sino de 4 segundos. Lo que se busca con esto es proponer un nuevo método el cual reduzca el tiempo de identificación, utilice el menor número de canales posibles y discrimine entre vigilia y somnolencia en la mayoría de los once sujetos que se analizaron.

Por el momento, a diferencia de Dey et al., se ha utilizado un único canal para realizar el análisis y, a diferencia de Belakhdar, la ventana a analizar es de solo cuatro segundos. En las secciones a continuación se presenta la metodología planteada y los resultados obtenidos.

En la siguiente tabla se mencionan a menor detalle otras metodologías para detección de somnolencia analizando señales EEG utilizadas por algunos autores. Se presentan

únicamente el título del artículo, el método utilizado y los resultados obtenidos de cada desarrollo.

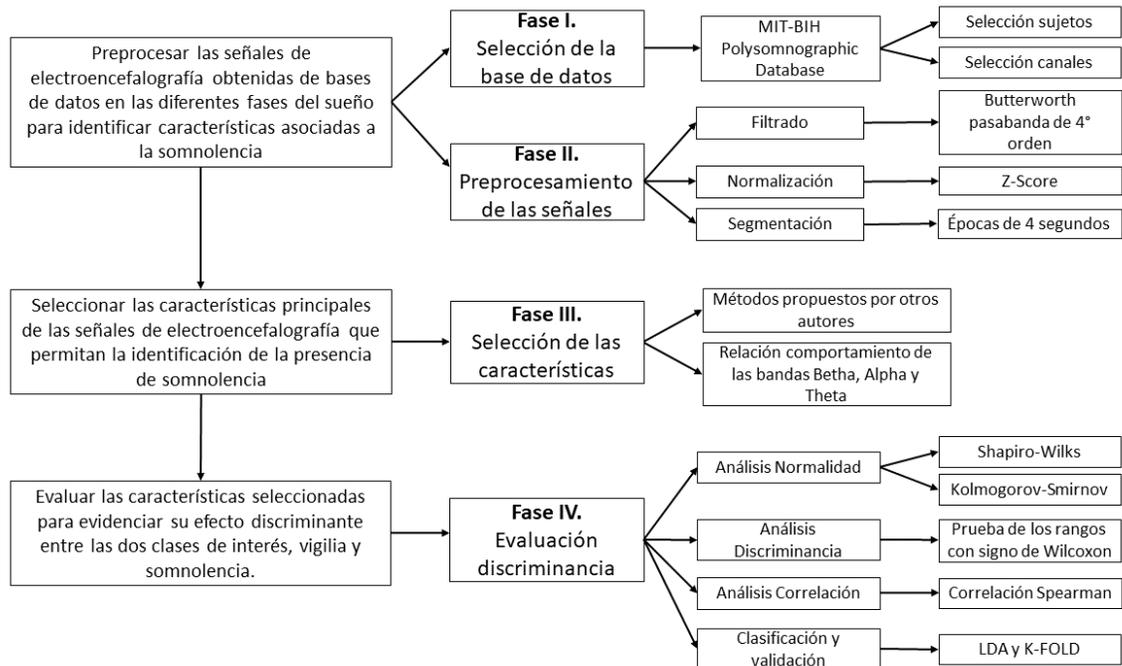
**Tabla 1.** Antecedentes detección de somnolencia a través de la electroencefalografía

ARTÍCULO	MÉTODO	RESULTADOS
Desarrollo de modelo para la detección de somnolencia basado en redes neuronales convolucionadas (Guarda L., 2018)	Se analizaron segmentos de 5 y 13 segundos de la señal. Se realizaron espectrogramas con ventanas de 512 puntos y superposición de 50%.  Se realizó clasificación con 4 métodos diferentes con el fin de detectar cuál era el mejor para identificar somnolencia. Los métodos fueron: redes neuronales convoluciones (CNN), redes neuronales convencionales (NN), Support Vector Machines (SVM) y Random Forest (RF).	Random Forest fue el clasificador que mejores resultados tuvo en cuanto a la detección de somnolencia:  Sensibilidad: 80.56% Exactitud: 76.19% Especificidad: 72.14% Precisión: 74.55%
Evaluation of driver fatigue on two channels of EEG data (Wei L., chang H., Xiu-min F., Zhi-min F., 2011)	Obtuvieron características de 6 índices de relación de frecuencias de los ritmos cerebrales Beta, Alpha y Theta; tuvieron una exactitud del 92.3%.	A pesar de algunas limitaciones que tuvieron como que no se estudiaron los factores fisiológicos, obtuvieron:  Exactitud del 92.3%.
Automatic detection of drowsiness in EEG records based on multimodal analysis (Garcés A., Orosco L., Laciari E., 2013)	Realizaron la detección de somnolencia extrayendo 19 características en tiempo y frecuencia y usaron análisis discriminante lineal para seleccionar las mejores características.	Obtuvieron una tasa de aciertos del 85.5% para 20148 épocas de 5 segundos.

**Fuente:** (elaboración propia).

## 10. METODOLOGÍA

Figura 7. Diagrama de metodología.



Fuente: (elaboración propia)

### 10.1. SELECCIÓN DE LA BASE DE DATOS

#### MIT-BIH Polysomnographic Database

La obtención de las señales electroencefalográficas utilizadas para la detección de presencia de somnolencia se realizó a través de una de las bases de datos de Physionet las cuales tienen la facultad de facilitar la obtención de una gran cantidad de señales biológicas con licencia a utilizarlas gratuitamente y evita el proceso de adquisición de las señales con sujetos de prueba.

La base de datos MIT-BIH Polysomnographic Database (Goldberger et al., 2000; Ichimaru & Moody, 1999) se seleccionó teniendo en cuenta revisión bibliográfica en la que fue utilizada previamente para identificar somnolencia (Boonnak, Kamonsantiroj, & Pipanmaekaporn, 2015; Garcés Correa, Orosco, & Laciari, 2014; Y. Li, Tang, Xu, Liu, & Li, 2016; Rossow, Salles, & Côco, 2011). En la tabla 2 se presenta la relación de algunos artículos que la implementaron.

**Tabla 2.** Trabajos que implementaron MIT-BIH Polysomnographic Database

Artículo	Canales	Año
Detection and Analysis of Drowsiness in Human Beings Using Multimodal Signals	--	2019
Complex-valued unsupervised convolutional neural networks for sleep stage classification	--	2018
Sleep-Wake Transitions and Volatility of EEG Changes	--	2018
Automatic Detection of Drowsiness in EEG records based on Time Analysis	C3-O1 C4-A1 O2-A1	2017
Temporal correlation between two channels EEG of bipolar lead in the head midline is associated with sleep-wake stages	Fpz-Cz Pz-Oz	2016

**Fuente:** (elaboración propia)

Para la realización de la base de datos los autores registraron señales de electroencefalograma, electrooculograma, electromiograma de la barbilla, presión arterial invasiva, saturación de oxígeno, respiración y volumen cardíaco (Ichimaru & Moody, 1999). El tiempo de grabación duró entre dos y siete horas, según cada paciente. Las señales fueron digitalizadas con una frecuencia de muestreo de 250 Hz y 12 bits por muestra. Los sujetos utilizados para la grabación de estas señales fueron monitoreados en el laboratorio de sueño del hospital Beth Israel de Boston. La base de datos está compuesta por 18 grabaciones de 16 sujetos. Cuenta con registros de tres canales diferentes, uno bipolar y dos monocanal: C3-O1, C4-A1 y O2-A1.

En la base de datos se pueden encontrar las fases del sueño referenciadas de la siguiente forma: '0'=vigilia, '1-4'= etapas del sueño, R=REM, MT=movimientos corporales. Cada grabación incluye un encabezado en el que se describe el tipo de señal, la longitud de las grabaciones, edad, género y peso del sujeto. Todos los registros se tomaron de hombres con edades entre los 32 y los 56 años y un rango de pesos entre los 89 y los 152 Kg.

Cada segmento del vector de anotaciones con el que venía la base de datos correspondiente a cualquiera de las etapas del sueño (w, s1, s2, s3, s4 y REM) tiene una duración de 30 segundos. Esa duración fue seleccionada por los expertos que realizaron las marcaciones de las señales registradas para la base de datos MIT-BIH Polysomnographic Database basados en el protocolo de Rechtschaffen y Kales (R&K). Según el Manual de Clasificación del Sueño realizado en 1968 por R&K, la duración de las anotaciones debe tener esa longitud ya que segmentaciones más pequeñas podrían dar una impresión engañosa de la alternancia entre las etapas más frecuentes (Richard B. Berry, MD; Rita Brooks, MEd, RST, RPSGT; Charlene E. Gamaldo & Susan M. Harding, MD; Robin M. Lloyd, 2016). Además, debido al patrón cambiante de los husos del sueño presentes en la etapa II y al aumento y disminución de las ondas Delta presentes en la etapa III y IV, se requiere de una duración mayor a 20 segundos para cada anotación. Además, la Academia Americana de Medicina del Sueño (AASM) manifestó también que épocas secuenciales de 30 segundos “reflejan con bastante precisión el curso del tiempo y la macroestructura del sueño normal” (Allan Hobson, 1969; Richard B. Berry, MD; Rita Brooks, MEd, RST, RPSGT; Charlene E. Gamaldo & Susan M. Harding, MD; Robin M. Lloyd, 2016; Schulz, 2008).

El canal seleccionado para el análisis fue el C3-O1 puesto que, según la literatura, los canales ubicados en la zonas centrales, occipitales y parietales presentan buena descripción de la somnolencia (Braüning, 2018; Da Silveira, Kozakevicius, & Rodrigues, 2016; Gurudath & Bryan Riley, 2014; W. Li et al., 2012). Además, los canales occipitales, según Silveira et al., aportan un poder discriminante y tienen una elevada relación con el estado de somnolencia (Da Silveira et al., 2016).

De los 16 sujetos con los que cuenta la base de datos se seleccionaron aquellos que realizaron el registro con el canal C3-O1. Las grabaciones de esos once sujetos fueron procesadas y analizadas para con ellas realizar la detección de somnolencia. En la tabla 3 se pueden observar los sujetos seleccionados.

**Tabla 3.** Sujetos seleccionados de la base de datos MIT-BIH Polysomnographic Database

#	Grabación	Canal EEG	Cantidad de W	Cantidad de S1
1	'slp03'	'(C3-O1)'	151	105
2	'slp04'	(C3-O1)'	162	60
3	'slp14'	'(C3-O1)'	321	188
4	'slp16'	'(C3-O1)'	316	108
5	'slp45'	'(C3-O1)'	119	54
6	'slp48'	'(C3-O1)'	213	241
7	'slp59'	'(C3-O1)'	140	105
8	'slp60'	'(C3-O1)'	286	344
9	'slp61'	'(C3-O1)'	124	88
10	'slp66'	'(C3-O1)'	175	143
11	'slp67x'	'(C3-O1)'	72	41

**Fuente:** (elaboración propia)

## 10.2. PROCESAMIENTO DE LAS SEÑALES EEG

Tras seleccionar los canales y sujetos a analizar se inició la fase de preprocesamiento de las señales. Esta fase integraba el proceso de filtrado, normalización y segmentación de las grabaciones. Se utilizó un filtro pasa-banda, normalización de z-score y las ventanas se tomaron con duración de cuatro segundos. A continuación, se describe cada uno de esos procesos y se definen algunos términos para mejorar la comprensión de los métodos utilizados.

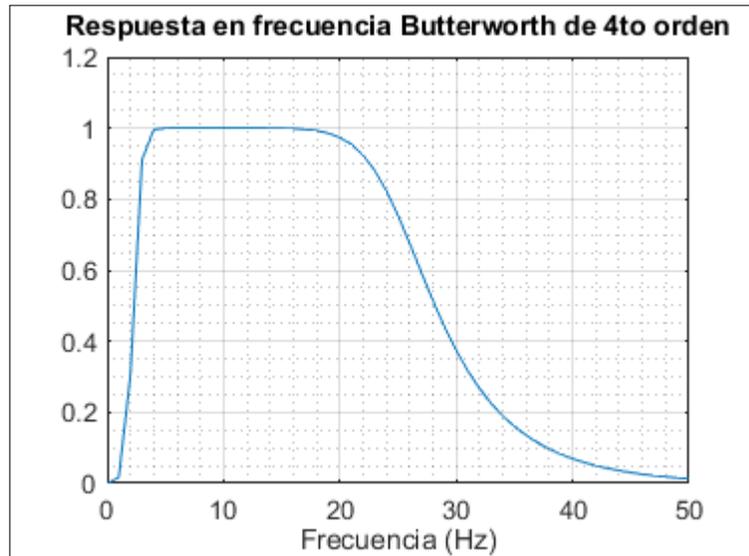
### **10.2.1. Selección y aplicación del filtro implementado**

Se escogió un filtro Butterworth IIR ya que en la banda de paso producen una respuesta de frecuencia lo más plana posible a comparación de los filtros FIR. Tiene la ventaja de que con un orden mayor, como 4 o 5, la respuesta de paso mantiene su forma mientras que con los FIR se requiere un orden mucho más elevado, 18 a 20, para conseguir una respuesta similar (Raphael & Borja, 2018), lo que a su vez hace a los filtros IIR computacionalmente más ligeros.

Para la selección del filtro Butterworth se partió del análisis de literatura en donde se encontró que los trabajos previos de detección de somnolencia con EEG se realizaron aplicando un filtro IIR Butterworth de 2do, 4to o 8to orden. Si bien existen muchas más investigaciones en las que implementan el filtro de segundo orden, en este trabajo no se escogió puesto que, al realizar el análisis de los datos, se perdía gran parte de la información comprendida entre los 4.5 Hz y los 5 Hz debido al tiempo de estabilización del filtro de orden bajo. Tampoco se implementó de orden muy alto puesto que cuando se encontraba la señal original con alguna potencia alta, el filtro en la mayoría de los casos superaba el umbral de datos de la señal, es decir, dejaba pasar más información de la que se requería.

Con base en lo anterior se realizó un filtro pasa banda ButterWorth de cuarto orden tomando frecuencias desde 4.0 Hz hasta 40 Hz para seleccionar el rango de las ondas cerebrales de interés, Beta, Alpha y Theta y tener en cuenta el tiempo de estabilización del filtro para que no se perdieran las frecuencias de Betha deseadas. En la figura 8 se muestra el diseño del filtro y su respuesta en frecuencia y fase. Como se puede ver en la gráfica, se espera que el filtro omita las frecuencias inferiores a 4 Hz y superiores a 40 Hz con el fin de evitar posibles ruidos producidos por frecuencias muy bajas o altas, además, el desfase de su implementación debe ser cero.

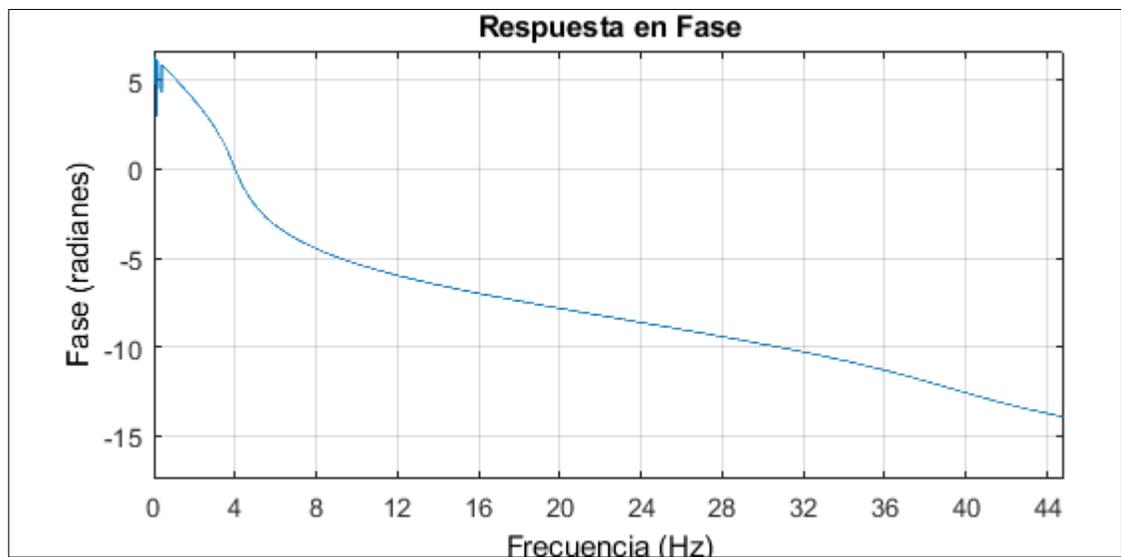
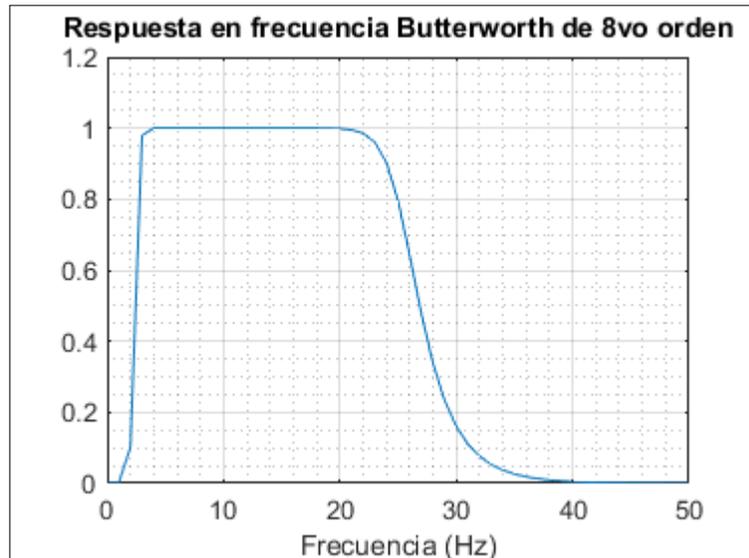
**Figura 8.** Respuesta en frecuencia del filtro pasa banda de 4° orden.



**Fuente:** (elaboración propia)

Se seleccionó un filtro de cuarto orden puesto que para el desarrollo de la presente metodología se busca analizar las frecuencias de Theta, Alpha y Beta por lo que es importante prevenir interferencias derivadas de ruidos de frecuencias muy altas o bajas relacionadas a artefactos oculares como el parpadeo, por lo tanto, es importante que la frecuencia de corte del filtro sea lo más precisa posible. Sin embargo, la función que se implementó para su diseño fue `filtfilt` de Matlab con la cual se obtiene como resultado: distorsión de fase cero, una función de transferencia de filtro igual a la magnitud al cuadrado de la función de transferencia de filtro original y un orden del filtro del doble del especificado, es decir, orden 8 (MathWorks, 2019) La figura 9 muestra la respuesta en frecuencia y fase del filtro modificado tras su implementación.

**Figura 9.** Respuesta en frecuencia del filtro pasa banda de 8vo orden.

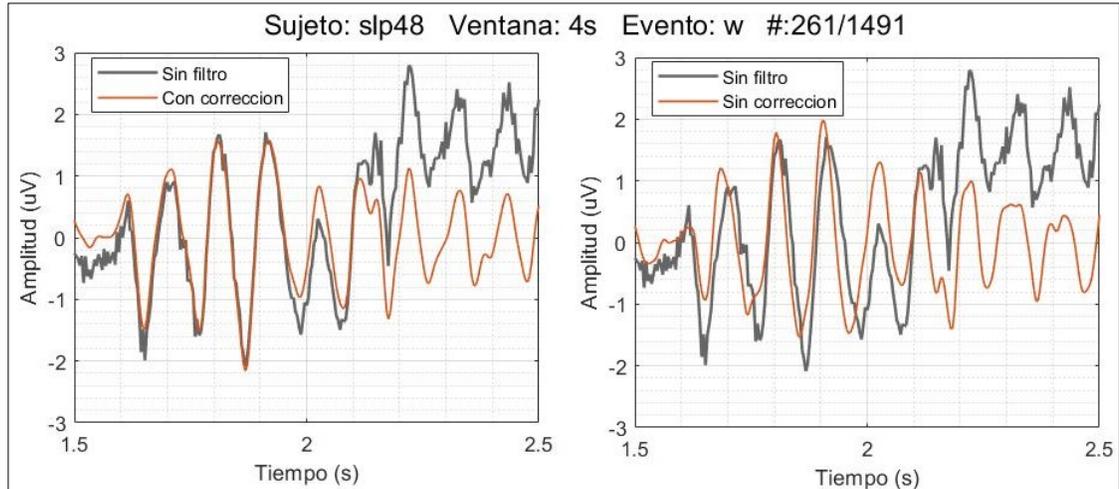


**Fuente:** (elaboración propia)

Como se puede observar en la figura 9, el filtro de orden 8 al igual que el de orden 4 toma las frecuencias mayores a 4 Hz y menores 40 Hz, sin embargo, es menos precisa la atenuación en el de menor orden que en el de mayor. En la respuesta en fase se puede observar que para frecuencias menores a 4 Hz el filtro de orden 8 tiene un desfase igual a 5 radianes y en las frecuencias de interés, de 4 Hz a 40 Hz, la fase del filtro está por debajo de cero aun cuando su orden se duplicó

tras la implementación de la función. La figura 10 muestra la señal en el dominio del tiempo sin filtro, sin corrección de fase y con corrección de fase.

**Figura 10.** Señal filtrada sin corrección y con corrección de fase



**Fuente:** (elaboración propia)

Como se puede ver en la gráfica de la derecha (figura 10), se implementó el filtro Butterworth más no la corrección de fase. La señal original se identifica de color gris y la señal filtrada, pero sin corrección de fase se identifica de color naranja. En la gráfica de la izquierda se puede observar de nuevo la señal original (gris) y superpuesta a esta la señal filtrada y con corrección de fase (naranja) tras implementar la función.

### 10.2.2. Normalización de las señales

Después de cargar las anotaciones y las señales de los sujetos se realizó la normalización de la señal completa con el método z-score, también conocida como normalización de puntaje Z, con el fin de transformar los datos con diferentes distribuciones a una misma escala. Esta normalización permite mantener la relación entre los datos iniciales y los datos deseados. La ecuación 1 indica la fórmula utilizada para la normalización.

$$v_i' = \frac{v_i - \bar{E}}{std(E)}$$

(Ecuación 1)

Donde,

$v_i$  es el valor de la fila E de la i-ésima columna

$$std(E) = \sqrt{\frac{1}{(n-1)} \sum_{i=1}^n (v_i - \bar{E})^2}$$

$$\bar{E} = \frac{1}{n} \sum_{i=1}^n v_i \text{ o valor de la media}$$

### 10.2.3. Segmentación

La base de datos de MIT contiene un archivo de anotaciones en donde se puede observar el orden en el que aparece cada una de las marcaciones correspondientes a las etapas del sueño a lo largo de las grabaciones registradas. Este archivo se utilizó para seleccionar los segmentos correspondientes al estado de vigilia demarcado como “W” y al estado de somnolencia (etapa I) demarcado como “1”. Cada segmento identificado por el algoritmo se almacenó en la variable correspondiente a cada uno de los estados de interés: W y S1.

Autores como (Da Silveira et al., 2016; Dey et al., 2017; Garcés Correa et al., 2014) han utilizado la base de datos MIT-BIH Polysomnographic para detectar la somnolencia y han trabajado sobre ventanas de 5 y 10 segundos. Garcés et al., trabajaron con 10074 segmentos de W y S tras la segmentación (Garcés Correa et al., 2014). Por otra parte, Li et al., trabajaron con épocas de duración de 30 segundos cada una obteniendo 73201 segmentos para W y 34084 para S1 (Y. Li et al., 2016).

Para la obtención de las ventanas de esta metodología se realizó un análisis intrasujeto, al igual que en el análisis estadístico, en el que se escogió cada segmento correspondiente a

eventos W y S1 y se tomaron ventanas de cuatro segundos para cada una de las clases, al igual que en la metodología realizada por (Wang et al., 2019). Cada sujeto quedo con un número diferente de épocas para W y para S1, es decir, eran dos conjuntos de datos desbalanceados.

Para realizar el análisis estadístico se realizó submuestreo aleatorio el cual consiste en la eliminación aleatoria de valores de la clase mayoritaria hasta lograr el balance de los datos entre las clases. Se realizó esto para evitar que en la clasificación, el algoritmo no tienda a predecir aquellos valores pertenecientes a la clase minoritaria como valores de la clase mayoritaria (García-García, Reding-Bernal, & López-Alvarenga, 2013; Osorio, 2019; Santacruz, 2016).

El tamaño de la ventana se escogió de cuatro segundos porque como se plantea en la sección 7, se espera aportar metodológicamente a los estudios realizados en detección de somnolencia y, hasta el momento, de los artículos revisados para este desarrollo, el único estudio que ha trabajado con ventanas de esta duración lo hizo con más de cinco canales electroencefalográficos y con análisis de electrooculografía. Por lo tanto, se espera obtener resultados similares a los del estudio de Wang et al., con la diferencia de que en esta metodología solo se analizan las señales electroencefalográficas provenientes del canal C3-O1.

#### **10.2.4. Estimación espectral mediante el Método de Welch**

El método de Welch es un método no paramétrico que se utiliza para estimar la densidad espectral de una señal. El método consiste en tomar la señal a analizar y dividirla en varios segmentos, conocidos como periodogramas, que se pueden solapar y promedia los espectros de estos (Brahmani, Kumar, Ramesh, Rao, & Chandra, 2017; Roggerone,

Rébillat, & Corteel, 2017; Verma & Dekar, 2018). A continuación, se presenta la ecuación utilizada en el método de Welch (Verma & Dekar, 2018).

$$P_x^{(k)} = \frac{1}{N} \sum_{n=0}^{L-1} |w_{(n)} X^{(k)}(n) e^{-jwn}|$$

*(Ecuación 2)*

Donde,

$w_{(n)}$  representa la ventana.

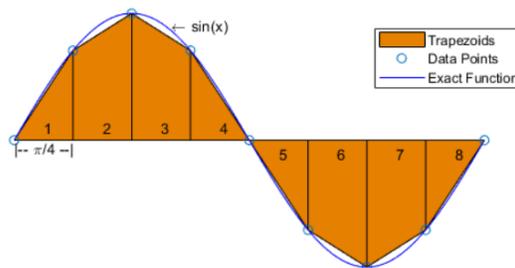
$x^k(n)$  representa los valores presentes en los segmentos K.

Para el desarrollo de la presente metodología se utilizó en el método de Welch ventana Hamming y superposición del 50%. Este método se implementó para sacar cada una de las características descritas a continuación.

#### **10.2.5. Obtención del área bajo la curva mediante el Método de integración trapezoidal**

El método de integración trapezoidal aproxima la integral de una función dada, por el área del trapecio. Consiste en dividir el área ubicada bajo la curva en trapecoides y hallar el área de cada uno de ellos. La imagen a continuación representa una función sinusoidal dividida uniformemente en 8 trapecios a los cuales se les hallará el área (Manzanarez & Acevedo, 2015; MathWorks, 2019).

**Figura 11.** Función sinusoidal dividida en trapezoides para hallar su área



(MathWorks, 2019).

La fórmula implementada para hallar el área de una función por medio de trapezoides se presenta a continuación. Esta es utilizada cuando los puntos se encuentran espaciados uniformemente

$$\int_a^b f(x) dx \approx \frac{b-a}{2N} \sum_{n=1}^N (f(x_n) + f(x_{n+1}))$$

$$= \frac{b-a}{2N} [f(x_1) + 2f(x_2) + \dots + 2f(x_N) + f(x_{N+1})]$$

**(Ecuación 3)**

Donde,

N representa el número de puntos

$\frac{b-a}{N}$  equivale al espacio entre cada punto azul de la figura 9.

Cuando en la función los puntos no se distribuyen uniformemente se implementa la siguiente ecuación:

$$\int_a^b f(x) dx \approx \frac{1}{2} \sum_{n=1}^N (x_{n+1} - x_n) [f(x_n) + f(x_{n+1})]$$

**(Ecuación 4)**

Donde,

N corresponde al número de puntos utilizados.

$(x_{n+1} - x_n)$  representa al espacio entre cada par de puntos consecutivos.

#### **10.2.6. Obtención del área bajo la curva de cada una de las bandas de frecuencia de interés: $\beta$ , $\alpha$ , $\theta$**

Según literatura, cuando se está en estado de vigilia se hacen más prominentes la onda Beta y Alpha en comparación a la onda Theta y cuando se está en estado de somnolencia es Theta quien predomina sobre las otras dos bandas características del estado de vigilia (R. Aguirre, 2015b; Carlson, 2010).

El área de  $\beta$ ,  $\alpha$  y  $\theta$  se extrajo con el fin de analizar cada una de las bandas de interés asociadas a los estados del sueño mediante la implementación de diferentes índices basados en su comportamiento. Para realizar el análisis de las áreas se inició con el método de Welch para obtener la densidad espectral de potencia (PSD) de los segmentos seleccionados para el análisis. Tras la estimación espectral se halló el área bajo la curva de cada una de las bandas de frecuencia a través del método de integración trapezoidal.

La fase de selección de características se llevó a cabo después de realizar una revisión de las características extraídas previamente por otros autores para identificar somnolencia con señales EEG. Durante el proceso de revisión de literatura se encontró que algunos índices expuestos a continuación se han utilizado para evaluar señales biológicas y también comparar estados del sueño mas no, para identificar somnolencia. A continuación, se presenta la definición de las características extraídas.

### 10.3. DEFINICIÓN DE LAS CARACTERÍSTICAS

Para la selección de características se utilizaron algunos métodos los cuales se mencionarán a continuación para facilitar el entendimiento de los procedimientos realizados y expuestos más adelante en el proceso de cada característica extraída.

#### 10.3.1. Centroide

Es una medida estadística que permite obtener información acerca del centro de gravedad del espectro. Esta medida considera al espectro como una distribución de probabilidad “la cual viene determinada por la amplitud del espectro para cada frecuencia, obteniendo así la frecuencia media ponderada en amplitud” (F. Aguirre, 2017). Cuanto más altas son las frecuencias, más alto es el valor del centroide espectral (Sobreira & Rodríguez, 2008).

El centroide se escogió como característica para analizar la etapa de transición e identificar la somnolencia con base en la referencia de Sobreira y Rodríguez en donde se menciona la relación de la frecuencia con el valor del centroide. Se espera que en vigilia el valor del centroide sea más alto que en estado de somnolencia. Lo anterior, teniendo en cuenta que según literatura en la etapa de somnolencia la frecuencia disminuye en comparación con la etapa de vigilia (R. Aguirre, 2015b; Carlson, 2010), por lo tanto, al ser mayores las frecuencias referentes al estado de vigilia, Beta y Alpha, su centroide debería ser más alto que en somnolencia. La ecuación implementada para hallar el centroide se presenta a continuación:

$$\mu_1 = \frac{\sum_{k=b_1}^{b_2} |f_{(k)}| S_{(k)}}{\sum_{k=b_1}^{b_2} S_{(k)}}$$

(Ecuación 5)

Donde,

$f_{(k)}$  es la frecuencia correspondiente en Hz al bin  $k$ ,

$S_{(k)}$  es el valor espectral del bin  $k$ ,

$b_1$  y  $b_2$  son las frecuencias máxima y mínima sobre la cual se va a calcular el centroide.

Para la obtención de este índice se dio inicio con la obtención de las frecuencias y potencias correspondientes a las bandas de Beta, Alpha y Theta mediante los métodos de Welch y de integración trapezoidal. Posterior a esto se utilizó la ecuación 5 sobre cada uno de los segmentos a analizar.

### **10.3.2. Entropía**

La entropía espectral es una herramienta que se ha utilizado particularmente en señales biomédicas. Este cálculo utiliza la densidad espectral de potencia (PSD) para detectar eventos que alteran su distribución espectral. Bermúdez et al., usan la entropía como medida para detectar ritmos Alpha y crisis epilépticas (Bermúdez & Spinelli, 2011) por otro lado, Zhang et al., la usan como característica para la detección de somnolencia con un único canal electroencefalográfico (Zhang et al., 2014).

Teniendo en cuenta que la entropía mide el nivel de caos de una señal y con base a literatura revisada previamente referente al comportamiento de las bandas de frecuencia presentes en el sueño y a su fisiología, se espera que en la etapa de vigilia los valores de entropía sean mayores que en la etapa de somnolencia puesto que al tener frecuencias más altas debería haber más caos presente.

Para la selección de esta característica se utilizó el método de Welch para obtener las potencias y frecuencias que se aplicarían a la fórmula implementada en el algoritmo, ver ecuación 6.

$$\mu = - \sum_{i=1}^N p_{(n)} \log_2 p_{(n)}$$

(ecuación 6)

Donde,

$n$  corresponde a cada una de las frecuencias.

$P(n)$  corresponde a la distribución de probabilidad de cada conjunto de frecuencias.

### 10.3.3. Movilidad de Hjort

Es un parámetro que se ha utilizado para detectar la excitación electroencefalográfica la cual se caracteriza por cambios repentinos en la frecuencia EEG durante el sueño. A estos cambios se les conoce como despertares nocturnos y son una de las principales causales de la somnolencia diurna (Behera et al., 2014).

La Movilidad de Hjort es definida como “la raíz cuadrada de la relación de la varianza de la primera derivada de la señal y la de la señal” (Oh, Lee, & Kim, 2014). Este parámetro representa la frecuencia media o la proporción de desviación estándar del espectro de potencia. Hjort contiene información sobre el espectro de frecuencia de una señal y permite su análisis tanto en el dominio del tiempo como en el de la frecuencia. Los parámetros de Hjort tienen la ventaja de lograr una menor complejidad computacional durante su uso (Oh et al., 2014).

Con base en lo anterior, se espera que este índice sea más alto en vigilia que en somnolencia. Esto, teniendo en cuenta que las frecuencias del primer evento son mayores a las del segundo (Aguilar et al., 2017; Carlson, 2010). El cálculo implementado para hallar el parámetro Hjort se presenta a continuación.

$$Mobilidad = \sqrt{\frac{var(y'(t))}{var(y(t))}}$$

(ecuación 7)

Donde,

$Var$  corresponde a la varianza.

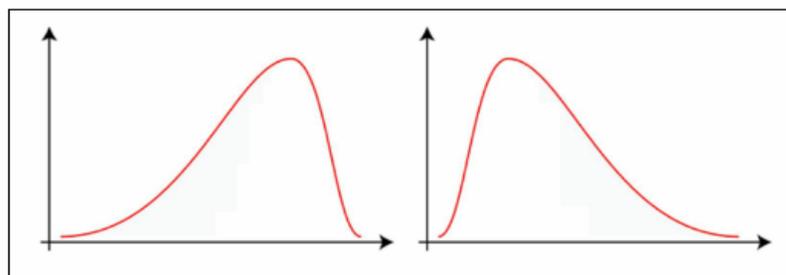
$y'(t)$  corresponde a la primera derivada de la señal la cual se obtiene mediante la diferencia entre las muestras.

$y(t)$  corresponde a la señal en el dominio del tiempo.

#### 10.3.4. Asimetría Espectral

La asimetría espectral “aporta información de la asimetría energética del espectro respecto a su centroide”, mas no refleja la posición central (F. Aguirre, 2017) La asimetría del espectro puede ser positiva cuando la cola tiende a la derecha o negativa cuando la cola se alarga hacia la izquierda (Aguirre F., 2017; D’Arcy T., 2013). En la figura 12 se puede observar una asimetría negativa y una positiva.

**Figura 12.** Asimetría negativa y asimetría positiva



**Fuente:** (Ciaburro, 2017).

Al igual que la entropía y la curtosis este cálculo se ha utilizado previamente para analizar diferentes tipos de señales biológicas. Hasta el momento no se ha evidenciado el uso de

la asimetría como indicador para la detección de somnolencia, sin embargo, se ha implementado para clasificar las etapas del sueño (Hassan, Bashar, & Bhuiyan, 2015).

Para la obtención de este índice se dio inicio con la obtención de las frecuencias y potencias correspondientes a las bandas de Beta, Alpha y Theta mediante los métodos de Welch y de integración trapezoidal. Posterior a esto se utilizó la ecuación 8 sobre cada uno de los segmentos a analizar (Rashik A., 2015)

$$k = \frac{\sum_{b_1}^{b_2} (f_k - \mu_1)^3 S_k}{(\mu_2)^3 \sum_{b_1}^{b_2} S_k}$$

*(Ecuación 8)*

Donde,

$f_k$  es la frecuencia en Hz correspondiente al bin K.

$S_k$  es el valor del espectro del bin K.

$b_1$  y  $b_2$  son las frecuencias máxima y mínima sobre la cual se va a calcular la Curtosis.

$\mu_1$  corresponde al centroide espectral y  $\mu_2$  la envergadura espectral.

En cuanto al comportamiento de esta característica en el análisis discriminante se espera que sus valores sean más altos en vigilia que en somnolencia puesto que, teniendo en base literatura relacionada a las bandas de frecuencia involucradas en el sueño, se asume que, así como en W debería presentarse más caos que en S1, debería haber también mayor asimetría debido a la naturaleza de la señal.

### **10.3.5. Envergadura espectral**

Es una medida la cual permite definir la concentración de energía alrededor del centroide. Estadísticamente la envergadura corresponde con la varianza. A veces se denomina ancho

de banda instantáneo. Al igual que la asimetría, brinda información respecto a la asimetría energética del espectro respecto a su centroide.

Para la obtención de este índice se dio inicio con la obtención de las frecuencias y potencias correspondientes a las bandas de Beta, Alpha y Theta mediante los métodos de Welch y de integración trapezoidal, al igual que con los índices anteriores. La ecuación matemática utilizada para su implementación se presenta a continuación (F. Aguirre, 2017).

$$\mu^2 = \sqrt{\frac{\sum_{k=b_1}^{b_2} (f_{(k)} - \mu_c)^2 S_k}{\sum_{k=b_1}^{b_2} S_k}}$$

**(Ecuación 9)**

Donde,

$f_{(k)}$  es la frecuencia correspondiente en Hz al bin k

$S_{(k)}$  es el valor espectral del bin k

$b_1$  y  $b_2$  son las frecuencias máxima y mínima sobre la cual se va a calcular la envergadura espectral

$\mu_c$  es el centroide espectral

En cuanto al comportamiento de esta característica en el análisis discriminante se espera que sus valores sean más altos en vigilia que en somnolencia ya que al igual que se menciona en las características anteriores se asume que al presentarse frecuencias más altas en W, debe haber más caos, asimetría, aleatoriedad y en este caso, debería concentrarse más energía en este evento que en el correspondiente a S1.

### 10.3.6. Curtosis Espectral

La curtosis espectral hace referencia a lo plano o picudo que es un espectro alrededor del centroide; los valores altos de  $k$  indican el pico más agudo de la distribución de datos (F. Aguirre, 2017; Ciaburro, 2017; Gurudath & Bryan Riley, 2014; Hassan et al., 2015).

Autores como (Garcés Correa et al., 2014) estudiaron la posibilidad de implementar la curtosis espectral como característica para detectar la somnolencia. Tras analizar sus resultados descartaron este cálculo como indicador de detección de la etapa 1 del sueño. Sin embargo, en el presente proyecto, se implementó el cálculo de la curtosis espectral como característica para detectar la somnolencia.

Para su cálculo se implementó el método de Welch para obtener las frecuencias y potencias deseadas para posteriormente implementar el índice de curtosis. A continuación, se puede observar la ecuación utilizada para realizar el cálculo (Ciaburro, 2017)

$$k = \frac{\sum_{b_1}^{b_2} (f_k - \mu_1)^4 S_k}{(\mu_2)^4 \sum_{b_1}^{b_2} S_k}$$

*(Ecuación 10)*

Donde,

$f_k$  es la frecuencia en Hz correspondiente al bin  $K$ .

$S_k$  es el valor del espectro del bin  $K$ .

$b_1$  y  $b_2$  son las frecuencias máxima y mínima sobre la cual se va a calcular la Curtosis Espectral.

$\mu_1$  corresponde al centroide espectral.

$\mu_2$  la envergadura espectral.

Al igual que en las características anteriores se espera que los valores obtenidos del análisis de curtosis sean más altos para W que para S1. Lo anterior con base a que durante

la vigilia el EEG muestra no solo actividad de Alpha sino también de Beta la cual es una banda de ondas irregulares y de actividad asincrónica (Carlson, 2010).

### **10.3.7. Relación potencia media entre las áreas de Theta y Alpha; índice propuesto**

Para hallar la relación de potencia media entre Alpha y Theta se utilizó el método de Welch para obtener la PSD de los segmentos correspondientes a los estados W y S1. Posterior a esto se halló el área de cada una de las bandas de frecuencia y se buscó la relación de potencia media entre ellas dividiendo la potencia media de la banda Theta por la potencia media de la banda Alpha.

Con esta característica se busca observar el comportamiento de las dos bandas mencionadas y se espera que, tal como se menciona en la literatura, en la etapa de somnolencia el índice muestre valores superiores a la etapa de vigilia. Esto, teniendo en cuenta que en la etapa de somnolencia es la frecuencia de la banda Theta la que predomina sobre la frecuencia de la banda Alpha (R. Aguirre, 2015b; Carlson, 2010).

$$\text{Relación Potencia Media entre Theta y Alpha} = \frac{\theta}{\alpha}$$

*(ecuación 11)*

Donde,

$\alpha$  corresponde al área en los rangos de frecuencias entre 8 y 12 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

### **10.3.8. Relación de potencia entre las áreas de Alpha y Theta; índice propuesto**

Esta característica se extrajo a partir del análisis del área de cada una de las bandas de interés, en este caso Alpha y Theta, las cuales se obtuvieron con el método de integración

trapezoidal teniendo en cuenta que para Alpha el rango de frecuencias era de 8 a 13 y para Theta de 4.5 a 8.

La selección de un índice similar basado en la relación de las bandas Alpha y Theta se realizó previamente por W. Li et al. Ellos extrajeron el espectro de potencia media de cada banda de frecuencias utilizando la transformada de Fourier y observaron la relación entre ellas (W. Li et al., 2012). A diferencia de ellos, esta metodología analiza las dos mismas bandas de frecuencia, pero en lugar de observar la relación entre la potencia media se observa la relación entre el área de las bandas y las frecuencias a analizar se obtuvieron implementando el método de Welch más no la transformada de Fourier.

Se espera que el índice basado en la relación de las áreas de Alpha y Theta sea más alto en vigilia que en somnolencia. Esto, partiendo de que la banda representativa del estado de vigilia previo a la somnolencia es Alpha (R. Aguirre, 2015a; Carlson, 2010), por lo tanto, se espera que la presencia de esta sea la que predomine en la clase W.

$$\text{Relación de Potencia} = \frac{\alpha}{\theta}$$

(ecuación 12)

Donde,

$\alpha$  corresponde al área en los rangos de frecuencias entre 8 y 12 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

### 10.3.9. Relación $\frac{\alpha+\theta}{\beta}$

Autores como (Chen, Wang, & Hua, 2018; Da Silveira et al., 2016; Jap, Lal, Fischer, & Bekiaris, 2009; W. Li et al., 2012) han trabajado con la relación entre cuatro de las cinco bandas de frecuencias presentes en la electroencefalografía (Beta, Alpha, Theta y Delta),

y han propuesto índices nuevos basados en el comportamiento de su relación. Esta metodología basó la selección de características en sólo tres de las bandas reconocidas durante el sueño. Dentro de la búsqueda de índices aportados para la detección de somnolencia se encontró un índice igual al que se plantea a continuación. La diferencia entre esa metodología y esta es que la selección de las características del autor (Da Silveira et al., 2016) se realizaron a partir de la transformada de Fourier mientras que en esta se basó el análisis en el método de Welch.

Este índice se basa en la relación de potencia de las bandas Beta, Alpha y Theta. Se plantea de esta forma puesto que, como lo mencionan algunos autores (R. Aguirre, 2015a; Carlson, 2010; Garcés et al., 2015), al entrar en somnolencia la presencia de Alpha disminuye con respecto a Theta. Se espera que los valores obtenidos para esta característica sean más altos en la etapa I del sueño que en la vigilia ya que en teoría, la banda de Alpha disminuye casi hasta desaparecer su actividad y la de Beta, en esa fase de transición, no debería tener actividad significativa.

Para su selección se halló la PSD de cada una de las bandas involucradas y por medio del método de integración trapezoidal se encontró el área de cada una de ellas, posterior a esto se halló la relación entre las bandas.

$$Relación = \frac{\alpha + \theta}{\beta}$$

*(Ecuación 13)*

Donde,

$\beta$  corresponde al área en los rangos de frecuencias entre 13 y 30 Hz.

$\alpha$  corresponde al en los rangos de frecuencias entre 8 y 12 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

### 10.3.10. Relación entre bandas de vigilia y banda de somnolencia $\frac{\alpha+\beta}{\theta}$ ; índice propuesto

Teniendo en cuenta que la banda Beta aumenta su presencia cuando una persona se encuentra en plena actividad mental y cuando en la etapa 2 del sueño se presentan los husos del sueño y complejos K, se tiene la teoría de que su presencia puede identificarse antes de entrar en somnolencia ya que la presencia de las ondas no desaparece por completo en el cerebro y podría llegar a aportar, junto con la onda Alpha, alguna característica que permita discriminar la transición entre vigilia y somnolencia (R. Aguirre, 2015a; Carlson, 2010; Néstor et al., 2009).

Índices similares al que se plantea a continuación se han aplicado para la detección de somnolencia. El área de las bandas utilizadas en otras metodologías se halló utilizando la transformada de Fourier. Algunos índices como los planteados por Silveira et al., incluye el análisis de las frecuencias correspondientes a las bandas Gamma y Delta (Da Silveira et al., 2016).

Este índice al igual que los ya mencionados se halló utilizando el método de Welch para extraer la PSD de cada una de las bandas de frecuencias y posteriormente, implementando el método de integración trapezoidal, hallar el área de cada una de las bandas seguido de la relación entre ellas. Con este índice se espera comprobar que, como se menciona en la literatura, en la Etapa I del sueño (S1) Theta aumenta su actividad mientras que Alpha y Beta la reducen significativamente (Da Silveira et al., 2016).

$$\text{Relación entre bandas de vigilia y banda de somnolencia} = \frac{\alpha + \beta}{\theta}$$

**(Ecuación 14)**

Donde,

$\beta$  corresponde al área en los rangos de frecuencias entre 13 y 30 Hz.

$\alpha$  corresponde al área en los rangos de frecuencias entre 8 y 12 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

### 10.3.11. Relación entre bandas de somnolencia y bandas de vigilia $\frac{\theta}{\alpha+\beta}$

Se espera que los valores obtenidos para esta característica sean más altos en la etapa I del sueño que en la vigilia ya que las bandas Alpha y Beta disminuyen su actividad en S1 mientras que Theta incrementa (R. Aguirre, 2015a; Carlson, 2010).

Para su selección se halló la PSD de cada una de las bandas involucradas y por medio del método de integración trapezoidal se encontró el área de cada una de ellas, posterior a esto se halló la relación entre las bandas.

$$\text{Relación entre banda de somnolencia y bandas de vigilia} = \frac{\theta}{\alpha + \beta}$$

(Ecuación 15)

Donde,

$\beta$  corresponde al área en los rangos de frecuencias entre 13 y 30 Hz.

$\alpha$  corresponde al área en los rangos de frecuencias entre 8 y 12 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

### 10.3.12. Relación entre las áreas de $\frac{\theta}{\beta}$

Al igual que en el índice anterior se espera que los valores obtenidos para esta característica sean más altos en la etapa I del sueño que en vigilia ya que en esta fase no debería evidenciarse actividad Beta tan alta como actividad Theta. La actividad de Beta

debería ser muy pequeña mas no nula puesto que la actividad de las bandas no desaparece por completo en el cambio de estado, sino que su actividad es atenuada por la de las bandas características a cada etapa.

Para su selección se halló la PSD de cada una de las bandas involucradas y por medio del método de integración trapezoidal se encontró el área de cada una de ellas, posterior a esto se halló la relación entre las bandas.

$$\text{Relación entre las áreas de Theta y Beta} = \frac{\theta}{\beta}$$

*(Ecuación 16)*

Donde,

$\beta$  corresponde al área en los rangos de frecuencias entre 13 y 30 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

### **10.3.13. Relación $\frac{\alpha+\theta}{\beta-\theta}$ ; índice propuesto**

Tras realizar el análisis de esta característica los valores obtenidos para la etapa de somnolencia deberían ser menores a los de la etapa de vigilia puesto que tanto Alpha como Beta presentan mayor actividad que Theta.

Para su selección se halló la PSD de cada una de las bandas involucradas y por medio del método de integración trapezoidal se encontró el área de cada una de ellas, posterior a esto se halló la relación entre las bandas.

$$\text{Relación} = \frac{\alpha + \theta}{\beta - \theta}$$

*(Ecuación 17)*

Donde,

$\beta$  corresponde al área en los rangos de frecuencias entre 13 y 30 Hz.

$\alpha$  corresponde al área en los rangos de frecuencias entre 8 y 12 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

#### **10.3.14. Cambio del área bajo la curva de Alpha respecto a Theta $\frac{\alpha-\theta}{\theta}$ ; índice propuesto**

Esta característica se extrajo a partir del análisis del área de cada una de las bandas de interés, en este caso Alpha y Theta, las cuales se obtuvieron con el método de integración trapezoidal teniendo en cuenta que para Alpha el rango de frecuencias es de 8 a 12 y para Theta de 4 a 8.

Este índice se propuso a partir del análisis de otros índices propuestos anteriormente por autores como (Da Silveira et al., 2016; Eoh, Chung, & Kim, 2005; Jap et al., 2009), en los que se relacionan las diferentes bandas de frecuencias involucradas en el sueño asociando entre sí las áreas representantes del estado de somnolencia y de vigilia.

$$\text{Cambio del área bajo la curva de Alpha respecto a Theta} = \frac{\alpha - \theta}{\theta}$$

*(Ecuación 18)*

Donde,

$\alpha$  corresponde al área en los rangos de frecuencias entre 8 y 12 Hz.

$\theta$  corresponde al área en los rangos de frecuencias entre 4 y 8 Hz.

Se espera que este índice sea más alto en vigilia que en somnolencia. Esto, partiendo de que la banda representativa del estado de vigilia previo a la somnolencia es Alpha (R.

Aguirre, 2015a; Carlson, 2010), por lo tanto, se espera que la presencia de esta predomine sobre la presencia de la banda Theta.

#### **10.4. ANÁLISIS DE DISTRIBUCIÓN DE LOS DATOS**

Tras escoger las características a evaluar se procede a realizar el análisis estadístico para saber si discriminan o no entre las dos clases de interés, W y S1. Para realizar la evaluación se debe iniciar con un análisis del tipo de distribución que presentan los datos para así poder escoger la prueba adecuada para evaluar si las características son discriminantes. Ese análisis se realizó con la prueba de Kolmogorov-Smirnov y Shapiro-Wilk las cuales se describen a continuación.

##### **10.4.1. Kolmogorov-Smirnov**

El test de Kolmogorov se aplica para saber qué prueba estadística se escoge para el análisis de discriminancia. Es un test estadístico utilizado para determinar el tipo de distribución de probabilidad de un grupo de datos. Este parte de la hipótesis de que la función de distribución de probabilidad de un grupo de datos es igual que la de cualquier distribución normal. De cumplirse la hipótesis, la diferencia entre la función de la hipótesis y la del grupo de datos a evaluar debe tender a cero (Razali & Wah, 2011). A continuación, se presenta la fórmula que se implementa para analizar la normalidad con la prueba de Kolmogorov.

$$T = \max (|F(x) - F_o(x)|)$$

*(Ecuación 19)*

Donde,

$F(x)$  es la función de probabilidad muestral

$F_0(x)$  la función teórica o la que corresponde a la población normal (especificada en la hipótesis nula).

El supuesto de la prueba de Kolmogorov asume que los parámetros de la distribución de prueba han sido especificados previamente. La prueba estima los parámetros a partir de la muestra, en donde, la media y la desviación estándar son los parámetros de una distribución normal, el rango de la distribución uniforme es definido por los valores máximos y mínimos, “la media muestral es el parámetro de la distribución de Poisson y la media muestral es el parámetro de la distribución exponencial” (IBM, 2014).

#### 10.4.2. Shapiro-Wilk

La prueba de Shapiro-Wilk, al igual que la de Kolmogorov-Smirnov, es un test estadístico que se utiliza para determinar el tipo de distribución de probabilidad de un grupo de datos. Originalmente se planteó para analizar menos de 50 muestras, sin embargo, se ha convertido en la prueba más utilizada debido a su alto poder estadístico (Razali & Wah, 2011). El estadístico de prueba de Shapiro-Wilk se define como:

$$W = \frac{(\sum_{i=1}^n a_i y_i)^2}{(\sum_{i=1}^n y_i - \bar{y})^2}$$

*(Ecuación 20)*

Donde,

$y_i$  es el orden estadístico  $i^{th}$

$\bar{y}$  es la media de la muestra

$$a_i = a_1, \dots, a_n = \frac{m^t V^{-1}}{C}$$

$C = (m^T V^{-1} V^{-1} m)^{1/2}$ , vector normalizado.

$m = (m_1, \dots, m_n)^T$ , corresponde a “los valores esperados de las estadísticas de orden de variables aleatorias independientes e idénticamente distribuidas muestreadas de la distribución normal estándar”.

$V$  corresponde a la matriz de covarianza de las estadísticas de orden anteriores.

Los valores obtenidos de  $W$  tras implementar la ecuación 20 deben encontrarse entre cero y uno. Los valores cercanos a uno indican la normalidad de los datos mientras que aquellos valores cercanos a cero indican el rechazo de la normalidad (Razali & Wah, 2011)s.

Al realizar las pruebas de Kolmogorov-Smirnov y Shapiro-Wilk se observó que los datos tenían una distribución no paramétrica, por lo tanto, se escogió la prueba de Rangos con Signo de Wilcoxon para analizar la discriminancia de las características.

## **10.5. SELECCIÓN DE LAS CARACTERÍSTICAS**

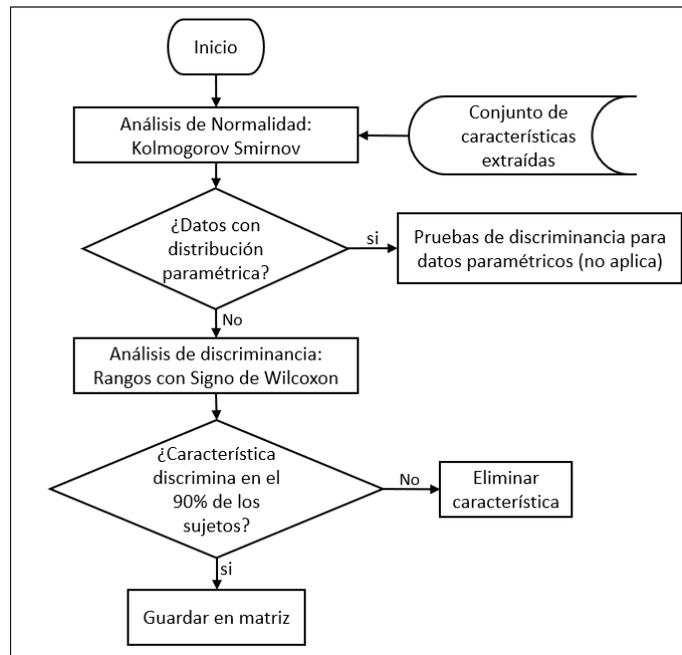
Con base en los resultados de normalidad se concluyó que el procedimiento adecuado para realizar el análisis de discriminancia de las características debía ser alguna prueba no paramétrica. Teniendo en cuenta la relación de los datos y que son dos muestras relacionadas las que se deseaban comparar, se escogió la prueba de Rangos con Signo de Wilcoxon al igual que en la metodología planteada por Silveira et al., (Da Silveira et al., 2016).

### **10.5.1. Discriminancia: Prueba de los rangos con Signo de Wilcoxon**

La prueba de Wilcoxon es un test en el que se pueden comparar poblaciones cuando la distribución de sus datos no cumple la hipótesis de normalidad. Esta prueba se caracteriza por comparar las diferencias existentes entre pares de datos que tienen distribución simétrica entorno a un valor (Rodrigo, 2016). “Si las dos muestras proceden de la misma población, es de esperar que las diferencias entre cada par de observaciones se distribuyan de forma simétrica entorno al cero” (Rodrigo, 2016).

La prueba de Wilcoxon es una prueba no paramétrica ya que a diferencia de la prueba T no se basa en ningún parámetro y se utiliza para muestras pareadas. Calcula las diferencias entre dos variables para la totalidad de los casos presentes en cada una y clasifica esas diferencias como positivas, negativas o empatadas. Cuando las dos variables analizadas presentan distribuciones similares, el número de las diferencias positivas y negativas no difiere significativamente. Cuando el “p-valor”, también conocido como nivel de significancia, es menor a 0.05 se rechaza la hipótesis nula, es decir, las variables analizadas no presentan distribuciones similares, por lo tanto, se puede discriminar entre ellas. Si el “p-valor” es mayor a 0.05, se entiende que los datos no son discriminantes entre las clases W y S1.

**Figura 13.** Proceso realizado hasta el análisis de discriminancia



**Fuente:** (elaboración propia)

### 10.5.2. Correlación de Spearman

La correlación de Spearman mide el grado de relación que tienen dos variables siempre y cuando sean cuantitativa-cuantitativa, cuantitativa-ordinal, ordinal-ordinal (Acuña, 2011; Ellis et al., 2011). El coeficiente de correlación de Spearman se aplica, a diferencia de la correlación de Pearson, cuando los datos no están normalmente distribuidos. La relación de una muestra se denota de la siguiente forma:  $-1 \leq r_s \leq 1$ . La ecuación implementada para menos de 20 observaciones se presenta a continuación.

$$\rho = 1 - \frac{6 \sum D^2}{N(N^2 - 1)} \quad (\text{Ecuación 20})$$

Donde,

$D$  es la diferencia entre los correspondientes estadísticos de orden de  $x - y$

$N$  corresponde al número de parejas de datos

$\rho$  (rho) representa al valor de significancia obtenido al analizar la correlación

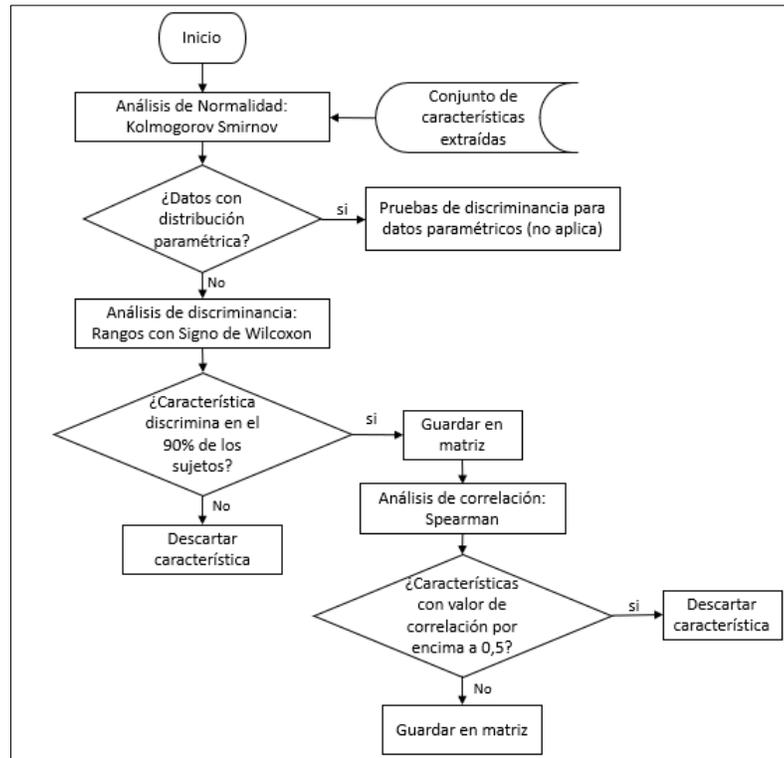
La fuerza de correlación, según Ellis et al., se puede describir como se muestra en la tabla 4 (Ellis et al., 2011).

**Tabla 4.** Descripción del nivel de correlación (Ellis et al., 2011).

0.00-0.19	Muy débil
0.20-0.39	Débil
0.40-0.59	Moderado
0.60-0.79	Fuerte
0.80-1.0	Muy fuerte

**Fuente:** (elaboración propia)

**Figura 14.** Proceso realizado hasta el análisis de correlación



**Fuente:** (elaboración propia)

## 10.6. CLASIFICACIÓN

### 10.6.1. Análisis discriminante lineal (LDA)

LDA es un método de clasificación que proporciona un porcentaje de precisión alto sin requisitos computacionales elevados. Se define como “una función lineal que representa un plano en el espacio de características para distinguir la clase a la que pertenece el vector de características a clasificar” (Alonso, 2012). Suele utilizarse para realizar clasificaciones de patrones hallados en señales EEG cuando se tienen dos clases diferentes, por ejemplo, cuando se trabaja con imaginación motora (Xu et al., 2015). En estos casos, el clasificador LDA asume que ambas son linealmente separables. Este clasificador tiene alta eficiencia

en memoria y en tiempo de computación en comparación a otros clasificadores (Liu et al., 2017). A continuación, se presenta el modelo del clasificador LDA (Ciaburro, 2017).

$$Y = \arg \min \sum_{k=1}^k P(k|x)C(y|k)$$

*(Ecuación 20)*

Donde,

Y: es la clase predicha

K: es el número de clases

$P(k|x)$  es la probabilidad posterior de la clase k para la observación x

$C(y|k)$  es el coste de la clasificación de la observación y cuando su verdadera clase es k

### **10.6.2. Support Vector Machine (SVM)**

En un método de clasificación que se basa en “minimizar el error cuadrático de la función de clasificación, la cual corresponde al hiperplano que separa de mejor manera los datos disponibles” (Braüning, 2018). El clasificador SVM maximiza la distancia entre el hiperplano óptimo y los hiperplanos canónicos que corresponden a los bordes de cada clase. Los vectores más cercanos a los hiperplanos se denominan como vectores soporte (Alonso, 2012).

Los clasificadores de SVM se han utilizado para realizar clasificaciones de dos clases y multiclases. Suelen ser muy utilizados en aplicaciones BCI al igual que los LDA. Los SVM se consideran clasificadores lineales puesto que para realizar la clasificación utiliza uno o varios hiperplanos (Alonso, 2012). Cuando los datos no son linealmente separables se pueden seleccionar dos hiperplanos paralelos los cuales separan las dos clases haciendo que la distancia entre los datos sea lo más grande posible. La región delimitada por los hiperplanos se denomina margen (Hastie, Tibshirani, & Jerome Friedman, 2014).

### 10.6.3. Selección del clasificador

Para seleccionar el clasificador adecuado se realizó el algoritmo para la implementación de LDA, SVM y KNN con validación cruzada de 50 iteraciones y se observó el porcentaje de exactitud que arrojó cada uno de ellos. La tabla 5 presenta los resultados de exactitud obtenidos para la clasificación de los 11 sujetos.

**Tabla 5.** Exactitud de los clasificadores evaluados.

Clasificador	KNN	LDA	SVM
Promedio de exactitud	67,66%	70,83%	63,33%
Desviación estandar	12,30	11,15	12,62

**Fuente:** (elaboración propia)

Con base en los resultados de la tabla 5 el clasificador que se escogió para realizar el análisis de las características extraídas fue Análisis Discriminante Lineal. En las metodologías propuestas por (Wei, Wang, Lin, & Jung, 2018) y (Alonso, 2012) se implementó el mismo clasificador por los resultados obtenidos en comparación con otros y porque es el clasificador que más se utiliza para el procesamiento de interfaces cerebro computador.

## 10.7. VALIDACIÓN DE LA CLASIFICACIÓN

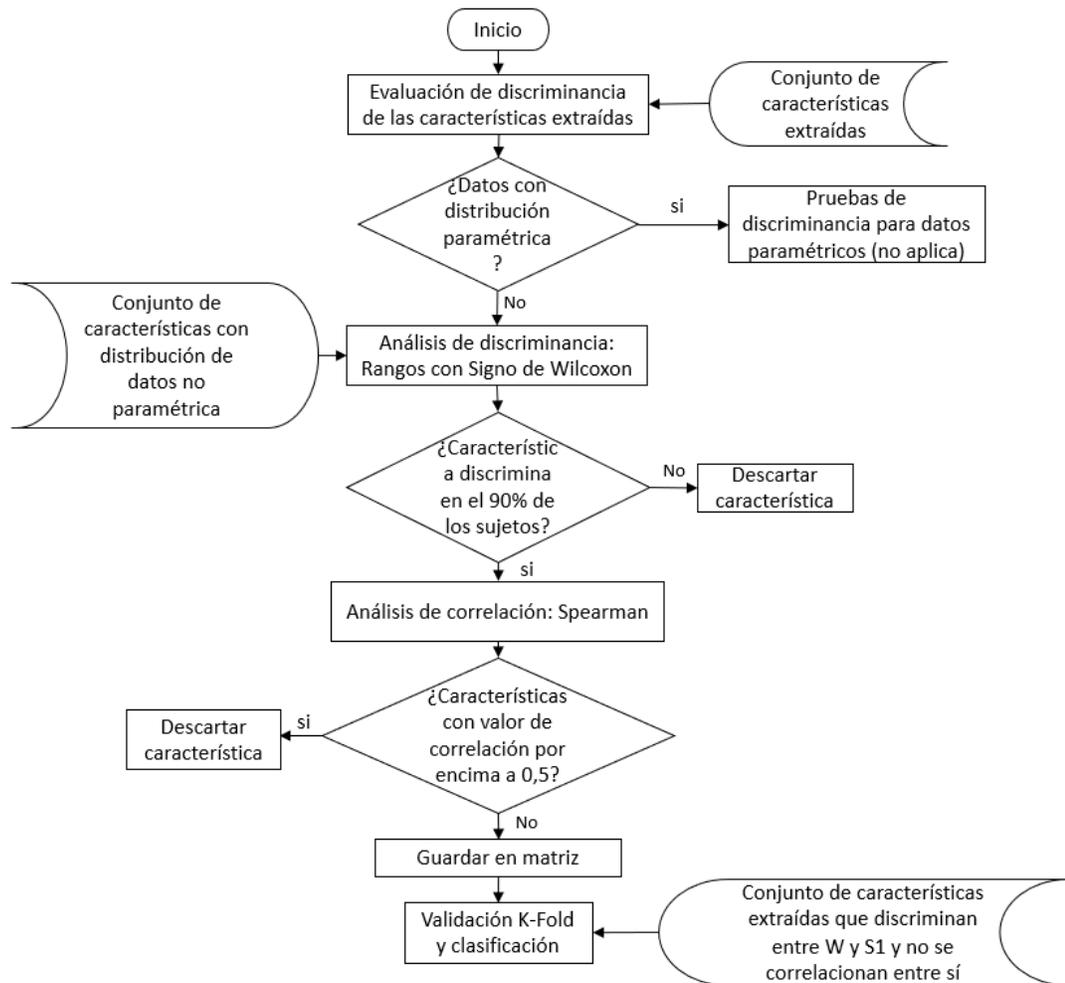
### 10.7.1. K-Fold

La validación cruzada se utiliza para evaluar los resultados obtenidos de un análisis estadístico. Consiste en dividir el conjunto de datos en dos partes, una para entrenamiento y la otra para validación (Espinar Lara, 2018). Existen diferentes métodos para realizar

validación cruzada: validación cruzada de K iteraciones, validación cruzada aleatoria y validación cruzada dejando uno afuera (Moore, 2001; Osuna, 2013).

Para la presente metodología se implementó validación cruzada aleatoria con K iteraciones la cual consiste en tomar un conjunto de datos aleatoriamente, en este caso se seleccionó el 20 % de ellos, para realizar la validación y el conjunto restante realizar el entrenamiento. Con el fin de reducir el sesgo en los resultados, se realizó un K-Fold de 50 iteraciones (Osuna, 2013).

**Figura 15.** Sección de evaluación de las características



**Fuente:** (elaboración propia)

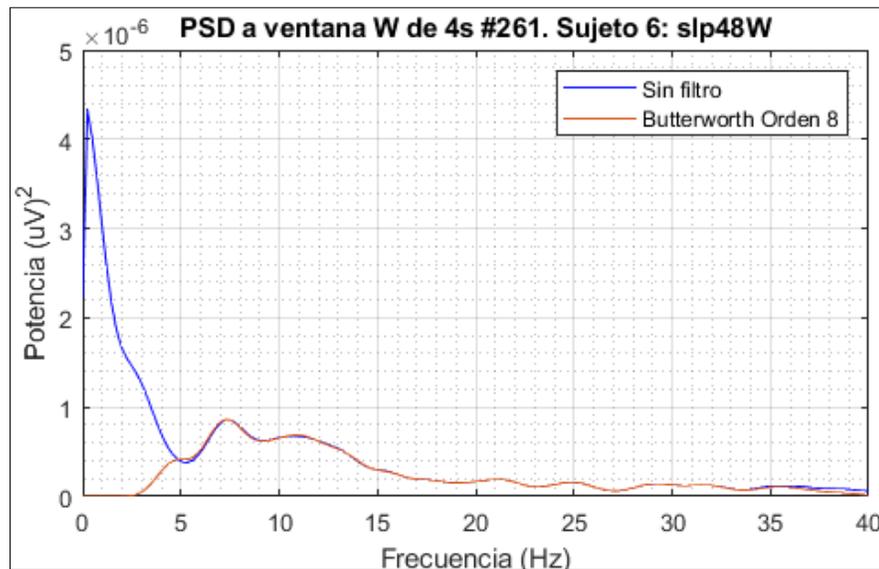
## 11. RESULTADOS Y DISCUSIÓN

### 11.1. PROCESAMIENTO DE LAS SEÑALES EEG

#### 11.1.1. Selección del filtro adecuado y Normalización

Como se mencionó en el ítem anterior, para realizar la selección del filtro se hizo una revisión de literatura con el fin de encontrar aquel que tuviera el comportamiento adecuado para el filtrado de las frecuencias deseadas. Con base en eso, se realizó una evaluación del comportamiento del filtro Butterworth pasa banda para ocho tipos de orden diferentes, ver anexo 1. En la figura 16 se puede ver la señal original en el dominio de la frecuencia (azul) y la señal filtrada (naranja). Como se puede observar en la figura 16 el filtro esta atenuando las frecuencias menores a 4 sin amplificar o atenuar las frecuencias de los rangos entre 4 y 40 Hz.

**Figura 16.** Señal normalizada y filtrada



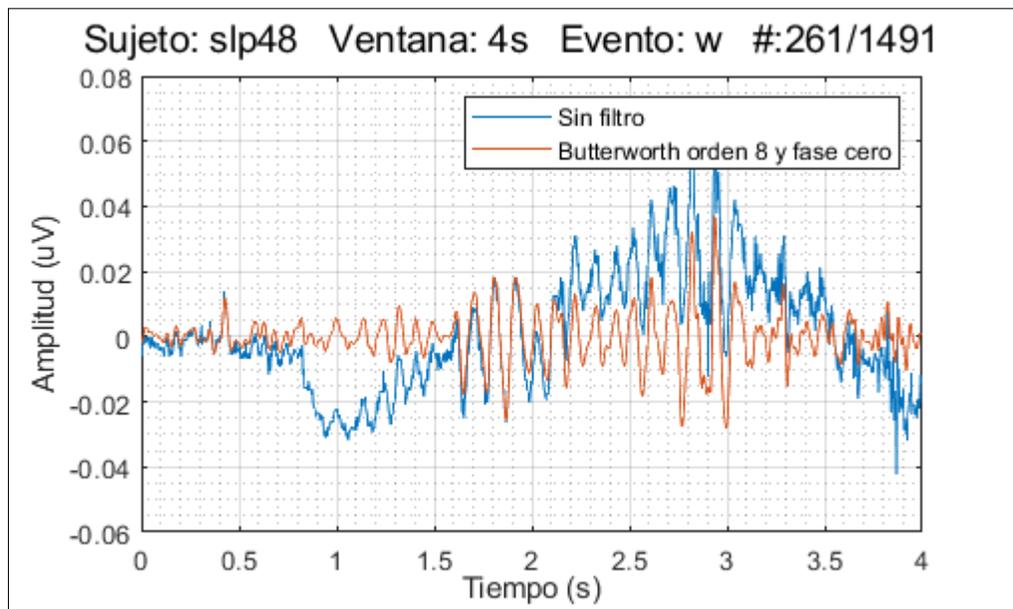
**Fuente:** (elaboración propia)

El orden del filtro se seleccionó con base al trabajo realizado por (Ayyagari, 2017) y a los resultados obtenidos de la comparación de los filtros. El filtro se seleccionó de orden

cuatro ya que con este orden la respuesta mantiene la forma de la señal original, sin embargo, tras implementarse el filtro con corrección de fase cero, el orden del filtro se duplicó a 8. Al usar un orden bajo para el filtro implementado se busca evitar al máximo la alteración de información que proveen las señales y evitar elevar el gasto computacional durante la fase del preprocesamiento (Leif Sornmo., 2018). Además, entre más alto sea el orden del filtro menos lineal va a ser su comportamiento.

En la figura 17 se presenta una gráfica que permite evidenciar el comportamiento del filtro seleccionado en uno de los segmentos de las señales trabajadas. En la figura la línea azul representa a la señal sin filtrar, la línea naranja la señal filtrada y con corrección de fase. Se puede ver como después de realizar el filtro la señal pierde el nivel DC que se puede observar en la señal azul, además, la señal suaviza sus ondas.

**Figura 17.** Señal normalizada y filtrada con corrección de fase.



**Fuente:** (elaboración propia)

## 11.2. CARACTERÍSTICAS A EVALUAR

La tabla 6 muestra cada una de las características extraídas. El número ubicado en la casilla izquierda a cada característica corresponde a aquel con el cual se identifica cada una de ellas en los análisis de discriminancia y de correlación realizados en Matlab. Como se mencionó en la sección de metodología, todas las características se extrajeron hallando las frecuencias relacionadas a las bandas Beta, Alpha y Theta con el método de Welch y la función de integración trapezoidal.

**Tabla 6.** Características extraídas

CARACTERÍSTICAS EXTRAÍDAS	
1	Centroide
2	Entropía
3	Hjort
4	Relación potencia media de las áreas de Theta/Alpha
5	Relación áreas Alpha / Theta
6	Relación áreas (Alpha + Betha) / Theta
7	Asimetría Espectral
8	Curtois Espectral
9	Envergadura Espectral
10	Relación entre área de Theta / (Alpha + Betha)
11	Relación entre área de Theta / Betha
12	Relación entre área de (Alpha + Theta) / Betha
13	Relación entre área de (Alpha + Theta) / (Betha - Theta)
14	Relación entre área de (Alpha - Theta) / área de Theta

**Fuente:** (elaboración propia)

## 11.3. SELECCIÓN DE LAS CARACTERÍSTICAS

En esta última fase se presenta el análisis realizado al conjunto de características con el fin de evidenciar su efecto discriminante entre las clases W y S1.

### **11.3.1. Normalidad**

Para analizar la normalidad de los datos se utilizó el programa estadístico IBM SPSS statistics el cual muestra resultados de dos pruebas diferentes al analizar el comportamiento de los datos, Kolmogorov-Smirnov y Shapiro-Wilk. Se observaron los resultados obtenidos por las dos pruebas, sin embargo, teniendo en cuenta que la prueba de Shapiro Wilk tiene mayor poder estadístico y que se ha convertido en la prueba más utilizada por la misma razón, se centró el análisis en sus resultados (Razali & Wah, 2011).

Los resultados del análisis de normalidad obtenidos con la prueba de Shapiro-Wilk indicaron que todas las características presentan valores de significancia por debajo de 0,05 lo que indica que en todas ellas se rechaza la hipótesis de normalidad en todos los sujetos (Razali & Wah, 2011). Teniendo en cuenta que el análisis es con muestras pareadas y que el resultados de distribución de los datos muestra un comportamiento no gaussiano o normal, se escogió como prueba de discriminancia los Rangos con Signo de Wilcoxon.

### **11.3.2. Discriminancia de las características**

La prueba se realizó para todas las características y todos los sujetos en el programa IBM SPSS statistics y en Matlab para corroborar los resultados obtenidos. A continuación, se presenta la tabla de resultados obtenidos tras aplicar la prueba en Matlab.

Las casillas de la tabla 7 que se encuentran sombreadas corresponden a las características que en la prueba de Wilcoxon mostraron nivel de significancia mayor a 0,05, es decir, que no discriminan entre vigilia y somnolencia en esos sujetos.

**Tabla 7.** Prueba de Rangos con Signo de Wilcoxon

WILCOXON CON RANGOS DE SIGNO												
Características		Sujetos										
		slp03	slp04	slp14	slp16	slp45	slp48	slp59	slp60	slp61	slp66	slp67x
		1	2	3	4	5	6	7	8	9	10	11
C1	Centroide	2,3E-39	9,9E-03	6,1E-05	4,3E-62	5,4E-19	6,8E-66	3,0E-51	2,8E-07	1,8E-39	3,8E-119	2,5E-14
C2	Entropía	8,8E-11	3,0E-31	1,9E-65	8,3E-04	5,1E-03	8,9E-18	7,9E-11	1,5E-02	1,7E-27	7,8E-05	9,6E-03
C3	Hjort	3,8E-38	9,8E-01	6,5E-02	4,4E-40	6,9E-19	1,6E-39	9,1E-35	7,3E-02	1,1E-40	1,6E-101	1,5E-13
C4	Pot media $\theta/\alpha$	1,9E-25	8,9E-50	2,4E-135	1,2E-77	1,6E-15	9,5E-200	1,3E-71	2,5E-60	1,4E-20	5,1E-95	2,5E-27
C5	$\alpha/\theta$	8,3E-30	1,1E-47	1,5E-140	8,0E-81	4,4E-25	1,5E-206	7,7E-79	8,5E-68	9,0E-21	3,7E-81	1,0E-33
C6	$(\alpha + \beta) / \theta$	1,1E-37	1,6E-42	4,3E-149	4,0E-99	8,6E-24	1,7E-191	4,1E-78	6,4E-45	5,3E-34	1,8E-101	2,3E-31
C7	Asimetría	9,9E-03	3,2E-42	8,3E-95	1,5E-16	9,6E-04	1,5E-53	2,0E-46	1,6E-24	2,6E-18	8,3E-01	7,5E-01
C8	Curtosis	1,8E-01	9,4E-45	9,3E-107	1,4E-25	4,0E-06	1,1E-91	5,0E-51	1,9E-43	4,0E-15	6,4E-02	1,9E-01
C9	Envergadura	7,2E-27	1,4E-11	2,6E-38	3,4E-06	9,6E-15	1,1E-06	8,4E-01	7,3E-21	1,0E-38	2,1E-27	1,0E-05
C10	$\theta / (\alpha + \beta)$	1,9E-31	1,7E-45	4,8E-157	2,7E-99	2,6E-20	1,6E-185	9,7E-76	1,1E-39	8,0E-39	8,2E-119	1,3E-31
C11	$\theta / \beta$	2,7E-12	8,1E-30	1,5E-61	1,3E-02	2,9E-01	5,0E-30	2,8E-05	2,2E-02	3,4E-22	2,9E-06	8,3E-05
C12	$(\alpha + \theta) / \beta$	5,0E-24	6,1E-14	1,1E-45	1,6E-48	1,2E-14	3,4E-12	7,4E-45	3,7E-03	2,9E-36	4,6E-113	8,3E-20
C13	$(\alpha + \theta) / (\beta - \theta)$	1,6E-05	1,1E-10	1,4E-06	5,9E-02	7,4E-07	9,5E-09	1,4E-02	3,7E-11	1,8E-01	6,4E-21	4,4E-04
C14	$(\alpha - \theta) / \theta$	8,3E-30	1,1E-47	1,5E-140	8,0E-81	4,4E-25	1,5E-206	7,7E-79	8,5E-68	9,0E-21	3,7E-81	1,0E-33

Fuente: (elaboración propia)

Después de obtener los resultados de discriminancia se procedió a descartar aquellas características que no discriminaban en dos o más sujetos. A continuación, se mencionan las características descartadas en este proceso.

- Movilidad de Hjort (C3): no discrimina en los sujetos 2,3 y 8.
- Asimetría Espectral (C7): no discrimina en los sujetos 10 y 11.
- Curtosis Espectral (C8): no discrimina en los sujetos 1, 10 y 11.
- Relación entre el área de  $\frac{\alpha+\theta}{\beta-\theta}$  (C13): no discrimina en los sujetos 4 y 9.

### 11.3.3. Correlación de Spearman

Como se mencionó en la sección del análisis de discriminancia, se eliminaron 4 características que mostraban valores de significancia mayores a 0,05 en dos o más sujetos. Tras la eliminación de estas se obtuvo una nueva matriz de 12 características a las cuales se les realizó el análisis de correlación mediante la prueba de Spearman en la que

se buscó un valor máximo de correlación de 0,5 entre ellas. Se escogió este umbral con el fin de obtener una correlación, según la tabla de Ellis et al., moderada (Ellis et al., 2011). En la tabla 8 se pueden observar los resultados obtenidos para cada una de las características en los 11 sujetos analizados.

**Tabla 8.** Prueba de correlación de Spearman

CORRELACIÓN DE SPEARMAN ENTRE LAS CARACTERÍSTICAS QUE DISCRIMINAN EN POR LO MENOS 10 DE LOS 11 SUJETOS										
	C1	C2	C4	C5	C6	C9	C10	C11	C12	C14
	Centroide	Entropía	Pot. Media $\frac{\theta}{\alpha}$	$\frac{\alpha}{\theta}$	$\frac{\alpha + \beta}{\theta}$	Envergadura	$\frac{\theta}{\alpha + \beta}$	$\frac{\theta}{\beta}$	$\frac{\alpha + \theta}{\beta}$	$\frac{\alpha - \theta}{\theta}$
C1	1,000	0,655	-0,400	0,359	0,589	0,793	-0,586	-0,724	-0,831	0,359
C2	0,655	1,000	0,053	-0,131	0,129	0,804	-0,172	-0,842	-0,599	-0,131
C4	-0,400	0,053	1,000	-0,902	-0,853	0,043	0,923	0,005	0,568	-0,902
C5	0,359	-0,131	-0,902	1,000	0,775	-0,055	-0,803	0,089	-0,478	1,000
C6	0,589	0,129	-0,853	0,775	1,000	0,130	-0,928	-0,191	-0,682	0,775
C9	0,793	0,804	0,043	-0,055	0,130	1,000	-0,181	-0,842	-0,647	-0,055
C10	-0,586	-0,172	0,923	-0,803	-0,928	-0,181	1,000	0,268	0,773	-0,803
C11	-0,724	-0,842	0,005	0,089	-0,191	-0,842	0,268	1,000	0,770	0,089
C12	-0,831	-0,599	0,568	-0,478	-0,682	-0,647	0,773	0,770	1,000	-0,478
C14	0,359	-0,131	-0,902	1,000	0,775	-0,055	-0,803	0,089	-0,478	1,000

**Fuente:** (elaboración propia)

Como se puede observar en la tabla 8 todas las características tienen por lo menos cinco valores de correlación superiores al umbral de 0,5. Para seleccionar aquellas que mejor discriminaban entre W y S1 y no se correlacionaban entre sí se realizó un algoritmo en Matlab tras el cual se seleccionaron como mejores características el Centroide (C1) y el Cambio del área bajo la curva de Alpha respecto a Theta  $\frac{(\alpha-\theta)}{\theta}$  (C14). Esto no quiere decir que las demás características evaluadas no discriminaran. Se escogieron estas dos porque además de mostrar discriminancia entre las dos clases, su índice de correlación fue de 0,36, además, la unión entre ellas también mostraba discriminancia en el análisis cualitativo.

En la sección 11.4.4 se presenta un diagrama de cajas de cada una de las características escogidas en el que se puede observar el comportamiento de estas en algunos sujetos y un

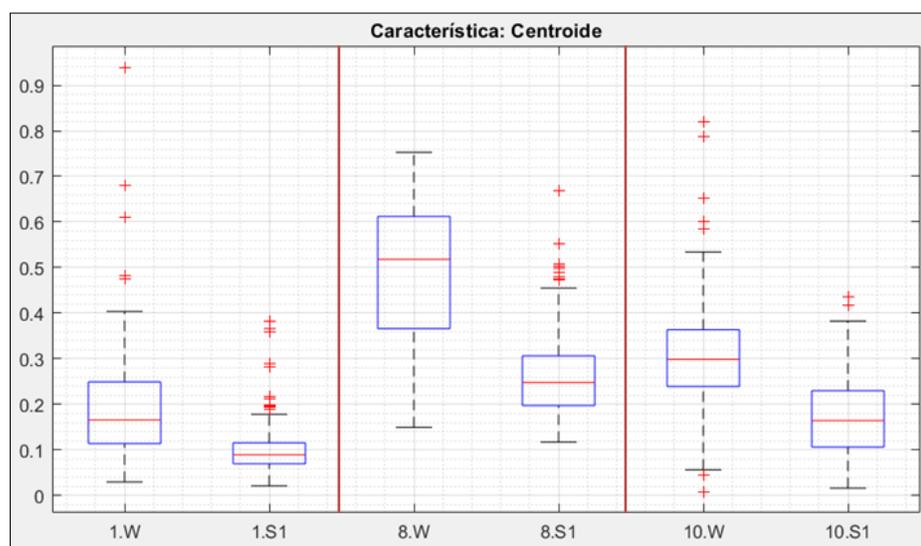
diagrama de dispersión. No se realiza la gráfica de los 11 sujetos al tiempo pues la variación en la amplitud de las cajas entre unos y otros no permite visualizar claramente en aquellos que las cajas son muy pequeñas tanto para W como para S1.

### 11.3.4. Características seleccionadas

#### - Centroide

La primera característica seleccionada fue el Centroide (C1). Como se puede observar en la figura 18 el centroide produce separabilidad en los datos referentes a la clase W (0) y la clase S1 (1) en los sujetos seleccionados para mostrar los resultados. Se esperaba que el índice fuera más alto para vigilia que para somnolencia debido a la asociación que Sobreira et al. hacen entre el Centroide y las frecuencias altas (Sobreira & Rodríguez, 2008). Como se puede ver en la figura 18, el índice es más alto en vigilia que en somnolencia lo que indica que la característica cumple con el comportamiento que se esperaba desde que se planteó.

**Figura 18.** Diagrama de cajas del comportamiento del Centroide



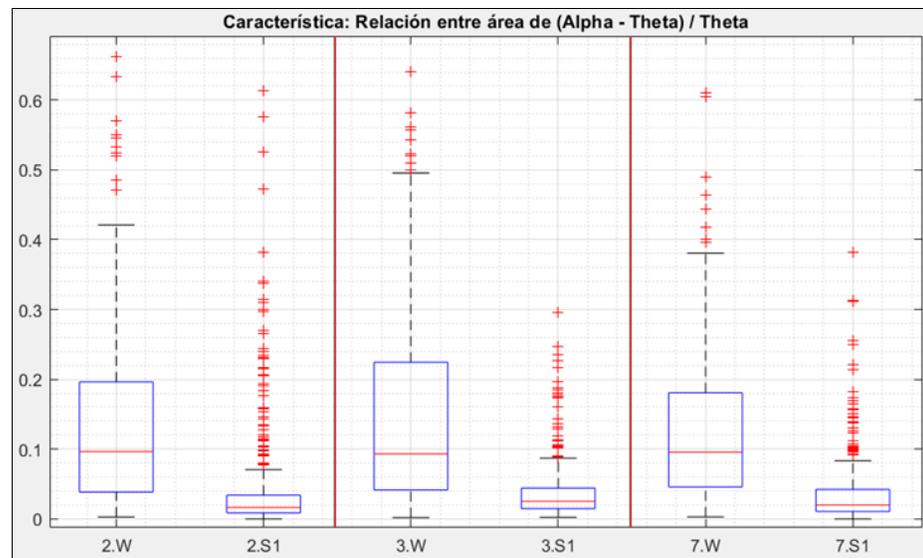
Fuente: (elaboración propia)

En la figura 18 se puede ver que el índice discrimina en las dos clases de interés. En los sujetos 1.S1, 8.S1, 10.W y 10.S1 se presenta distribución simétrica de los datos. En los tres sujetos presentados, el 50% de los datos de S1 se encuentra por debajo del 50% de los datos de W.

- **Cambio del área bajo la curva de Alpha respecto a Theta  $\frac{\alpha-\theta}{\theta}$**

La siguiente característica extraída tras el análisis discriminante y de correlación fue el Cambio del área bajo la curva de Alpha respecto a Theta  $\frac{(\alpha-\theta)}{\theta}$  (C14). En la sección de selección de características se mencionó que se esperaba que el índice fuera más alto en la clase W que en S1 ya que la banda representativa del estado previo a la somnolencia es Alpha (R. Aguirre, 2015a; Carlson, 2010) por lo tanto, si se aplica el índice sobre eventos W se debe observar mayor cantidad de datos acumulados a un nivel más alto que si se aplica sobre eventos S1. En la figura 19 se puede ver que el índice cumple con el comportamiento esperado.

**Figura 19.** Boxplot de la razón entre las áreas de  $\frac{\alpha-\theta}{\theta}$



**Fuente:** (elaboración propia)

En esta característica se puede ver que los dos eventos, W y S1, discriminan el uno del otro aun cuando hay alta presencia de valores atípicos. Tanto en los eventos W como S1 de los tres sujetos, seleccionados aleatoriamente, se puede ver que los datos presentan asimetría hacia la derecha por lo que su sesgo es positivo; esto corrobora que los datos no tienen distribución normal. Adicionalmente cabe notar la gran dispersión de los datos para W con respecto a S, hecho que se reflejará en los gráficos de dispersión de las figuras 20 y 21.

A continuación, en la tabla 9, se presentan las características de esta metodología que discriminan entre la clase W (0) y la clase S1 (1) como alternativa metodológica a otras características planteadas por otros autores que también trabajaron con relaciones de bandas de frecuencias. Esta metodología, como se menciona en la sección de selección de características basó sus cálculos en la selección de frecuencias y potencias a partir del método de Welch mientras que las demás metodologías presentes en la tabla basaron la selección de sus frecuencias en Fourier.

**Tabla 9.** Características por esta metodología y por trabajos previos.

Mejores características extraídas relacionadas a índices basados en las bandas de frecuencia presentes en el sueño								
Esta metodología (2020)	Silveira et al. (2016)		Jap et al. (2009)		Eoh et al. (2005)			
Centroide	$\frac{\alpha - \theta}{\theta}$	$\frac{\gamma}{\delta}$	$\frac{\gamma + \beta}{\delta + \alpha}$	$\frac{\theta}{\beta}$	$\frac{\theta + \alpha}{\alpha + \beta}$	$\frac{\theta}{\alpha}$	$\frac{\beta}{\alpha}$	$\frac{\theta + \alpha}{\beta}$

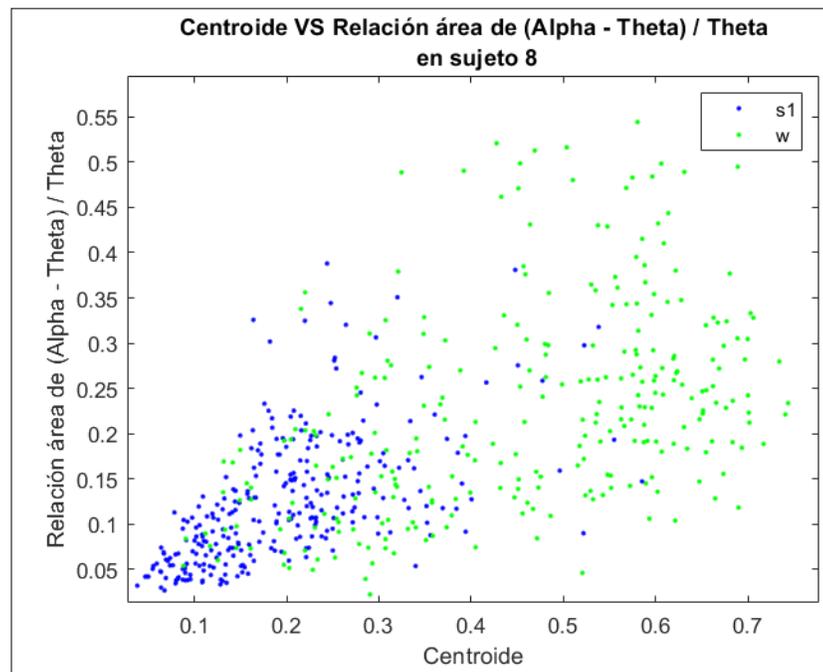
**Fuente:** (elaboración propia)

Durante la revisión de literatura para la selección de nuevos índices a plantear en esta metodología, no se encontró alguno que hiciera alusión al Cambio del área bajo la curva de Alpha respecto a Theta  $\frac{(\alpha - \theta)}{\theta}$  (C14) y tampoco a la implementación del análisis del centroide como característica discriminante entre vigilia y somnolencia. El centroide se ha implementado en reconocimiento de emociones humanas (Murugappan &

Murugappan, 2013), clasificadores de audio (F. Aguirre, 2017), detección de potenciales evocados (Castro Cabrera, 2011) y clasificación de estados del sueño (Hassan et al., 2015) pero, hasta el momento, no se encontró que se utilizara como característica discriminante de los eventos de Vigilia y Somnolencia.

En la figura 20 y 21 se puede ver como las dos características discriminan entre vigilia (puntos verdes) y somnolencia (puntos azules) en algunos de los sujetos presentados anteriormente en los diagramas de cajas.

**Figura 20.** Discriminancia entre Centroide y  $\frac{\alpha-\theta}{\theta}$  en el sujeto 8



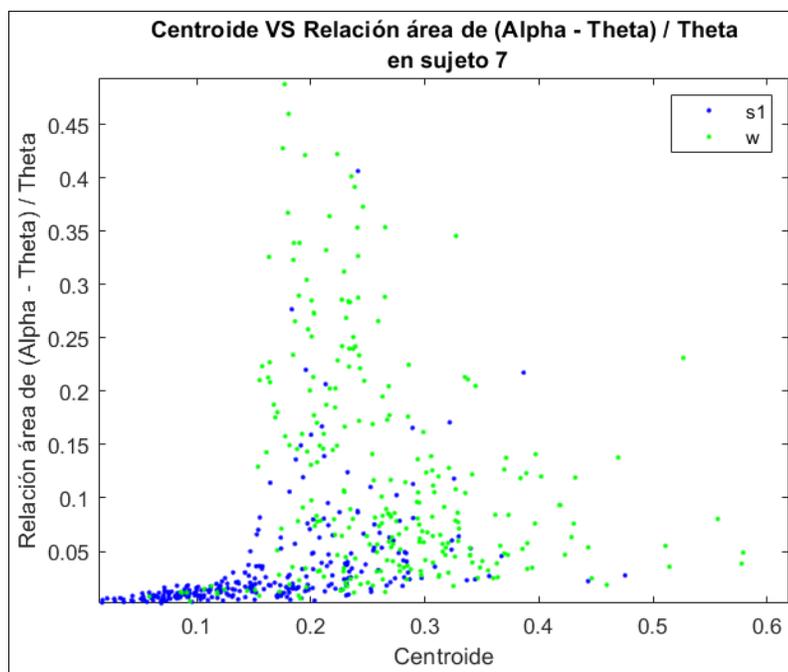
**Fuente:** (elaboración propia)

En la figura 20 se puede observar que hay una discriminancia entre las clases W (verde) y S1 (azul). Aún cuando hay solapamiento en algunos datos en gran medida por valores outlier, se puede evidenciar separabilidad de las dos características extraídas. En la figura 18 se podía ver que un 25% de los datos de W (cola inferior) se solapaba con un 25% de

los datos de S1 (cola superior). En la figura 20 se puede observar que los datos tienen un comportamiento similar a los diagramas de caja presentados para el sujeto número 8.

En la gráfica correspondiente al sujeto 7 (figura 21) se puede observar que, al igual que con el sujeto 8 (figura 20), la agrupación de datos correspondientes a las clase W se encuentran más dispersa que aquellos correspondientes a S1. El mismo comportamiento se pudo observar en los diagramas de cajas de los dos sujetos en donde los datos de W estaban más dispersos que los de S1. También es posible evidenciar la discriminancia entre las dos clases al igual que en la figura 20 aun cuando hay un porcentaje de datos que se solapan entre sí.

**Figura 21.** Discriminancia entre Centroide y  $\frac{\alpha-\theta}{\theta}$  en los sujetos 7



**Fuente:** (elaboración propia)

Un hecho importante que podemos denotar en la tabla 11 de análisis de Spearman, es la baja correlación entre el centroide (C1) y el índice  $\frac{\alpha-\theta}{\theta}$  (C14), cuyo valor es igual a 0.359.

Con esto se muestra la congruencia cualitativa y cuantitativa del análisis realizado ya que, como se puede ver en las gráficas 20 y 21, los datos presentan una dispersión asociada al valor  $\rho$  obtenido del análisis de correlación.

#### **11.4. CLASIFICACIÓN Y VALIDACIÓN**

Después de obtener las características que discriminan entre las dos clases y que no se correlacionan entre sí, se evaluó el desempeño de ellas en conjunto mediante la implementación del clasificador LDA. Este análisis se realizó intrasujeto. Para entrenar el clasificador se utilizó el 80% de los datos y el 20% restante se usó para validación.

Para la validación de los datos se utilizó un K-Fold con  $K=50$  iteraciones. Se escogió este número porque, como se menciona en (Osuna, 2013), a mayor número de iteraciones mayor probabilidad de reducir o eliminar el sesgo. Si bien 50 iteraciones no es un número muy grande, si es alto en comparación con las iteraciones utilizadas por otros autores que han trabajado en la identificación de somnolencia, en donde su validación ha sido con máximo 10 iteraciones.

En la tabla 10 se presenta el valor promedio de exactitud, sensibilidad, especificidad y precisión obtenido para cada uno de los 11 sujetos. Como se puede ver la sensibilidad dio un valor promedio de 79,02% en todos los sujetos lo que indica que el clasificador está detectando el 79% de los eventos S1 como S1. Por otro lado, la especificidad es de apenas 68,7%, es decir que solo se está detectando ese porcentaje de eventos W sobre la cantidad total de eventos W.

**Tabla 10.** Resultados clasificación con LDA y K-Fold de 50 iteraciones.

Numero	Sujeto	Exactitud	Sensibilidad	Especificidad	Presicion
1	slp03	64,8± 2,4	75,3± 3,7	54,8± 3,3	61,8± 3,4
2	slp04	78,5± 2,8	81,7± 4,1	75,0± 4,8	77,6± 3,8
3	slp14	74,3± 1,9	74,1± 2,0	74,5± 2,9	74,8± 2,3
4	slp16	76,8± 2,2	77,8± 3,3	75,7± 3,7	76,1± 3,3
5	slp45	67,6± 3,4	77,9± 3,5	56,9± 6,0	65,4± 4,7
6	slp48	84,1± 1,4	87,0± 1,5	81,1± 2,4	82,0± 2,0
7	slp59	74,7± 2,3	80,1± 3,2	69,2± 3,7	72,8± 4,4
8	slp60	72,0± 1,6	79,9± 1,8	64,3± 2,6	68,8± 2,1
9	slp61	68,6± 2,7	79,6± 4,3	57,8± 4,3	65,2± 3,2
10	slp66	77,9± 1,9	78,3± 3,5	77,5± 2,9	77,6± 3,4
11	slp67x	73,0± 3,5	77,3± 5,3	68,6± 5,1	71,5± 4,3
PROMEDIOS		73,8	79,0	68,7	72,1

**Fuente:** (elaboración propia)

En cuanto a la exactitud del clasificador (tabla 10) se puede ver que no es tan alta como la sensibilidad e indica que aproximadamente el 30% de la información no se está clasificando en el estado que debería ser, W o S1.

El resultado de la clasificación puede estar relacionado a la implementación de un único canal o a la duración de la ventana seleccionada para el análisis. Como se puede observar en la tabla de comparación de resultados (tabla 11) la metodología propuesta por Dey et al., obtuvo un porcentaje de clasificación del 83% de exactitud mientras que la metodología propuesta obtuvo un porcentaje del 73,8%. Como se evidencia en la tabla 11, ellos trabajaron con tres canales bipolares mientras que en este trabajo se implementó un solo canal bipolar. También se considera el tamaño de la ventana seleccionada. La mayoría de las metodologías evaluadas para el desarrollo de este proyecto trabajaron con ventanas de duración mayor a 5 segundos. Aquellos que implementaron ventanas de 1 segundo realizaron su análisis con más de 5 canales.

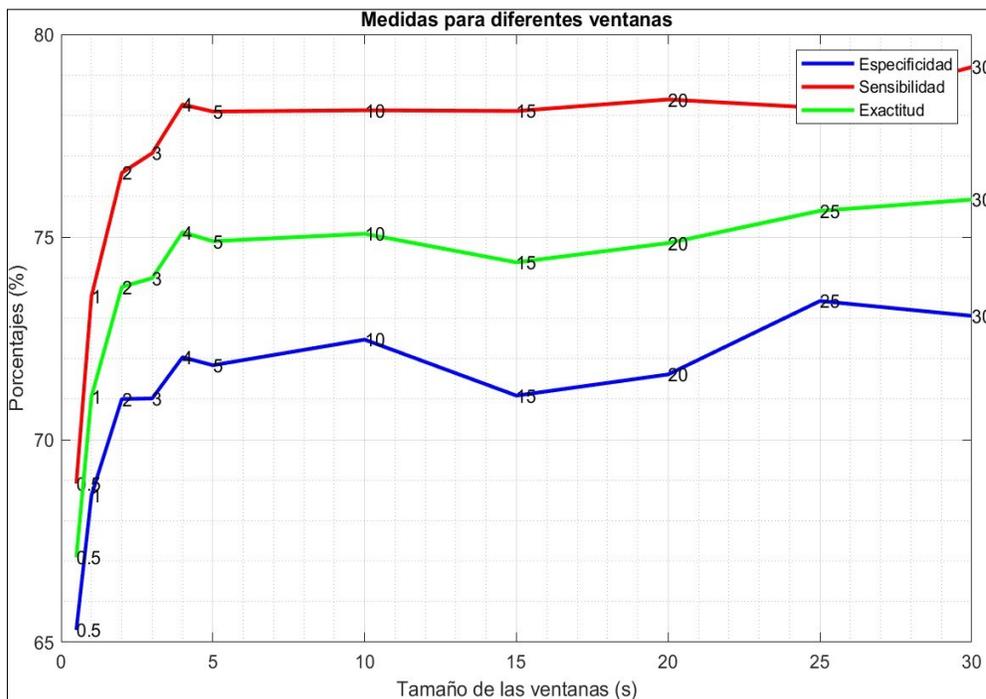
**Tabla 11.** Comparación entre metodologías de detección de somnolencia

Autor (a/as/es)	Método propuesto (2020)	Dey et al. (2017)	Silveira et al. (2016)	Jap et al. (2009)
Base de Datos	MIT-BIH	MIT-BIH	Sleep EDF [expanded]	Grabaciones propias
Canales Evaluados	C3-O1	C3-O1, C4-A1 y O2-A1	Pz-Oz	Los 30 canales EEG
Filtro Utilizado	Butterworth 4to Orden	Butterworth bidireccional	Pasa Banda	--
Tamaño Ventanas	4 segundos	5 segundos	30 segundos	1 segundo
Método de extracción	Welch	Time Analysis	Discrete Wavelet Transform	FFT
Análisis Discriminancia	Rangos con Signo de Wilcoxon / Clasificación	Clasificación	ANOVA	ANOVA
Clasificador	LDA	KNN	--	--
Características extraídas	Centroide Espectral	Máximo	$\frac{\gamma}{\delta}$	$\frac{\theta}{\beta}$
	$\frac{\alpha - \theta}{\theta}$	Mínimo	$\frac{\gamma + \beta}{\delta + \alpha}$	$\frac{\theta + \alpha}{\alpha + \beta}$
		Desviación Estándar		
Porcentaje de detección	Exactitud: 73,84%	Exactitud: 82,7%	--	--

**Fuente:** (elaboración propia)

Como análisis complementario, se realizó el desarrollo de la metodología con ventanas de diferente duración. Esto, con el fin de comparar los resultados de los índices obtenidos tras la clasificación en las de diferente duración y para corroborar si la ventana seleccionada era la adecuada para esta metodología. En la figura 22 se pueden observar los porcentajes de Especificidad, Sensibilidad y Exactitud obtenidos respecto a cada ventana analizada.

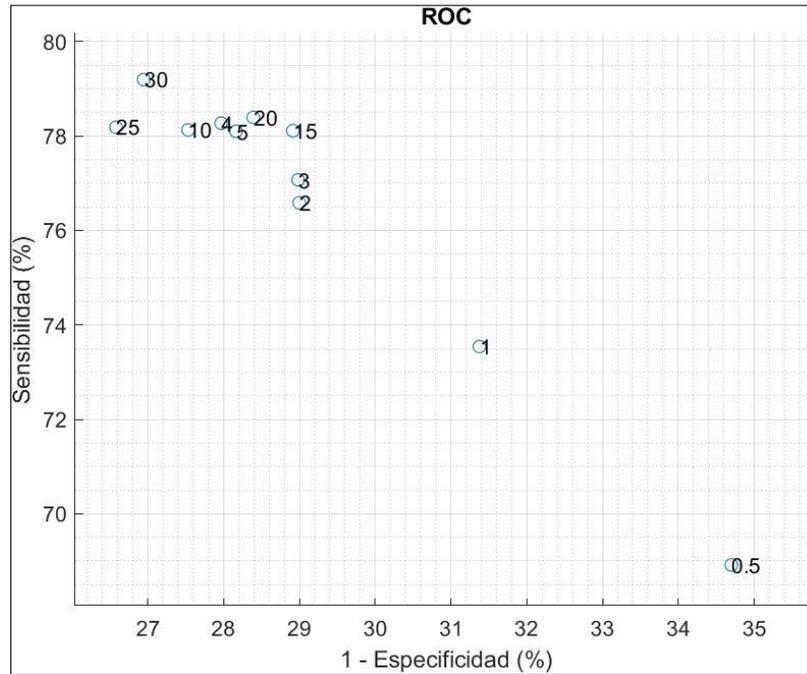
**Figura 22.** Resultados de clasificación en ventanas de diferentes tamaños



**Fuente:** (elaboración propia)

Como se puede observar en la figura 22, de las ventanas analizadas con duración inferior a 5 segundos, la ventana de 4 proporciona mejores porcentajes de clasificación en cuanto a la Especificidad, Sensibilidad y Exactitud a comparación de las ventanas de 3s, 2s, 1s y 5s. Este resultado permite corroborar que la ventana de cuatro segundos tiene mejor desempeño para el desarrollo de esta metodología en comparación con las demás ventanas inferiores a cinco segundos. Se hace énfasis en estas ventanas puesto que como se mencionó al inicio del documento, una de las finalidades de esta metodología era presentar una ventana de longitud inferior a 5s en comparación con las ya utilizadas, que proporcionara la información necesaria para realizar la detección de somnolencia en menos cantidad de tiempo. La figura 23 se presenta con la finalidad de soportar los resultados registrados en la figura 22.

**Figura 23.** ROC para ventanas de diferentes tamaños



**Fuente:** (elaboración propia)

Se puede observar en la figura 23 que el resultado obtenido para la ventana de cuatro segundos es el mejor respecto a otras ventanas con duraciones inferiores a cinco segundos. Si bien las ventanas de 25 y 30 son las mejores de entre el conjunto de ventanas evaluadas, también son las que mayor longitud tienen, por lo tanto, para un análisis en tiempo real, requerirían de al menos un minuto para realizar todo el análisis de somnolencia y, de ser así, no se estaría planteando un sistema de detección eficiente puesto que en esta cantidad de tiempo se puede registrar pérdida de la conciencia y como consecuencia un accidente podría ocurrir.

Como se mencionó anteriormente, este es un análisis complementario que se enfocó en corroborar que la ventana seleccionada fuera la mejor para la metodología planteada, sin embargo, es necesario realizar un análisis en cuanto al gasto computacional que cada una de estas ventanas tiene y así poder determinar cuál de todas es la mejor para implementaciones en tiempo real.

## 11.5. DISCUSIÓN

Para realizar el análisis de discriminancia entre vigilia y somnolencia se inició con la selección del canal bipolar C3-O1 puesto que, según la literatura, los canales ubicados en la zonas centrales, occipitales y parietales presentan buena descripción de la somnolencia (Braüning, 2018; Da Silveira et al., 2016; Gurudath & Bryan Riley, 2014; W. Li et al., 2012). Además, los canales occipitales, según Silveira et al., aportan un poder discriminante y tienen una elevada relación con el estado de somnolencia (Da Silveira et al., 2016).

Los resultados obtenidos tras realizar el análisis discriminante con la prueba de Rangos con Signo de Wilcoxon y el análisis de correlación de Spearman, muestran que las características escogidas al finalizar la metodología tienen un efecto diferenciador entre sí, respuesta que, teniendo en cuenta lo descrito por Silveira et al., demuestra el poder discriminante del canal seleccionado.

Considerando la localización del canal C3-O1 los potenciales musculares y oculares podrían verse reflejados en los registros de la zona occipital más que en la zona central. Es por esto por lo que al pensarse en la implementación en tiempo real de la presente metodología se debe realizar el análisis en cualquiera de los canales ubicados, principalmente, en la zona central. Los registros de la zona occipital no deben descartarse pues como lo menciona Silveira et al., es esta zona la que mayor relación tiene con el sueño, sin embargo, al igual que las zonas frontales y parietales, puede verse perturbada la señal electroencefalográfica de estas zonas al haber movimientos, en especial del músculo relacionado a la barbilla, por parte del sujeto de prueba.

Para hallar la estimación espectral se utilizó el método de Welch el cual pudo generar variabilidad en el índice relacionado con el área bajo la curva de las bandas Alpha y Theta ( $\frac{\alpha-\theta}{\theta}$ ), debido a la distorsión o ruido que genera la implementación de métodos de estimación espectral como el aplicado en esta metodología. Con base a esto, se recomienda realizar de

nuevo el desarrollo de la metodología hallando la estimación espectral a partir de métodos autorregresivos y comparar el comportamiento de la característica seleccionada.

En cuanto a las características seleccionadas al finalizar el proceso, se puede decir que tal como se asumió en la sección *10.3 Selección de las Características*, cada característica respondió al evento que según la literatura planteaba. Por ejemplo, el Centroide marcó valores más altos en los datos correspondientes al estado de vigilia que en los de somnolencia, por lo que se puede afirmar que el centroide se comportó tal como se esperaba desde que se planteó como posible característica. Sin embargo, al realizarse el filtro con frecuencias de corte entre 4 Hz y 40 Hz, es posible que el comportamiento de esta característica se vea afectado por frecuencias mayores a 30 Hz que se pueden estar filtrando en el análisis.

En cuanto a la segunda característica seleccionada, el Cambio del área bajo la curva de Alpha respecto a Theta  $\frac{(\alpha-\theta)}{\theta}$ , se esperaba que los valores obtenidos para la clase W fueran más altos que para la clase S1. Esto, teniendo en cuenta que cuando se está en vigilia es la actividad de la banda Alpha la que predomina sobre la actividad de la banda Theta (R. Aguirre, 2015a; Carlson, 2010). Los resultados arrojados por la prueba de discriminancia podrían confirmar la teoría que se tenía al plantearse el índice pues se puede ver que la característica discrimina, según la prueba de Rangos con Signo de Wilcoxon, entre W y S1. Sin embargo, como se mencionó previamente, puede que su resultado se haya visto afectado por el ruido causado tras la estimación espectral mediante el método de Welch.

Las demás características extraídas que se basaban en las frecuencias de cada banda relacionada al sueño no se descartaron porque no discriminaron entre las dos clases, sino porque al evaluarse el índice de correlación entre ellas se obtenía un valor mayor a 0,8. El valor de correlación tan alto se asocia al origen de cada uno de esos índices, es decir, cada uno de ellos se basó en el análisis de las diferentes bandas de frecuencia y de la conjugación de ellas. Por lo tanto, sin importar la ubicación o la operación que se le asignara a cada índice, siempre mostraban alta redundancia en la información que proporcionaban. El índice

extraído como una de las dos características discriminantes entre vigilia y somnolencia ( $\frac{\alpha-\theta}{\theta}$ ) solo se basó en el análisis de dos de las tres bandas extraídas, por lo tanto, la relación que este presentó con las demás, si bien fue alta con algunas, también dio oportunidad a que no se correlacionara por encima del umbral de correlación evaluado (0,5) con algunas de las otras características evaluadas, como fue el caso del Centroide.

En cuanto al proceso de clasificación, aunque este no era requisito para determinar la discriminancia entre las características extraídas, se realizó con el fin de demostrar que aquellos índices seleccionados discriminaran entre vigilia y somnolencia en todos los sujetos. Para su análisis se evaluó el comportamiento de tres clasificadores utilizados en algunas metodologías que sirvieron como base de este proyecto, *Análisis Discriminante Lineal (LDA)*, *Máquina de Soporte Vectorial (SVM)* y *K-Vecinos más Cercanos (KNN)*.

Los clasificadores LDA y SVM arrojaron valores similares, sin embargo, se pudo evidenciar que el mejor entre ellos fue LDA. Además, este es el clasificador que se implementa con mayor frecuencia en trabajos de Interfaces Cerebro Computador razón por la cual, a pesar de que las características no tenían relación lineal, se implementó este por encima de otros, aun cuando la finalidad de esta metodología no incluye, por el momento, un sistema BCI. No obstante, se recomienda para la continuidad de este proyecto utilizar clasificadores que permitan obtener mejores resultados y que a futuro, aporten en la implementación en tiempo real de esta metodología para la detección de somnolencia.

## 12. CONCLUSIONES

Se extrajeron 14 características en el dominio de la frecuencia con el fin de identificar la presencia del estado de somnolencia en las señales EEG seleccionadas de la base de datos. De acuerdo con las pruebas de discriminancia, diez de las catorce características analizadas rechazaron la hipótesis nula en los 11 sujetos estudiados, es decir, discriminaban entre vigilia y somnolencia.

EL proyecto planteó cuatro índices nuevos basados en el análisis de las bandas de frecuencias relacionadas a las etapas de vigilia y somnolencia de un único canal EEG, C3-O1. Los índices se basaron en el análisis del área bajo la curva obtenida de la estimación espectral mediante el método de Welch de las bandas Beta ( $\beta$ ), Alpha ( $\alpha$ ) y Theta ( $\theta$ ). De esos cuatro se seleccionó el cambio del área bajo la curva de Alpha respecto a Theta ( $\alpha$ - $\theta$ ) / $\theta$  como característica para la detección de somnolencia.

El canal seleccionado para el análisis, C3-O1, aporta información referente a la somnolencia gracias a la relación que tiene el canal occipital con la etapa I del sueño. Si se deseara realizar la implementación de esta metodología en tiempo real el registro de las señales debería realizarse en la zona central o/y occipital. Esto, teniendo en cuenta que en las zonas frontales y parietales se puede ver perturbada la señal EEG por ruidos de señales electromiográficas y electrooculográficas, con mayor potencia que en las zonas recomendadas.

Los resultados obtenidos con la metodología propuesta evidencian que las características escogidas, cambio del área bajo la curva de Alpha respecto a Theta ( $\alpha$ - $\theta$ ) / $\theta$  y centroide, tienen un porcentaje de clasificación de 73,8% de exactitud entre vigilia y somnolencia. Este resultado junto con los valores obtenidos para especificidad y sensibilidad se reducen en comparación con los de otros autores por la cantidad de información obtenida del canal evaluado ya que en esta metodología se empleó únicamente el canal C3-O1, mientras que en las demás metodologías se trabajó con más de tres canales.

Otra razón para que los porcentajes de sensibilidad y especificidad de las características seleccionadas fuera de 79,02% y 68,8%, respectivamente, es el tamaño del segmento seleccionado. Trabajos previos sobre los que se basó esta metodología empleaban ventanas con duraciones mayores a cinco segundos y como mínimo tres canales EEG durante la evaluación, por lo tanto, contaban con más información electroencefalográfica para realizar el análisis de detección.

Teniendo en cuenta los resultados obtenidos en la clasificación, referentes a cada una de las ventanas de tiempo evaluadas, la ventana de cuatro segundos presenta mejores valores de sensibilidad, especificidad y exactitud respecto a las ventanas menores a 5 segundos. Este resultado puede aportar a futuros estudios relacionados a la detección de somnolencia dado que es una ventana que, al aplicarse con mejores características, podría permitir la detección oportuna de la etapa I del sueño.

Si a futuro se desea realizar la implementación en tiempo real de esta metodología, se debe tener en cuenta que los resultados pueden variar significativamente en comparación con los presentados en este documento dado que las marcaciones proporcionadas por la base de datos se basaban en el Manual de Clasificación del Sueño realizado en 1968 por Rechtschaffen and Kales (R&K), el cual se modificó en el 2007 por la Academia Americana de Medicina del Sueño (AASM). Según menciona la AASM, las marcaciones de R&K podrían tener inconsistencias en cuanto a la precisión de las etapas del sueño.

Adicional a la precisión de las marcaciones utilizadas, también se debe tener en cuenta que las señales electroencefalográficas con las que se trabajó se registraron en un ambiente controlado, con pacientes acondicionados para la toma de las señales. Con base en esto, es posible que la discriminancia de las características seleccionadas varíen al momento de realizar el análisis en tiempo real debido a las múltiples perturbaciones que se pueden presentar en una toma EEG durante la conducción, el cual es un proceso que requiere

movimiento corporales y visuales lo cual conlleva a que las señales EMG y EOG se puedan solapar en la señal EEG.

Por último, se espera que la metodología desarrollada aporte a los estudios que se realizan de detección de somnolencia gracias al índice propuesto y a la evaluación del canal y de la longitud de la ventana seleccionada.

### 13. RECOMENDACIONES

1. Para la continuidad de este proyecto es importante seguir combinando características que hayan presentado alta discriminancia entre las clases con nuevos índices propuestos para formar nuevas características que permitan aumentar el porcentaje de exactitud del clasificador implementado.
2. Es preciso, para futuras implementaciones, realizar el registro en las zonas centrales y occipitales ya que pueden verse menos afectadas por ruidos EMG y EOG que las zonas frontales y parietales. Además, según literatura, las zonas C y O se relacionan mejor con el sueño en comparación con las demás zonas.
3. Debido a que el método de estimación espectral implementado en esta metodología puede agregar ruido a los índices planteados, se recomienda el uso de modelos autorregresivos en lugar del Método Welch con el fin de mejorar el comportamiento de las características.
4. Si se desea realizar la implementación de esta metodología en tiempo real, se recomienda hacer uso de filtros adaptativos para remover las señales EMG y EOG que puedan superponerse en la señal EEG registrada.
5. En cuanto al análisis de duración de la ventana, es recomendable realizar una evaluación del gasto computacional que genera una ventana de 4 segundos en comparación con una de 30 segundos. Esto, en pro de hacer más eficientes los sistemas existentes y realizar en menos tiempo la detección de somnolencia.

## 14. REFERENCIAS

- Acuña, E. (2011). *Pruebas no paramétricas* (p. 23). p. 23. Retrieved from <http://math.uprm/edu/~edgar%0AUNIVERSIDAD>
- Aguilar, L., Caballero, S., Ormea, V., Aquino, R., Yaya, E., Portugal, A., ... Muñoz, A. (2017). Neurociencia del sueño: rol en los procesos de aprendizaje y calidad de vida. *Apuntes de Ciencia & Sociedad*, 07(02), 103–109. <https://doi.org/10.18259/acs.2017015>
- Aguirre, F. (2017). *Desarrollo y análisis de clasificadores de señales de audio*. Universidad Politécnica de Valencia.
- Aguirre, R. (2015a). Bases anatómicas y fisiológicas del sueño. *Rev. Ecuat. Neurol*, 15(2–3).
- Aguirre, R. (2015b). *Cambios Fisiológicos en el Sueño*. 22(1). Retrieved from <http://revecuatneurol.com/wp-content/uploads/2015/06/9-Cambios.pdf>
- AL, G., LAN, A., L, G., JM, H., PCh, I., RG, M., ... HE, S. (2003). PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. <https://doi.org/https://doi.org/10.13026/C23K5S>
- Allan Hobson, J. (1969). A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. *Electroencephalography and Clinical Neurophysiology*, Vol. 26, p. 644. [https://doi.org/10.1016/0013-4694\(69\)90021-2](https://doi.org/10.1016/0013-4694(69)90021-2)
- Alonso, L. F. N. (2012). Clasificación de características de electroencefalogramas en sistemas Brain Computer Interface basados en ritmos sensoriomotores. *Universidad De Valladolid*.
- Ayyagari, S. (2017). *Reservoir Computing approaches to EEG-based Detection of Microsleeps*. Retrieved from [https://ir.canterbury.ac.nz/bitstream/handle/10092/13205/Ayyagari%2C Subramanya final PhD thesis.pdf?sequence=1&isAllowed=y](https://ir.canterbury.ac.nz/bitstream/handle/10092/13205/Ayyagari%2C%20Subramanya%20final%20PhD%20thesis.pdf?sequence=1&isAllowed=y)
- Behera, C. K., Reddy, T. K., Behera, L., & Bhattacharya, B. (2014). Artificial neural network based arousal detection from sleep electroencephalogram data. *I4CT 2014 -*

- 1st International Conference on Computer, Communications, and Control Technology, Proceedings, (I4ct)*, 458–462.  
<https://doi.org/10.1109/I4CT.2014.6914226>
- Belakhdar, I., Kaaniche, W., Djemal, R., & Ouni, B. (2018). Single-channel-based automatic drowsiness detection architecture with a reduced number of EEG features. *Microprocessors and Microsystems*, 58(August 2017), 13–23.  
<https://doi.org/10.1016/j.micpro.2018.02.004>
- Benavides-endara, P., & Ramos-galarza, C. (2019). *Fundamentos Neurobiológicos del Sueño Neurobiological Basis Of Sleep*. 28(3), 73–80.
- Bermúdez, A. N., & Spinelli, E. M. (2011). *Detección de eventos en señales de EEG mediante Entropía Espectral*.
- Blanco, R. A., Mauricio, A., Bernal, C., & Torres, M. P. (2017). Diseño de un sistema difuso para el reconocimiento de la actividad muscular en señales de EMG superficiales [ Design of a fuzzy logic system for muscular activity recognition using superficial EMG signals ]. *International Journal of Innovation and Applied Studies*, 19(4), 729–737. Retrieved from <http://www.ijias.issr-journals.org/>
- Boonnak, N., Kamonsantiroj, S., & Pipanmaekaporn, L. (2015). Wavelet Transform Enhancement for Drowsiness Classification in EEG Records Using Energy Coefficient Distribution and Neural Network. *International Journal of Machine Learning and Computing*, 5(4), 288–293. <https://doi.org/10.7763/ijmlc.2015.v5.522>
- Brahmani, K., Kumar, B. A., Ramesh, K. S., Rao, S. K., & Chandra, T. V. (2017). Estimation of power spectral density of seismic data using welch method. *International Journal of Pure and Applied Mathematics*, 114(10 Special Issue), 211–219.
- Braüning, L. F. G. (2018). *Desarrollo de modelo para la identificación de somnolencia basado en redes neuronales convolucionales y procesamiento de señales de electroencefalografía*. Universidad de Chile.
- Carlson, N. (2010). Fundamentos de la fisiología de la conducta. In *Psicothema* (Vol. 5).
- Castro Cabrera, P. A. (2011). Extracción y Selección de Características Discriminantes para

- la Detección de TDAH en Registros de Potenciales Evocados Cognitivos. *Universidad Nacional de Colombia*, 151. Retrieved from <http://www.bdigital.unal.edu.co/3815/>
- CEA. (2015). *El sueño y la fatiga en la conducción*. Retrieved from [www.fundacioncea.es](http://www.fundacioncea.es)
- Chen, J., Wang, H., & Hua, C. (2018). Assessment of driver drowsiness using electroencephalogram signals based on multiple functional brain networks. *International Journal of Psychophysiology*, 133(June), 120–130. <https://doi.org/10.1016/j.ijpsycho.2018.07.476>
- Chipugsi, F. (2017). *Departamento de eléctrica y electrónica*. Retrieved from <https://repositorio.espe.edu.ec/bitstream/21000/8819/1/T-ESPEL-EMI-0262.pdf>
- Ciaburro, G. (2017). *MATLAB for Machine Learning* (S. Patil, C. Dsa, V. Shetty, & V. Pagare, Eds.). Birmingham: Packt Publishing Ltd.
- Correa, K. J., Sara, M., Gomez, L., León, G. S., Magíster, R., Epidemiología, E. N., ... Medellin, S. (2018). *Alteración del patrón del sueño en el paciente crítico: un reto en el cuidado de enfermería*.
- Da Silveira, T. L. T., Kozakevicius, A. J., & Rodrigues, C. R. (2016). Automated drowsiness detection through wavelet packet analysis of a single EEG channel. *Expert Systems with Applications*, 55, 559–565. <https://doi.org/10.1016/j.eswa.2016.02.041>
- Dey, I., Jagga, S., Prasad, A., Sharmila, A., Borah, S. K., & Rao, G. (2017). Automatic detection of drowsiness in EEG records based on time analysis. *2017 Innovations in Power and Advanced Computing Technologies, i-PACT 2017, 2017-Janua*, 1–5. <https://doi.org/10.1109/IPACT.2017.8245167>
- Ellis, M., Novello, I., Ric, L. Y., Hrough, J., Palace, V., Milland, R. A. Y., & Preston, R. (2011). *Spearman's correlation* (p. 8). p. 8.
- Eoh, H. J., Chung, M. K., & Kim, S. H. (2005). Electroencephalographic study of drowsiness in simulated driving with sleep deprivation. *International Journal of Industrial Ergonomics*, 35(4), 307–320. <https://doi.org/10.1016/j.ergon.2004.09.006>
- Espinar Lara, R. (2018). *Modelos de Clasificación con datos no balanceados*. Universidad de Sevilla.
- Garcés Correa, A., Orosco, L., & Laciari, E. (2014). Automatic detection of drowsiness in

- EEG records based on multimodal analysis. *Medical Engineering and Physics*, 36(2), 244–249. <https://doi.org/10.1016/j.medengphy.2013.07.011>
- Garcés, M. A., Salgado, J. D. J., Cruz, J. A., & Cañon, W. H. (2015). Sistemas de detección de somnolencia en conductores: inicio, desarrollo y futuro. *Ingeniería y Región*, 13(1), 159. <https://doi.org/10.25054/22161325.717>
- García-García, J. A., Reding-Bernal, A., & López-Alvarenga, J. C. (2013). Cálculo del tamaño de la muestra en investigación en educación médica. *Investigación En Educación Médica*, 2(8), 217–224. [https://doi.org/10.1016/s2007-5057\(13\)72715-7](https://doi.org/10.1016/s2007-5057(13)72715-7)
- Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* [Online]. 101 (23), pp. e215–e220.
- Graimann, B., Allison, B., & Pfurtscheller, G. (2010). *Brain-Computer Interfaces* (B. Graimann, G. Pfurtscheller, & B. Allison, Eds.). <https://doi.org/10.1007/978-3-642-02091-9>
- Gurudath, N., & Bryan Riley, H. (2014). Drowsy driving detection by EEG analysis using Wavelet Transform and K-means clustering. *Procedia Computer Science*, 34, 400–409. <https://doi.org/10.1016/j.procs.2014.07.045>
- Hassan, A. R., Bashar, S. K., & Bhuiyan, M. I. H. (2015). On the classification of sleep states by means of statistical and spectral features from single channel Electroencephalogram. *2015 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2015*, 2238–2243. <https://doi.org/10.1109/ICACCI.2015.7275950>
- Hastie, T., Tibshirani, R., & Jerome Friedman. (2014). The Elements of Statistical Learning. *The Business of Giving*. <https://doi.org/10.1057/9780230355033.0018>
- Herrera, M. F. (2019). Autoridades han sancionado a 12.796 conductores en este puente festivo. Retrieved from <https://www.rcnradio.com/colombia/autoridades-han-sancionado-12796-conductores-en-este-puente-festivo>
- IBM. (2014). Prueba Kolmogorov-Smirnov. Retrieved from

- [https://www.ibm.com/support/knowledgecenter/es/SSLVMB\\_25.0.0/statistics\\_mainhe lp\\_ddita/spss/base/idh\\_ntk1.html](https://www.ibm.com/support/knowledgecenter/es/SSLVMB_25.0.0/statistics_mainhe lp_ddita/spss/base/idh_ntk1.html)
- Ichimaru, Y., & Moody, G. B. (1999). Development of the polysomnographic database on CD-ROM. *Psychiatry and Clinical Neurosciences*, 53, 175–177. Retrieved from <http://ecg.mit.edu/george/publications/slpdb-pcn-1999.pdf>
- Jap, B. T., Lal, S., Fischer, P., & Bekiaris, E. (2009). Using EEG spectral components to assess algorithms for detecting fatigue. *Expert Systems with Applications*, 36(2 PART 1), 2352–2359. <https://doi.org/10.1016/j.eswa.2007.12.043>
- Leif Sornmo., P. L. (2018). *BIOELECTRICAL SIGNAL PROCESSING IN CARDIAC AND NEUROLOGICAL APPLICATIONS*. <https://doi.org/10.1037/0033-2909.126.1.78>
- Li, W., He, Q. C., Fan, X. M., & Fei, Z. M. (2012). Evaluation of driver fatigue on two channels of EEG data. *Neuroscience Letters*, 506(2), 235–239. <https://doi.org/10.1016/j.neulet.2011.11.014>
- Li, Y., Tang, X., Xu, Z., Liu, W., & Li, J. (2016). Temporal correlation between two channels EEG of bipolar lead in the head midline is associated with sleep-wake stages. *Australasian Physical and Engineering Sciences in Medicine*, 39(1), 147–155. <https://doi.org/10.1007/s13246-015-0409-7>
- Liu, A., Chen, K., Liu, Q., Ai, Q., Xie, Y., & Chen, A. (2017). Feature selection for motor imagery EEG classification based on firefly algorithm and learning automata. *Sensors (Switzerland)*, 17(11). <https://doi.org/10.3390/s17112576>
- Manzanarez, A. R., & Acevedo, J. P. (2015). *Integración numérica : Regla del trapecio Método de Romberg Integración numérica*. Retrieved from [http://www.cimat.mx/?alram/met\\_num/](http://www.cimat.mx/?alram/met_num/)
- MathWorks. (2019). *Integración numérica trapezoidal - MATLAB trapz - MathWorks América Latina*. Retrieved from <https://la.mathworks.com/help/matlab/ref/trapz.html>
- McFarland, D. J., Anderson, C. W., Müller, K. R., Schlögl, A., & Krusienski, D. J. (2006). BCI Meeting 2005 - Workshop on BCI signal processing: Feature extraction and translation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(2), 135–138. <https://doi.org/10.1109/TNSRE.2006.875637>

- Moore, A. W. (2001). *Cross-validation for detecting and preventing overfitting*. Retrieved from <http://www.cs.cmu.edu/~cga/ai-course/overfit.pdf>
- Müller-Putz, G. R., Riedl, R., & Wriessnegger, S. C. (2015). Electroencephalography (EEG) as a research tool in the information systems discipline: Foundations, measurement, and applications. *Communications of the Association for Information Systems*, 37(1), 911–948. <https://doi.org/10.17705/1cais.03746>
- Muñoz, E. L. B., & Mendez, M. M. M. (2015). *Sistema basado en la detección y notificación de somnolencia para conductores de autos* (Universidad de Córdoba; Vol. 151). <https://doi.org/10.1145/3132847.3132886>
- Murugappan, M., & Murugappan, S. (2013). Human emotion recognition through short time Electroencephalogram (EEG) signals using Fast Fourier Transform (FFT). *Proceedings - 2013 IEEE 9th International Colloquium on Signal Processing and Its Applications, CSPA 2013*, (April), 289–294. <https://doi.org/10.1109/CSPA.2013.6530058>
- Néstor, A., Culqui, M. M., Robin, D. D., & Rueda, A. (2009). *Sistema De Monitoreo De Las Ondas Cerebrales (Electroencefalograma O Eeg) Presentes En El Sueño: Análisis De Frecuencia Y Coherencia Del Eeg En Ambos Hemisferios Proyecto Previo a*. Retrieved from <http://bibdigital.epn.edu.ec/bitstream/15000/16797/1/CD-2521.pdf>
- NISSAN. (2019). NISSAN INTELLIGENT MOBILITY. Retrieved from Intelligent Mobility website: <https://es.nissan.pr/vehiculos/new/20-versa/intelligent-mobility.html>
- Oh, S., Lee, Y., & Kim, H. (2014). *A Novel EEG Feature Extraction Method Using Hjorth Parameter*. 2(2), 106–110. <https://doi.org/10.12720/ijeee.2.2.106-110>
- Osorio, J. K. H. (2019). Metodología de clasificación de datos desbalanceados basado en métodos de submuestreo (Universidad Tecnológica de Pereira; Vol. 53). <https://doi.org/10.1017/CBO9781107415324.004>
- Osuna, R. G. (2013). Database Validation Plan. In *Definitions*. <https://doi.org/10.32388/877n7q>
- Pereira, D. M. T., & Toro, J. D. V. (2016). *Desarrollo de un sistema inalámbrico basado en electroencefalograma (EEG) para el monitoreo del sueño en un conductor*. 78.

- Retrieved from <http://dspace.uazuay.edu.ec/bitstream/datos/5835/1/12155.pdf>
- Raphael, M., & Borja, F. De. (2018). *Estudio y Análisis de Métodos para la Extracción de Características y Clasificación de Emociones Basados en EEG*.
- Razali, N. M., & Wah, Y. B. (2011). Power comparisons of Shapiro-Wilk , Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. *Journal of Statistical Modeling and Analytics*, 2(1), 21–33. <https://doi.org/doi:10.1515/bile-2015-0008>
- Richard B. Berry, MD; Rita Brooks, MEd, RST, RPSGT; Charlene E. Gamaldo, M., & Susan M. Harding, MD; Robin M. Lloyd, M. C. L. M. (2016). The AASM Manual for the Scoring of Sleep and Associated Events : Rules, Terminology, and Technical Specifications. *American Academy of Sleep*, 28(3), 391–397.
- Rico-Rosillo, M. G., & Vega-Robledo, G. B. (2018). Sleep and immune system. *Revista Alergia Mexico*, 65(2), 160–170. <https://doi.org/10.29262/ram.v65i2.359>
- Rodrigo, J. A. (2016). *Prueba de los rangos con signo de Wilcoxon alternativa no paramétrica al t-test de medias dependientes*.
- Roggerone, V., Rébillat, M., & Corteel, É. (2017). Parallel Hammerstein Models Identification using Sine Sweeps and the Welch Method. *IFAC-PapersOnLine*, 50(1), 14040–14045. <https://doi.org/10.1016/j.ifacol.2017.08.2434>
- Rosales Mayor, E., & Rey de Castro Mujica, J. (2010). Somnolencia: qué es, qué la causa y cómo se mide: [revisión] TT - Sleepiness: what it is, what causes it, and how measure it: [review]. *Acta Méd. Peru*, 27(2), 137–143. Retrieved from <http://www.scielo.org.pe/pdf/amp/v27n2/a10v27n2.pdf>
- Rosow, A. B., Salles, E. O. T., & Côco, K. F. (2011). Automatic sleep staging using a single-channel EEG modeling by Kalman Filter and HMM. *2011 ISSNIP Biosignals and Biorobotics Conference: Biosignals and Robotics for Better and Safer Living, BRC 2011*, 134–139. <https://doi.org/10.1109/BRC.2011.5740661>
- Rowan, A. J., & Tolunsky, E. (2004). *Conceptos Basicos Sobre EEG*. Retrieved from <https://books.google.com.mx/books?id=d2sOAQAIAAJ>
- Santacruz, A. (2016). *Por qué es importante trabajar con datos balanceados para clasificación*. Retrieved from <http://amsantac.co/blog/es/2016/09/20/balanced-image->

classification-r-es.html

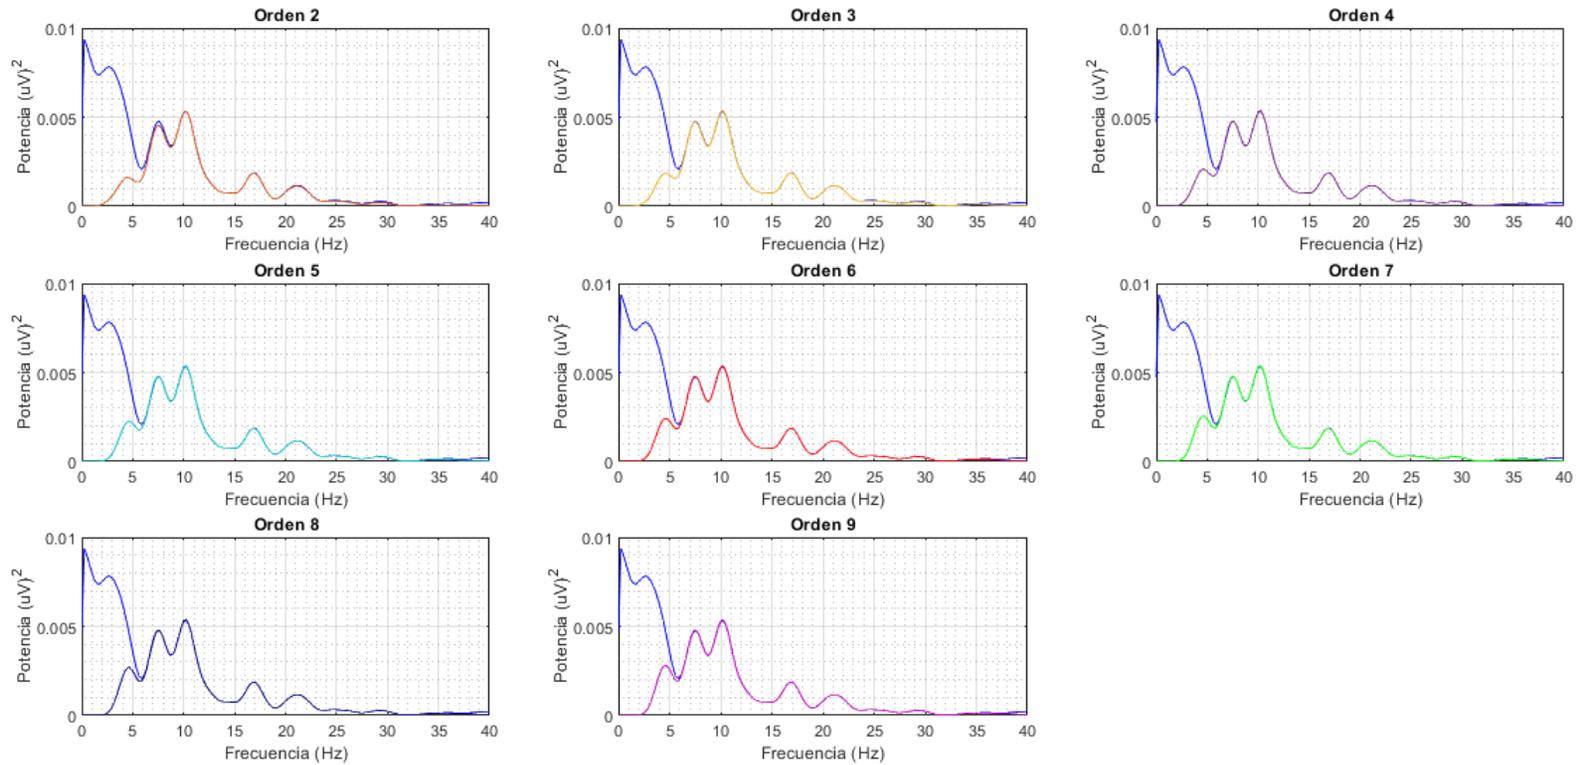
- Schulz, H. (2008). Rethinking sleep analysis. *Journal of Clinical Sleep Medicine*, 4(2), 99–103. <https://doi.org/10.5664/jcsm.27124>
- Sobreira, M., & Rodríguez, A. (2008). Clasificación Automática De Fuentes De Ruido De Tráfico. *Acustica 2008*, 11.
- Talero-Gutiérrez, C., Durán-Torres, F., & Pérez-Olmos, I. (2013). Sueño: Características generales. Patrones fisiológicos y fisiopatológicos en la adolescencia. *Revista Ciencias de La Salud*, 11(3), 333–348.
- Verma, R., & Dekar, R. (2018). Sleep Disorder Detection by Welch Algorithm Based PSD Analysis on EEG Signals. *Sleep*, 5(06), 858–865.
- Wang, H., Wu, C., Li, T., He, Y., Chen, P., & Bezerianos, A. (2019). Driving Fatigue Classification Based on Fusion Entropy Analysis Combining EOG and EEG. *IEEE Access*, 7, 61975–61986. <https://doi.org/10.1109/ACCESS.2019.2915533>
- Wei, C. S., Wang, Y. Te, Lin, C. T., & Jung, T. P. (2018). Toward Drowsiness Detection Using Non-hair-Bearing EEG-Based Brain-Computer Interfaces. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(2), 400–406. <https://doi.org/10.1109/TNSRE.2018.2790359>
- Xu, B., Song, A., Zhao, G., Xu, G., Pan, L., Yang, R., ... Cui, J. (2015). Design and evaluation of a motor imagery electroencephalogram-controlled robot system. *Advances in Mechanical Engineering*, 7(3), 1–11. <https://doi.org/10.1177/1687814015573607>
- Zhang, Z., Guan, C., Chan, T. E., Yu, J., Ng, A. K., Zhang, H., & Kwoh, C. K. (2014). Automatic sleep onset detection using single EEG sensor. *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2014*, 2265–2268. <https://doi.org/10.1109/EMBC.2014.6944071>

## 15. ANEXOS

### ANEXO 1.

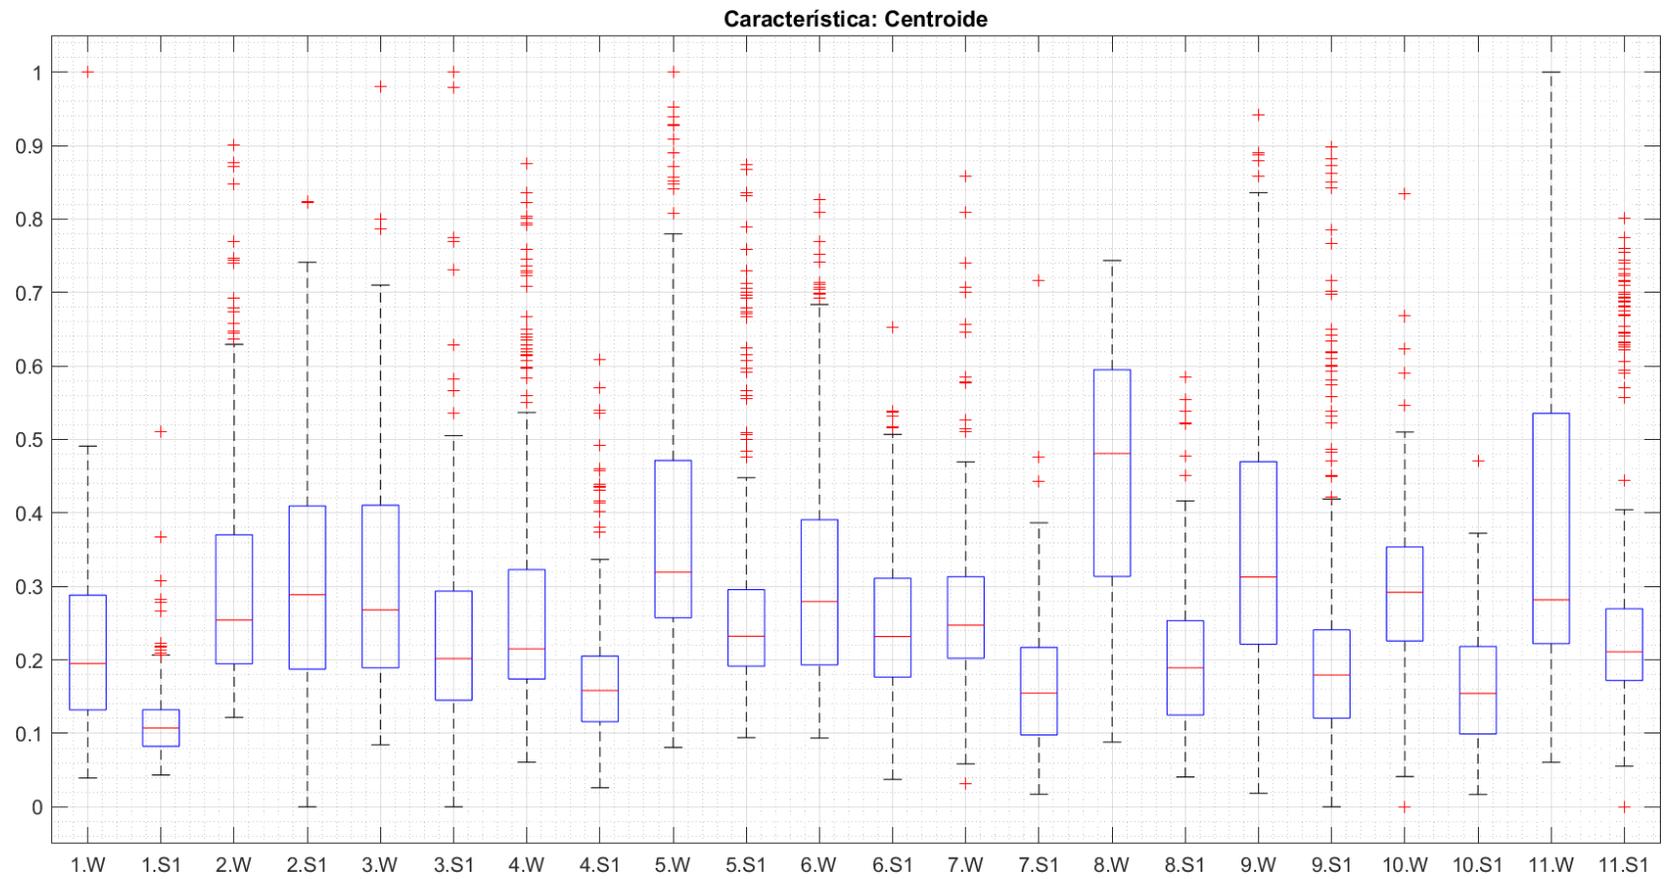
**Figura 24.** Comparación entre órdenes del filtro Butterworth respecto a la señal original.

Sujeto: slp48 Ventana: 4s Evento: w #:70/1491



## ANEXO 2.

Figura 25. Resultado diagrama de cajas del Centroide en todos los sujetos.



**Figura 26.** Resultado diagrama de cajas del Cambio del área bajo la curva de Alpha respecto a Theta  $\frac{\alpha-\theta}{\theta}$

