

	GESTIÓN SERVICIOS BIBLIOTECARIOS						  
	CARTA DE AUTORIZACIÓN						
CÓDIGO	AP-BIB-FO-06	VERSIÓN	1	VIGENCIA	2016	PÁGINA	1 de 2

Neiva, 23 de Enero de 2017

Señores

CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN

UNIVERSIDAD SURCOLOMBIANA

Neiva

Los suscritos: Isabel Alejandra Ávila Vidal con C.C. No. 1075289892 y Jesús Andrés Cruz Sanabria con C.C. No. 1075261947, autores de la tesis y/o trabajo de grado titulado Desarrollo de un Sistema de Detección y Predicción de Somnolencia mediante Procesamiento de Señales Electroencefalográficas presentado y aprobado en el año 2016 como requisito para optar al título de Ingeniero Electrónico, autorizamos al CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN de la Universidad Surcolombiana para que, con fines académicos, muestre al país y el exterior la producción intelectual de la Universidad Surcolombiana, a través de la visibilidad de su contenido de la siguiente manera:

- Los usuarios puedan consultar el contenido de este trabajo de grado en los sitios web que administra la Universidad, en bases de datos, repositorio digital, catálogos y en otros sitios web, redes y sistemas de información nacionales e internacionales “open access” y en las redes de información con las cuales tenga convenio la Institución.
- Permita la consulta, la reproducción y préstamo a los usuarios interesados en el contenido de este trabajo, para todos los usos que tengan finalidad académica, ya sea en formato CD-ROM o digital desde internet, intranet, etc., y en general para cualquier formato conocido o por conocer, dentro de los términos establecidos en la Ley 23 de 1982, Ley 44 de 1993, Decisión Andina 351 de 1993, Decreto 460 de 1995 y demás normas generales sobre la materia.
- Continúo conservando los correspondientes derechos sin modificación o restricción alguna; puesto que, de acuerdo con la legislación colombiana aplicable, el presente es un acuerdo jurídico que en ningún caso conlleva la enajenación del derecho de autor y sus conexos.

De conformidad con lo establecido en el artículo 30 de la Ley 23 de 1982 y el artículo 11 de la Decisión Andina 351 de 1993, “Los derechos morales sobre el trabajo son propiedad de los autores”, los cuales son irrenunciables, imprescriptibles, inembargables e inalienables.



GESTIÓN SERVICIOS BIBLIOTECARIOS

CARTA DE AUTORIZACIÓN



CÓDIGO

AP-BIB-FO-06

VERSIÓN

1

VIGENCIA

2016

PÁGINA

2 de 2

EL AUTOR/ESTUDIANTE:

Isabel Alejandra Ávila Vidal

EL AUTOR/ESTUDIANTE:

Jesús Andrés Cruz Sanabria

Firma:

Firma:

	GESTIÓN SERVICIOS BIBLIOTECARIOS						  
	DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO						
CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2016	PÁGINA	1 de 4

TÍTULO COMPLETO DEL TRABAJO: Desarrollo de un Sistema de Detección y Predicción de Somnolencia mediante Procesamiento de Señales Electroencefalográficas

AUTOR O AUTORES:

Primero y Segundo Apellido	Primero y Segundo Nombre
Ávila Vidal	Isabel Alejandra
Cruz Sanabria	Jesus Andres

DIRECTOR Y CODIRECTOR TESIS:

Primero y Segundo Apellido	Primero y Segundo Nombre
Salgado Patrón	José de Jesús

ASESOR (ES):

Primero y Segundo Apellido	Primero y Segundo Nombre

PARA OPTAR AL TÍTULO DE: Ingeniero Electrónico

FACULTAD: Ingeniería

PROGRAMA O POSGRADO: Ingeniería Electrónica

CIUDAD: Neiva **AÑO DE PRESENTACIÓN:** 2016

NÚMERO DE PÁGINAS: 76

	GESTIÓN SERVICIOS BIBLIOTECARIOS						  
	DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO						
CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2016	PÁGINA	2 de 4

TIPO DE ILUSTRACIONES (Marcar con una X):

Diagramas Fotografías Grabaciones en discos Ilustraciones en general
 Grabados Láminas Litografías Mapas Música impresa Planos
 Retratos Sin ilustraciones Tablas o Cuadros

SOFTWARE requerido y/o especializado para la lectura del documento: Ninguno

MATERIAL ANEXO: Ninguno

PREMIO O DISTINCIÓN (*En caso de ser LAUREADAS o Meritoria*):

PALABRAS CLAVES EN ESPAÑOL E INGLÉS:

<u>Español</u>	<u>Inglés</u>	<u>Español</u>	<u>Inglés</u>
1. EEG	EEG	6. PSD	PSD
2. Somnolencia	Drowsiness	7. Wavelet	Wavelet
3. Señal	Signal	8. Umbralización	Thresholding
4. Artefacto	Artifact	9. KNN	KNN
5. EPOC+	EPOC+	10. SVM	SVM

	GESTIÓN SERVICIOS BIBLIOTECARIOS						  
	DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO						
CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2016	PÁGINA	3 de 4

RESUMEN DEL CONTENIDO: (Máximo 250 palabras)

Este documento presenta un algoritmo para el procesamiento de señales electroencefalográficas EEG con el objetivo de detectar estados de somnolencia y vigilia. El dispositivo seleccionado para la adquisición de los registros EEG utilizados durante el desarrollo de este proyecto, es el EPOC+, diseñado y fabricado por Emotiv Systems. Las muestras electroencefalográficas, regularmente contaminadas por artefactos, deben ser sometidas a una etapa de preprocesamiento antes de continuar con los pasos lógicos en el proceso de caracterización. Se realizó el proceso de atenuación de artefactos utilizando la transformada discreta de Wavelet junto con el método de umbralización suave, para luego reconstruir la señal con su transformada inversa. Mediante la función de densidad espectral de potencia, se procede a determinar los estadios de vigilia y somnolencia. De este proceso fue posible extraer seis características por canal, para posteriormente construir un vector final de 84 características, las cuales representan una ventana de tiempo de cuatro segundos de duración. El algoritmo de máquinas de vectores de soporte con kernel gaussiano fue la técnica de aprendizaje supervisado finalmente elegida, siendo esta la encargada de los procedimientos de clasificación y reconocimiento de patrones que establecerían el estado de la persona y con la cual se alcanzó un 92% de exactitud.

ABSTRACT: (Máximo 250 palabras)

This thesis presents an algorithm for the processing of EEG electroencephalographic signals with the objective of detecting drowsiness and wakefulness stages, mainly directed at individuals prone to cause accidents due to fatigue and/or numbness. The device selected for the acquisition of EEG records used during the development of this project is EPOC+, designed and manufactured by Emotiv Systems. Electroencephalographic samples, regularly contaminated by artifacts, must be subjected to a pre-processing step before proceeding with the logical steps in the characterization process. The artifact attenuation process was performed using the Wavelet discrete transform along with the soft threshold method, to then reconstruct the signal with its inverse transform. By means of the power spectral density function, we proceed to determine the stages of wakefulness and drowsiness. From this process, it was possible to extract six characteristics per channel, to construct a final vector of 84 characteristics, which represent a window of time of four seconds of duration. The Gaussian kernel support vector machine algorithm was the finally chosen supervised learning technique, which was responsible for the procedures for classifying and recognizing patterns that would establish the state of the person and with which it was reached 92% of accuracy.

	GESTIÓN SERVICIOS BIBLIOTECARIOS					  	
	DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO						
CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2016	PÁGINA	4 de 4

APROBACIÓN DE LA TESIS

Nombre Presidente Jurado: José de Jesús Salgado Patrón



Firma:

Nombre Jurado: Faiber Ignacio Robayo Betancourt



Firma:

Nombre Jurado: Diego Fernando Sendoya Losada



Firma:

DESARROLLO DE UN SISTEMA DE DETECCIÓN Y PREDICCIÓN DE
SOMNOLENCIA MEDIANTE PROCESAMIENTO DE SEÑALES
ELECTROENCEFALOGRÁFICAS

JESÚS ANDRÉS CRUZ SANABRIA
ISABEL ALEJANDRA ÁVILA VIDAL

UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERÍA
PROGRAMA DE INGENIERÍA ELECTRÓNICA
NEIVA – HUILA
2016

DESARROLLO DE UN SISTEMA DE DETECCIÓN Y PREDICCIÓN DE
SOMNOLENCIA MEDIANTE PROCESAMIENTO DE SEÑALES
ELECTROENCEFALOGRÁFICAS

JESÚS ANDRÉS CRUZ SANABRIA
ISABEL ALEJANDRA ÁVILA VIDAL

TRABAJO DE GRADO PARA OPTAR POR EL TÍTULO DE
INGENIERO ELECTRÓNICO

DIRIGIDO POR:
ING. MSC. JOSÉ DE JESÚS SALGADO PATRÓN

UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERÍA
PROGRAMA DE INGENIERÍA ELECTRÓNICA
NEIVA – HUILA
2016

Nota de Aceptación

Director

Jurado

Jurado

Neiva, Diciembre 2 de 2016

Dedico este trabajo a mis padres Hortensia y Carlos, mis hermanos Arturo, Diego y Jeison, mi tía Edelmira y su esposo Enrique, y demás familiares que me apoyaron en el transcurso de mi carrera y siempre fueron un gran e importante apoyo para cumplir con esta meta en mi vida. También dedico este proyecto a Paula, porque con su cariño y apoyo constante durante el tiempo del proyecto siempre me animo a no desfallecer. A Jairo y Agustina porque desde la distancia y la cercanía respectivamente, siempre fueron importantes guías y maestros para poder concluir este proyecto.

Jesús Andrés Cruz Sanabria

Este proyecto está dedicado a mi madre, Clara Inés, por sus palabras que llegan siempre en el momento indicado, por sus oídos que constantemente estuvieron disponibles para escuchar mis procederes y mis preocupaciones, y, por su apoyo, que ha permanecido invariante y se ha tornado indispensable. Todo lo que soy, se lo debo a ella. A mis hermanos, Paula, Laura y Felipe, por enseñarme que la responsabilidad es una de las más grandes virtudes que deben prevalecer en todo profesional integral, que siempre existe tiempo para todo y que existen vínculos que jamás se romperán.

Isabel Alejandra Ávila Vidal

AGRADECIMIENTOS

Queremos agradecer a las siguientes personas por su apoyo para la realización del proyecto:

A nuestros padres y familiares que nos apoyaron desde el principio de nuestras carreras universitarias.

PhD. Ing. Carlos Andrés Lozano Garzón por apoyarnos con la documentación necesaria para hacer las consultas pertinentes con el fin de realizar el proyecto.

PhD. Ing. Henry Andrade por estar siempre presto a resolver nuestras dudas a nivel técnico en el área del tratamiento de señales biomédicas.

PhD. Ing. Agustina Garcés porque siempre estuvo atenta desde Argentina y nos acompañó desde el principio del proceso a llevar a feliz término este proyecto.

Ing. Jairo Antonio Cuartas Molina por apoyarnos y dirigir el proyecto en la fase de aplicación de aprendizaje de máquina.

Ms. Ing. José de Jesús Salgado Patrón por aceptar dirigir este proyecto.

Al programa de ingeniería electrónica y su cuerpo docente por darnos la formación académica necesaria para desenvolvemos en nuestras profesiones.

CONTENIDO

	Pág.
1. INTRODUCCIÓN.....	13
2. OBJETIVOS.....	15
2.1. OBJETIVO GENERAL.....	15
2.2. OBJETIVOS ESPECÍFICOS.....	15
3. MARCO TEÓRICO Y ESTADO DEL ARTE.....	16
3.1. SOMNOLENCIA	16
3.1.1. Concepto y consecuencias	16
3.1.2. Trastornos del sueño.....	17
3.2. ESTADO DEL ARTE SOBRE LA SOMNOLENCIA Y SUS SISTEMAS DE DETECCIÓN	17
3.2.1. Detección a través de los apartados mecánicos del vehículo relacionados con el mal desempeño del conductor	18
3.2.2. Detección por métodos de visión por computador	19
3.2.3. Detección por el análisis de señales fisiológicas.....	19
3.3. Diagrama de bloques general propuesto.....	19
4. ELECTROENCEFALOGRAFÍA Y SOMNOLENCIA	20
4.1. INTRODUCCIÓN AL CAPÍTULO.....	20
4.2. ACTIVIDAD ELÉCTRICA CEREBRAL	20
4.2.1. Conducción nerviosa.....	20
4.2.2. Señales y potenciales bioeléctricos.....	21
4.3. ELECTROENCEFALOGRAMA	22
4.3.1. Características de la señal EEG.....	23
4.3.2. Emotiv EPOC+	24
4.4. RITMOS CEREBRALES.....	26
4.4.1. Ondas Delta	27
4.4.2. Ondas Theta	27
4.4.3. Ondas Alpha	27

4.4.4.	Ondas Beta	27
4.4.5.	Ondas Gamma	28
4.4.6.	Otros complejos de ondas.....	28
4.5.	FASES DEL SUEÑO	29
4.5.1.	Fase I	30
4.5.2.	Fase II	30
4.5.3.	Fase III	30
4.5.4.	Fase IV.....	30
4.5.5.	Fase REM	31
5.	PREPROCESAMIENTO DE LA SEÑAL EEG	32
5.1.	INTRODUCCIÓN AL CAPÍTULO.....	32
5.2.	ADQUISICIÓN DE LA SEÑAL EEG	32
5.3.	NORMALIZACIÓN DE LA SEÑAL.....	34
5.4.	VENTANEO DE LA SEÑAL.....	34
5.5.	FILTRADO Y ACOTACIÓN DE LA SEÑAL	34
5.6.	Transformada Discreta de Wavelet	35
5.6.1.	Niveles y coeficientes.....	36
5.6.2.	Umbralización	37
5.6.3.	Coeficientes de aproximación y de detalle	37
5.6.4.	Transformada Inversa Discreta de Wavelet	38
6.	PROCESAMIENTO Y CARACTERIZACIÓN DE LA SEÑAL EEG	40
6.1.	INTRODUCCIÓN A CAPÍTULO.....	40
6.2.	DENSIDAD ESPECTRAL DE POTENCIA.....	40
6.3.	CARACTERIZACIÓN EEG	41
6.3.1.	Energía entre 4Hz y 8Hz	42
6.3.2.	Energía entre 8Hz y 12Hz	42
6.3.3.	Frecuencia en la potencia máxima.....	42
6.3.4.	Entropía de Shannon	42
6.3.5.	Entropía energética	43
6.3.6.	Entropía de Renyi.....	43

6.4.	HISTORIAL DE MUESTRAS DE EEG.....	44
6.5.	ANÁLISIS DE COMPONENTES PRINCIPALES	44
6.5.1.	Normalización de características.....	45
6.5.2.	Aplicación del PCA.....	45
7.	RECONOCIMIENTO DE PATRONES PARA LA CLASIFICACIÓN DE LA SEÑAL EEG.....	46
7.1.	INTRODUCCIÓN DE CAPÍTULO	46
7.2.	PREPARACIÓN DE DATOS	46
7.3.	SECCIONAMIENTO DE DATOS Y VALIDACIÓN CRUZADA.....	47
7.4.	PIPELINE.....	48
7.5.	STACK DE CLASIFICACIÓN	48
7.6.	INDICADORES DE ENTRENAMIENTO, VALIDACIÓN Y TESTEO.....	49
7.6.1.	Precisión	49
7.6.2.	Exhaustividad.....	49
7.6.3.	Valor F.....	50
7.6.4.	Vectores.....	50
7.7.	K-ÉSIMO VECINO MAS CERCANO	50
7.7.1.	Vecinos	51
7.7.2.	Pesos	51
7.7.3.	Resultados de implementación de KNN.....	51
7.8.	MAQUINA DE VECTORES DE SOPORTE	52
7.8.1.	Kernel.....	53
7.8.2.	C.....	53
7.8.3.	Gamma	54
7.8.4.	Optimización convexa	54
7.8.5.	Resultados de Implementación de SVM	55
8.	ANÁLISIS DE RESULTADOS	57
8.1.	INTRODUCCIÓN DE CAPÍTULO	57
8.2.	ANÁLISIS DEL SUBPROCESO DE PREPROCESAMIENTO DE LA SEÑAL	57

8.3. ANÁLISIS DEL SUBPROCESO DE PROCESAMIENTO DE LA SEÑAL .58	
8.4. ANÁLISIS DEL SUBPROCESO DE CLASIFICACIÓN Y RECONOCIMIENTO DE PATRONES DE LA SEÑAL.....59	
8.5. ANÁLISIS DE LOS SISTEMAS DE ENTRENAMIENTO Y CLASIFICACIÓN 62	
9. CONCLUSIONES.....65	
10. RECOMENDACIONES Y TRABAJOS FUTUROS.....68	
11. BIBLIOGRAFÍA.....70	

LISTA DE TABLAS

	Pág.
Tabla 1 Especificaciones técnicas del equipo Emotiv Eporc+.....	25
Tabla 2 Segmentos frecuenciales de coeficientes de aproximación.....	38
Tabla 3 Segmentos frecuenciales de coeficientes de detalle	38
Tabla 4 División de datos para el clasificador	47
Tabla 5 Pipeline entrenamiento programado para KNN	52
Tabla 6 Indicadores de entrenamiento para el test del mejor entrenamiento para KNN	52
Tabla 7 Pipeline de entrenamiento programado para SVM de kernel Lineal	55
Tabla 8 Indicadores de entrenamiento para el test del mejor entrenamiento para SVM de kernel lineal	55
Tabla 9 Pipeline de entrenamiento programado para SVM de kernel radial	55
Tabla 10 Indicadores de entrenamiento para el test del mejor entrenamiento para SVM de kernel radial.....	56
Tabla 11 Correlación entre señal sin filtrar y después de filtrar con el subsistema propuesto.....	58

LISTA DE FIGURAS

	Pág.
Figura 1 Diagrama de bloques general del proyecto	19
Figura 2 Señal EEG canal F3 sin ningún tipo de tratamiento tomada el 16-08-2016 con duración de 60 segundos	22
Figura 3 Dispositivo Físico Emotiv Epoc+.....	24
Figura 4 Ritmos cerebrales más comunes.....	26
Figura 5 Huso del sueño (Sleep Spindle) y Complejo K (K-Complex).	28
Figura 6 Fases del sueño (eje y) vs Horas de sueño (eje x) saludable.....	29
Figura 7 Señales EEG en crudo del canal F3 (A) Señal de muestra en Somnolencia (B) Señal de muestra en Vigilia.....	33
Figura 8 Subproceso de adquisición de muestras	33
Figura 9 Señales EEG del canal F3 posterior al filtro IIR butterworth (A) Señal de muestra en Somnolencia (B) Señal de muestra en Vigilia	35
Figura 10 (a) Señal sin umbralizar (b) señal con umbralización fuerte (c) señal con umbralización suave	37
Figura 11 Señales EEG del canal F3 posterior al proceso de DWT – IDWT (A) Señal de muestra en Somnolencia (B) Señal de muestra en Vigilia	39
Figura 12 Diagrama de PSD de la señal EEG en Vigilia del canal F3 después del preprocesamiento	41
Figura 13 Validación cruzada con N=5	47
Figura 14 Subproceso de clasificación	48
Figura 15 Efectos de C en la selección de Vectores de Soporte	54
Figura 16 Comparación de exactitud de los clasificadores	60
Figura 17 Exactitud de clasificadores con seccionamiento invertido	60
Figura 18 Resultado del proceso de reconocimiento de patrones a) estados clasificados por medio del soporte audiovisual b) datos a la salida del clasificador c) datos con media móvil d) datos con umbralización fuerte a media móvil	61
Figura 19 Diagrama de bloques específico de los sistemas de entrenamiento y clasificación de reconocimiento de patrones para la detección de somnolencia a partir de señales EEG	63

RESUMEN

Este documento presenta un algoritmo para el procesamiento de señales electroencefalográficas EEG con el objetivo de detectar estados de somnolencia y vigilia, principalmente dirigido a individuos propensos a causar siniestros por causa de la fatiga y/o el adormecimiento. El dispositivo de baja resolución seleccionado para la adquisición de los registros EEG utilizados durante el desarrollo de este proyecto, es el EPOC+, diseñado y fabricado por Emotiv Systems. Fue escogido por su facilidad de manejo, por su soporte y amplia documentación y, por supuesto, por su bajo costo (sin comprometer su confiabilidad).

Las muestras electroencefalográficas, regularmente contaminadas por artefactos, deben ser sometidas a una etapa de preprocesamiento antes continuar con los pasos lógicos en el proceso de caracterización, debido a la amplitud tan reducida que presentan estas señales por naturaleza. Para esta tarea, cada registro EEG adquirido fue sometido a un estudio mediante ventanas cuya duración fuese lo suficientemente corta como para que cada señal pudiese ser considerada estacionaria. Posterior a esto, se realizó el proceso de atenuación de artefactos utilizando la transformada discreta de Wavelet junto con el método de umbralización suave, para luego reconstruir la señal con su transformada inversa.

Una vez reconstruida la señal EEG, mediante la función de densidad espectral de potencia (PSD), la cual brinda información sobre cómo está distribuida la señal en el dominio frecuencial, se procede a determinar los estadios de vigilia y somnolencia. De este proceso fue posible extraer seis características por canal, para posteriormente construir un vector final de 84 características, las cuales representan una ventana de tiempo de 4 segundos de duración. El algoritmo de máquinas de vectores de soporte SVM con kernel gaussiano fue la técnica de aprendizaje supervisado finalmente elegida, siendo esta la encargada de los procedimientos de clasificación y reconocimiento de patrones que establecerían el estado de la persona y con la cual se alcanzó un 92% de exactitud.

PALABRAS CLAVE: Electroencefalografía, somnolencia, vigilia, Transformada de Wavelet Discreta, Densidad Espectral de Potencia, Máquina de Vectores de Soporte.

1. INTRODUCCIÓN

El cerebro es el órgano más importante de los mamíferos, pues este es por decirlo de alguna forma la Unidad Central de Proceso de nuestro cuerpo, es el encargado de regular nuestras funciones vitales y de guardar información que vamos adquiriendo a través de nuestra vida (Garcés C., Orosco, & Laciari, 2014) (Navarro, Tema 5: Electroencefalografía, 2011). Este gran flujo de información se hace por medio de un proceso que se le conoce como sinapsis, que no es más que la forma en la que las neuronas intercambian información por medio de señales bioeléctricas. Desde principios de los años 1920 se registran los primeros electroencefalogramas (EEG) en humanos, a pesar de que los electrolitos no eran muy eficientes y apenas comenzaba a debelarse la importancia de capturar las señales cerebrales, no fue sino hasta la década de 1950 que estos estudios comenzaron a cobrar más fuerza tomando características de los EEG de manera manual con el fin de estudiar el proceso del sueño (Guerrero Martínez, 2010) (Gil-Nagel A, 2002).

A pesar de que en la actualidad existen otras técnicas para detectar somnolencia, como visión artificial para análisis de gestos y comportamientos de las personas, no hay que subestimar lo precisas que son las señales biológicas y toda la información que pueden brindar sobre el estado de una persona, es por esto que es importante profundizar y contribuir en los estudios que actualmente se realizan en esta área teniendo en cuenta las bondades que ofrecen las diferentes técnicas en el área del procesamiento digital de señales y de reconocimiento y clasificación de patrones. Por ende, un estudio basado en la clasificación de la señal EEG en diversos componentes y la detección temprana del sueño, permitiría la implementación de sistemas en vehículos que monitoreen conductores que por diversos factores se encuentren somnolientos mientras están delante de un volante o para determinar la cantidad de anestesia necesaria a aplicar a la hora de realizar una intervención quirúrgica invasiva.

Este proyecto pretende establecer las bases necesarias para realizar futuros proyectos y aplicaciones usando información suministrada por señales biológicas, en este caso la señal EEG y la información sobre los estados de somnolencia y vigilia. Sus aportes a nivel académico permitirán detectar el uso de técnicas de procesamiento digital de señal y de reconocimiento de patrones para el análisis de la señal EEG. Las muestras fueron tomadas a nivel intrapersonal, siendo Jesús Andrés Cruz Sanabria quien en diferentes sesiones aportó muestras bajo ambientes controlados, por lo que se trató al máximo de reducir factores como sudoración,

altos volúmenes de cabello, caspa y otros factores que puedan incurrir en lecturas erradas del EEG, pues no es objeto de estudio en esta investigación tomar muestras en situaciones reales. Lo que se obtuvo finalmente fue un algoritmo capaz de discriminar entre los estados de sueño y vigilia según muestras de EEG que se le suministren. Los buenos resultados obtenidos en este proyecto benefician diferentes niveles de la academia y la ciencia, pues se incentivarán a llevar a cabo más investigaciones que permiten formular aplicaciones con los resultados aquí obtenidos.

Finalmente presentamos un algoritmo para el procesamiento de señales electroencefalográficas EEG. El dispositivo seleccionado para la adquisición de los registros EEG utilizados durante el desarrollo de este proyecto, es el EPOC+, diseñado, fabricado por Emotiv Systems. El algoritmo analiza las muestras electroencefalográficas, regularmente contaminadas por artefactos, que primeramente son sometidas a una etapa de preprocesamiento antes de continuar y posteriormente caracterizada. Se realizó el proceso de atenuación de artefactos utilizando la transformada discreta de Wavelet junto con el método de umbralización suave, para luego reconstruir la señal con su transformada inversa. Mediante la función de densidad espectral de potencia, se procede a extraer las características que permitirán determinar los estadios de vigilia y somnolencia. De este proceso fue posible extraer seis características por canal, para posteriormente construir un vector final de 84 características, que posteriormente pasara por un sistema de Análisis de Componentes Principales. Estas características representan una ventana de tiempo de cuatro segundos de duración. El algoritmo de máquinas de vectores de soporte con kernel radial gaussiano fue la técnica de aprendizaje supervisado finalmente elegida, siendo esta la encargada de los procedimientos de clasificación y reconocimiento de patrones que establecerían el estado de la persona y con la cual se alcanzó un 92% de exactitud.

2. OBJETIVOS

2.1. OBJETIVO GENERAL

Diseñar un sistema para la identificación del estado de somnolencia de manera inalámbrica basado en el procesamiento digital de la señal EEG.

2.2. OBJETIVOS ESPECÍFICOS

Diseñar un sistema basado en técnicas de procesamiento digital de señales para filtrar la señal EEG adquirida.

Plantear un sistema digital para caracterizar la señal EEG en las diferentes etapas del sueño y la vigilia.

Diseñar un sistema de análisis para las señales obtenidas, capaz de interpretar el estado de somnolencia basado en inteligencia computacional.

Generar un sistema embebido que integre el sistema de filtrado, caracterización y clasificación de estados del sueño a partir de registros EEG previamente obtenidos.

3. MARCO TEÓRICO Y ESTADO DEL ARTE

3.1. SOMNOLENCIA

3.1.1. Concepto y consecuencias

La somnolencia es el estado en el que una persona tiende al adormecimiento durante el día, por lo general, en horas diferentes a las regulares para dormir, su causa principal reside en los malos hábitos de sueño y llega a ser considerada un problema cuando esta lleva al sujeto a quedarse dormido en situaciones inapropiadas (Pérez, 2016).

La somnolencia se puede clasificar en dos según su origen, la somnolencia fisiológica, relacionada con la edad o con situaciones concretas, como el síndrome premenstrual (PMS), el embarazo, el ejercicio físico intenso, entre otros; y la somnolencia patológica, que se manifiesta cuando existe una enfermedad que la origina (saludemia, 2016).

El descanso nocturno (y en menor medida, el descanso particionado a lo largo del día) resulta ser más importante de lo que se cree; no solo es beneficioso, si no imprescindible, incluso más que la comida, lo cual ya es mucho decir. Una persona en estado permanente de somnolencia, no realizaría la restauración debida de los centros neuronales, afectaría negativamente sus sentidos y alteraría sus niveles de cortisona y melatonina, hormonas encargadas de producir e inhibir el sueño respectivamente (Tiempo, 2004).

En función de la edad, está determinada la cantidad de horas de sueño que tanto niños como adultos necesitan para ejecutar de manera simple las tareas diarias, por ejemplo, los bebés necesitan dormir un promedio de 17 horas diarias, los niños deben dormir unas 10 horas, mientras que los adultos tienen la menor tasa de sueño recomendada, siendo esta entre 7 y 8 horas (Alonso, 2016).

El ritmo de vida actual ha intentado y logrado en medida que el proceso de dormir se vea alterado por factores como el estrés, la depresión y la adicción al trabajo, produciendo malos hábitos de descanso, que llevan a intensificar las dolencias que ya cada ser humano presenta y a crear nuevas tales como: afecciones neurodegenerativas, trastornos gastrointestinales, incremento del apetito y obesidad, repercutiendo de manera directa sobre la calidad de vida de los individuos

perjudicados, afectando su rendimiento laboral, relaciones personales y aumentando el riesgo de accidentes.

3.1.2. Trastornos del sueño

La Organización Mundial de la Salud (OMS) afirma que en la actualidad existen 88 tipos de trastornos del sueño, los cuales, adicional a las consecuencias mencionadas anteriormente, llevan a la población afectada a pensar que las noches de sueño reparador y relajante han terminado, convirtiendo el hábito de dormir en una tarea tensionante (de Medicina Avanzada (RIMA), 2016).

La misma organización, además, insiste en que dormir, más que un placer, es una necesidad, por lo que decidió clasificar los trastornos del sueño en primarios y secundarios, estando incluidos en los primeros, afecciones populares como el insomnio y la hipersomnia, mejor conocida como uno de nuestros temas de estudio, la somnolencia, y otros padecimientos tales como el sonambulismo y los trastornos del ciclo sueño-vigilia. Los trastornos del segundo tipo, están mayormente relacionados a enfermedades, entre las que destacan el síndrome de apnea obstructiva del sueño y el síndrome de las piernas inquietas (Torres, 2016).

3.2. ESTADO DEL ARTE SOBRE LA SOMNOLENCIA Y SUS SISTEMAS DE DETECCIÓN

Según el boletín epidemiológico cuatrimestral expedido en diciembre de 2007 por el Instituto Nacional de Medicina Legal y Ciencias Forenses de Colombia, existen estudios en diferentes países que han documentado que los accidentes de tránsito tienden a ser más frecuentes entre la media noche, el amanecer y al promediar la tarde, coincidiendo curiosamente con los picos de tendencia al sueño normal de la población general (de Servicios Forenses División de Referencia de Información Pericial, 2007).

El impacto del adormecimiento en los accidentes automovilísticos, laborales, domésticos y catástrofes públicas es desconocido en términos precisos, aunque se estima que puede estar implicado en el 36% del total de los accidentes de tráfico fatales, y que este estado es debido principalmente a los malos hábitos a la hora de dormir o a la sobrecarga física por exceso en las horas de conducción.

Una vigilia permanente por más de 17 horas en ocasiones es similar a haber consumido una cantidad de alcohol similar al límite máximo permitido para conducir. Por ende, la hipersomnía disminuye la productividad laboral y el funcionamiento social en las personas afectadas. En Colombia se desconocen los efectos de la hipersomnía sobre la salud de los trabajadores, siendo más vulnerables los trabajadores por turnos como personal de salud, vigilantes nocturnos, pilotos, militares, conductores, entre otros (Espectador, 2009).

Conociendo estas cifras, resulta totalmente acertado establecer que este tema de estudio tiene un impacto alto y alcanza a toda la población en general, ya que no solo los responsables pueden verse afectados en las calamidades, sino cualquiera que se encuentre en el rededor o en el lugar equivocado, llevando a la necesidad de detectar la somnolencia como método de prevención de finales fatales.

Es por esto que, desde inicios del siglo XXI, se han venido desarrollando métodos de ayuda a la conducción, entre los que se puede mencionar el desarrollo de sistemas específicos de valoración del nivel de alerta y de detección de somnolencia en conductores, esto como parte del despliegue de nuevas tecnologías para la incorporación en vehículos que busca resolver los inconvenientes relacionados al tráfico vial (Garcés Correa, Procesamiento de Señales cerebrales para la Detección de Somnolencia en Conductores., 2011).

Durante la conducción, la somnolencia ha podido ser detectada mediante diversas técnicas, siendo las más conocidas: la detección a través de los apartados mecánicos del vehículo relacionados con el mal desempeño del conductor, la detección por métodos de visión por computador (expresiones faciales, movimientos corporales y oculares) y la detección por el análisis de señales fisiológicas.

3.2.1. Detección a través de los apartados mecánicos del vehículo relacionados con el mal desempeño del conductor

Varios trabajos estudiados se basaron en el comportamiento físico del conductor, de esta manera, el análisis se basa en aspectos como el tono facial, los movimientos de la cabeza, el frotarse los ojos, bostezar; y en mayor cuantía, se popularizó la técnica de registrar el movimiento de los ojos con cámaras, usando parámetros tales como el diámetro de la pupila, la mirada fija y el parpadeo y su frecuencia.

3.2.2. Detección por métodos de visión por computador

Hong (2007) propuso un sistema en tiempo real en el que analizó los cambios en el rostro y en los ojos. Generalmente se usan cámaras de video para tomar los datos, si bien este método es más cómodo para las personas, los parámetros que se analizan varían mucho en los diferentes tipos de vehículos y condiciones de manejo.

3.2.3. Detección por el análisis de señales fisiológicas

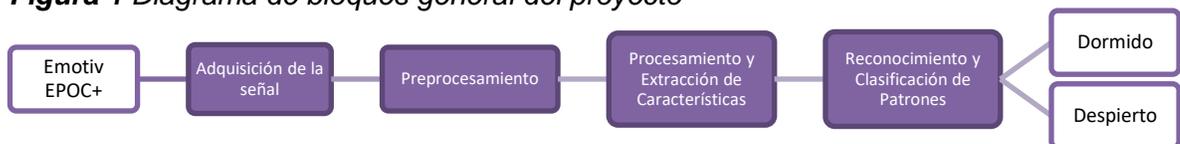
De igual manera, señales fisiológicas tales como el electroencefalograma (EEG), electrocardiograma (ECG) y electrooculograma (EOG), han sido utilizadas de manera individual o en conjunto para la cuantificación de la somnolencia.

Garcés (2011), otro trabajo en el área relacionada, buscó detectar mediante técnicas de procesamiento de señales cerebrales, la transición de la vigilia a la primera etapa del sueño, para entregar una señal de alerta anticipándose a los primeros síntomas de la somnolencia, devolviendo la atención del sujeto a la conducción del vehículo.

3.3. Diagrama de bloques general propuesto

El diagrama de bloques presentado a continuación, permite una vista general de los pasos y el orden lógico que seguirá el presente proyecto para su desarrollo.

Figura 1 Diagrama de bloques general del proyecto



4. ELECTROENCEFALOGRAFÍA Y SOMNOLENCIA

4.1. INTRODUCCIÓN AL CAPÍTULO

En este capítulo se introducirán algunos conocimientos sobre la fisiología del encéfalo humano, explicando cómo sus componentes logran generar las corrientes dentro del cerebro, que posteriormente serán captadas durante la electroencefalografía. De igual manera, se presentarán los principales ritmos cerebrales, además de otros que tienen relevancia para este estudio, describiendo sus características y su recurrente contaminación debida a artefactos. Esta información será de gran ayuda en los procesos de detección y clasificación del estado del individuo, siendo estos somnolencia o vigilia.

4.2. ACTIVIDAD ELÉCTRICA CEREBRAL

El cerebro es el órgano principal del sistema nervioso central, contiene neuronas en grandes cantidades y se encuentra en el encéfalo de animales vertebrados y en menor medida en invertebrados. Representa entre el 0.8% y el 2% del peso corporal humano y su consumo de energía en relación al resto del cuerpo es de aproximadamente el 20%, siendo estable independientemente de la actividad corporal.

4.2.1. Conducción nerviosa

El cerebro está compuesto de dos clases de células: las neuronas y las células gliales, siendo éstas últimas mayor en cantidad en un factor de diez comparada con las neuronas; además, sus diversas clases, realizan funciones de sostén estructural, metabólico y de modulación del desarrollo (Kandel, Schwartz, Jessell, Siegelbaum, & Hudspeth, 2000).

Las neuronas son las unidades funcionales del sistema nervioso, éstas cumplen el papel de unidades fundamentales, estructurales y funcionales del cerebro. Se estima que en el interior de la corteza cerebral hay entre 15.000 y 30.000 millones de neuronas y cada una de ellas se encuentra interconectada hasta con 10.000 conexiones sinápticas, teniendo como especialidad la comunicación entre células mediante la generación, transmisión y recepción de señales (Portellano, 2005).

Las neuronas, como todas las células, están formadas por la membrana, el citoplasma (encargado de los procesos de respiración y nutrición) y el núcleo (que contiene la información genética ADN), contando además con prolongaciones que salen del cuerpo de la célula formando las dendritas y el axón.

La transmisión de la información y sensaciones dentro del cerebro se produce mediante la actividad de sustancias capaces de provocar la transmisión de impulsos nerviosos, éstas son denominadas neurotransmisores. Estos, a su vez, se reciben en las dendritas y se emiten en los axones, donde las primeras, son ramificaciones que se conectan con otras células, y los segundos, una larga prolongación del cuerpo de la célula que termina en unas ramificaciones a través de las cuales la neurona se puede comunicar mediante señales eléctricas con otras células (Portellano, 2005).

4.2.2. Señales y potenciales bioeléctricos

Las señales bioeléctricas, son potenciales iónicos producidos por la actividad electroquímica de cierto tipo de células “excitables”, que están presentes en el sistema cardiaco, nervioso, muscular, entre otros; dependiendo del origen de estas, se encuentran asociadas a la actividad cerebral (señal EEG), la actividad cardíaca (señal ECG), la actividad muscular (señal EMG) y otras.

Los potenciales de acción, que se pueden generar de manera intracelular como extracelular, presentan una amplitud y duración fijas, dependiendo del tipo de célula que lo produzca, independiente del método, duración e intensidad del estímulo.

De este modo, las células de estos sistemas, a partir de los potenciales de acción, generan sus propias señales de monitorización, las llamadas Señales Bioeléctricas, que permiten la obtención de información acerca de su funcionamiento (Pereyra, 2011).

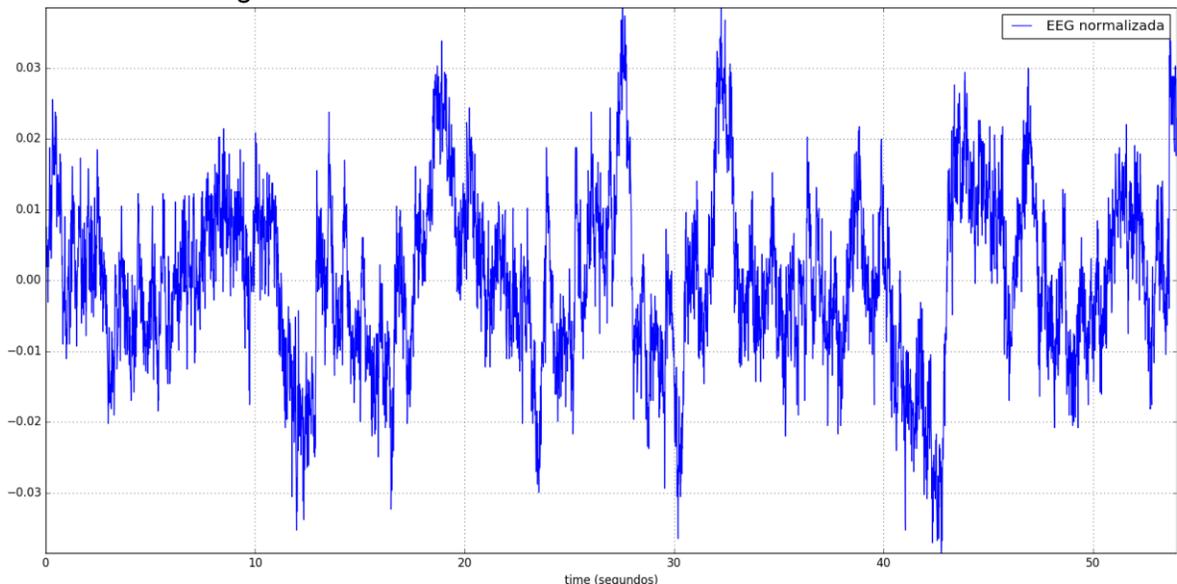
Los potenciales bioeléctricos del cuerpo humano o de cualquier animal raramente son determinísticos. Sus magnitudes varían con el tiempo, incluso cuando todos los factores que las originan están controlados. Los valores de la misma medida pueden variar enormemente entre diferentes individuos, aunque estos estén sanos y las condiciones de medición sean las mismas. Esto quiere decir que los valores pueden ser muy diferentes para diferentes personas, aunque sean valores normales en ellos

(Navarro, Tema 3: Sistemas de Acondicionamiento y Adquisición de Señales Bioeléctricas, 2010).

4.3. ELECTROENCEFALOGRAMA

La Electroencefalografía es la captación y evaluación de la actividad bioeléctrica cerebral originada por las neuronas del encéfalo en condiciones basales de reposo, en vigilia o sueño, y durante diversas activaciones. Esta puede realizarse de manera aislada o asociada al registro video gráfico simultáneo y sincronizado del paciente (Diaz, 2012).

Figura 2 Señal EEG canal F3 sin ningún tipo de tratamiento tomada el 16-08-2016 con duración de 60 segundos



El electroencefalograma (EEG) es el registro por medio de electrodos de superficie de los potenciales eléctricos cerebrales. Dicho registro posee formas muy complejas que varían mucho con la localización de los electrodos y entre individuos, esto es debido al gran número de interconexiones que presentan las neuronas y por la estructura no uniforme del encéfalo (Navarro, Tema 5: Electroencefalografía, 2011).

4.3.1. Características de la señal EEG

4.3.1.1. Frecuencia y amplitud

Las frecuencias de estas ondas se mueven entre 0,5 y 100 Hz y dependen mucho del grado de actividad del córtex cerebral. A su vez, este gran rango de frecuencias, se divide en 5 bandas llamadas “ritmos cerebrales”, de los que se brinda mayor detalle más adelante. La amplitud de los registros puede variar dependiendo de la ubicación de los electrodos, si están ubicados en la superficie (cuero cabelludo) esta puede ser de 100 μ V y si se encuentra en la corteza cerebral, puede alcanzar los 10mV.

4.3.1.2. No linealidad

El cerebro, como unidad central, recibe estímulos de todas partes del cuerpo, por lo que es común que al captar señales EEG, no solo se registren esta clase de ondas, sino, señales de cualquier naturaleza y/o fuente generadora. Por lo que, resulta acertado tratar a la señal EEG como la salida de un sistema no lineal determinístico, el cual puede verse afectado por fenómenos de tipo psicológico y biológico (Sanei & Chambers, 2013).

4.3.1.3. No estacionalidad

Las señales cuyo contenido de frecuencia no cambia en el tiempo se denominan señales estacionarias, y se caracterizan por poseer todos los componentes de frecuencia en todo instante de tiempo.

Como se va a ver más adelante, las señales electroencefalográficas poseen diferentes componentes frecuenciales durante una única muestra tomada, ya sea en estado de vigilia y/o somnolencia, pero es posible considerarlas estacionarias, si se analizan en intervalos cortos (Sanei & Chambers, 2013).

4.3.1.4. Segmentación temporal

En las aplicaciones más comunes, la señal EEG debe ser dividida en segmentos, los cuales, a su vez, son etiquetados y agrupados con otros que presenten

características similares, y, de esta manera, asegurar que estos sean estadísticamente estacionarios.

Esto certifica que, dentro de estos segmentos, la señal será similar en sus propiedades temporales y frecuenciales, y que sea posible su uso posterior en métodos que necesitan que la señal cumpla esta condición para su aplicación (Sanei & Chambers, 2013).

4.3.1.5. Artefactos

Cualquier interferencia no deseada que pueda afectar la señal biológica estudiada, es considerada un artefacto y estos se pueden clasificar según la fuente que los genera en fisiológicos y externos. Los primeros tienen como fuente principal el cuerpo de los propios sujetos, mientras que los segundos vienen de fuera del cuerpo, como el ambiente u otros instrumentos de medida, por ejemplo (Tandle & Jog, 2015).

El reconocimiento, identificación y supresión de los artefactos es un proceso importante para minimizar la posibilidad de analizar la señal de manera errada, no solo en el ámbito clínico, sino, en Interfaces Cerebro - Computador (BCI, de sus siglas en inglés Brain Computer Interface), sistemas de control inteligente, entre otros.

4.3.2. Emotiv EPOC+

Figura 3 Dispositivo Físico Emotiv EPOC+



Fuente: <https://www.emotiv.com/>

El EPOC+ es la segunda versión del popular EPOC diseñado y distribuido por la compañía Emotiv Systems. Es un equipo que permite realizar BCI y que se utiliza en diferentes aplicaciones de esta área. No es considerado un equipo médico, pero si permite captar EEG. Como se puede observar en la Tabla 1, cuenta con un importante número de canales, lo cual lo ha convertido en el equipo predilecto para realizar aplicaciones que tengan que ver con detección de expresiones faciales o parpadeo (EMOTIV, EMOTIV EPOC & TESTBENCH™ SPECIFICATIONS, 2014).

La ventaja de trabajar con este dispositivo es que funciona de manera inalámbrica, transmitiendo información de manera constante vía Bluetooth y de manera codificada para no ser alterada o intervenida. Consta además de un set de baterías de litio para suministrar una fuente de alimentación de 5V, logrando una independencia de la red eléctrica de 8 horas aproximadamente, el tiempo de carga es de 4 horas con un cargador de 700mA (EMOTIV, EMOTIV EPOC+ 14 Channel Mobile EEG, 2016).

Tabla 1 Especificaciones técnicas del equipo Emotiv Epoc+

Característica	Descripción
Número de canales	14 (adicional las referencias CMS/DRL, ubicadas en las posiciones P3/P4)
Nombres de los canales	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Método de muestreo	Muestreo secuencial con un único ADC
Tasa de muestreo	128 SPS (2048 Hz internamente)
Resolución	14 bits 1 LSB = 0.51µV (ADC de 16 bits, 2 bits dedicados a la remoción del ruido instrumental)
Ancho de banda	0.2 – 45 Hz, filtros digitales Notch a 50 y 60 Hz
Filtrado	Filtro pasabajos ideal digital de 5to orden incorporado
Conectividad	Banda inalámbrica propia 2.4 GHz

Fuente: <https://www.emotiv.com/>

Donde los términos:

ADC corresponde a un Conversor Análogo-Digital, de sus siglas en inglés Analog-Digital Converter. SPS corresponde a Muestras por Segundo, de sus siglas en inglés Samples Per Second. En el ítem de filtrado se habla de un filtro pasabajos

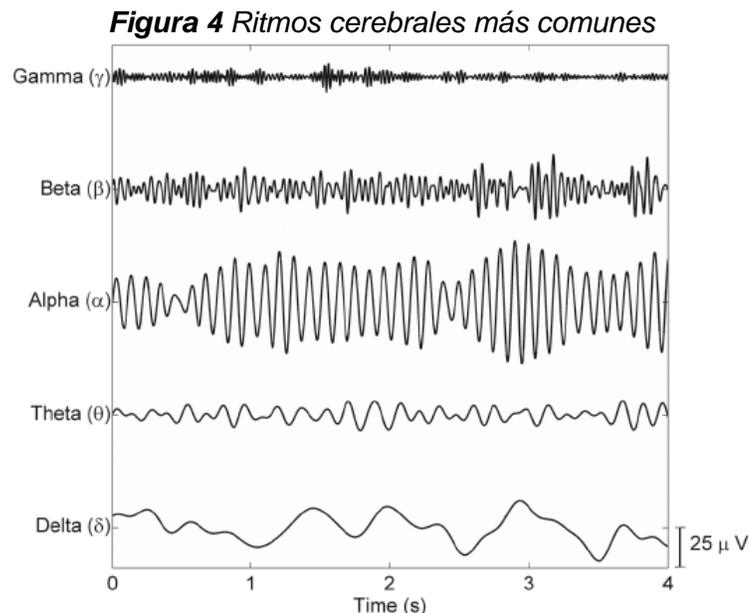
ideal (el término para referirse en inglés es Sinc Filter), la respuesta impulsional es una función Sinc en el dominio del tiempo, y su respuesta frecuencial es una función rectangular.

La razón principal para elegir este dispositivo como el equipo para adquisición de señales EEG, fue su fácil proceso de importación, soporte y grado de confianza, pues lleva 8 años en el mercado de dispositivos con BCI. Adicionalmente, y como queda demostrado en los resultados del proyecto, se logró diseñar un sistema compatible con un equipo de EEG de bajo costo, lo que garantiza su portabilidad y avala aplicaciones en distintos campos de estudio.

4.4. RITMOS CEREBRALES

Los ritmos cerebrales hacen alusión a la actividad eléctrica que produce el cerebro, y esta se subdivide en bandas Delta “ δ ” (desde 0,5 Hz hasta 4 Hz), Theta “ θ ” (desde 4 Hz hasta 8 Hz), Alpha “ α ” (desde 8 Hz hasta 14 Hz), Beta “ β ” (desde 14 hasta 30 Hz) y Gamma “ γ ” (frecuencias superiores a 30 Hz).

En la **Figura 4** es posible observar la morfología de las bandas mencionadas anteriormente, y, por ende, las que serán tenidas en cuenta en el presente estudio.



Fuente: <https://www.computer.org/csdl/mags/co/2012/07/mco2012070087-abs.html>

4.4.1. Ondas Delta

Las ondas Delta “ δ ” poseen frecuencias inferiores a 4 Hz, pero sin llegar a 0 Hz, pues eso significaría la muerte cerebral. Se presentan durante el sueño profundo, en la infancia y en enfermedades orgánicas cerebrales graves (Alipoor, Pooyan, & Suratgar, 2010).

4.4.2. Ondas Theta

Las ondas Theta “ θ ” poseen frecuencias entre 4 y 8 Hz y tienen morfología sinusoidal y voltaje cercano a 50 μ V. Se emiten cuando se está en la fase REM (de sus siglas en inglés Rapid Eye Movement) del sueño, aunque también ocurren cuando se está meditando, fantaseando o bajo hipnosis. Si aparece en adultos despiertos, es indicio de lesión, tensión o frustración. Se localizan en las zonas parietal y temporal (Li, Yan, Karmakar, & Liu, 2015).

4.4.3. Ondas Alpha

Las ondas Alpha “ α ” poseen frecuencias entre 8 y 14 Hz y su amplitud está comprendida entre 20 y 200 μ V. Se registran en sujetos normales despiertos, sin ninguna actividad y con los ojos cerrados, localizándose sobre todo en la zona occipital. Esta actividad desaparece totalmente en el momento que la persona entra en estado de somnolencia y se halla totalmente ausente durante el sueño profundo. Esto indica que la presencia de la actividad Alpha es un indicio de que la persona se encuentra en estado de vigilia y en estado de relajación mental (Garcés, Orosco, & Laciari, 2014).

4.4.4. Ondas Beta

Las ondas Beta “ β ” poseen frecuencias entre 14 y 30 Hz, se registran fundamentalmente en las regiones parietal y frontal. En el extremo más bajo, corresponden a estados de acción, trabajo y concentración. Según va subiendo el ritmo, corresponden a estados de excitación e intensa actividad mental.

4.4.5. Ondas Gamma

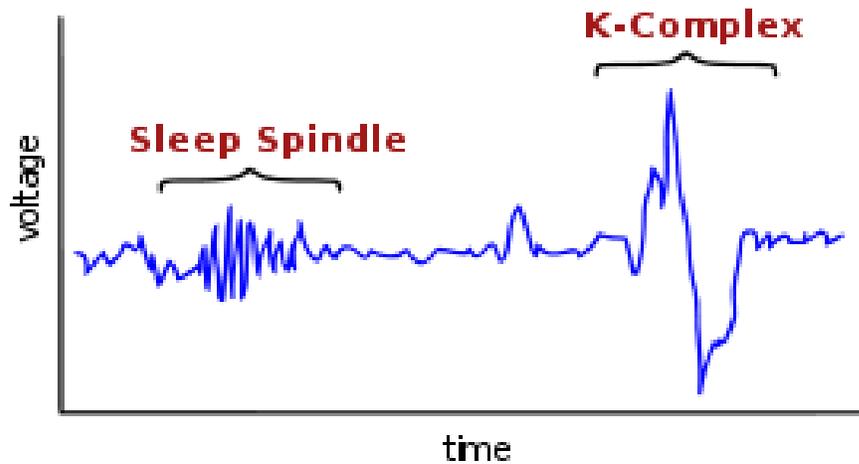
Las ondas Gamma “ γ ” poseen frecuencias superiores a los 30 Hz. Corresponden a estados de ansiedad y pánico. Los neurotransmisores están alertados. En este estado es imposible relajarse o dormir (Sinha, y otros, 2015).

4.4.6. Otros complejos de ondas

4.4.6.1. Ondas agudas del vértex

Son ondas electronegativas, aisladas, con mayor expresión en la región del vértice cerebral, generalmente asociado a un estímulo sonoro. Se registran en forma simétrica en ambos hemisferios (Gil-Nagel A, 2002).

Figura 5 Huso del sueño (Sleep Spindle) y Complejo K (K-Complex).



Fuente: https://en.wikipedia.org/wiki/Sleep_spindle

4.4.6.2. Husos del sueño

Son ondas sinusoidales de 12 – 14 Hz de frecuencia y aproximadamente 50 μ V de amplitud con mayor incidencia en regiones centrales, apareciendo de forma breve e intermitente. Suelen ser registradas con incidencias de cinco por minuto (de Neurología, 2011).

4.4.6.3. Complejos K

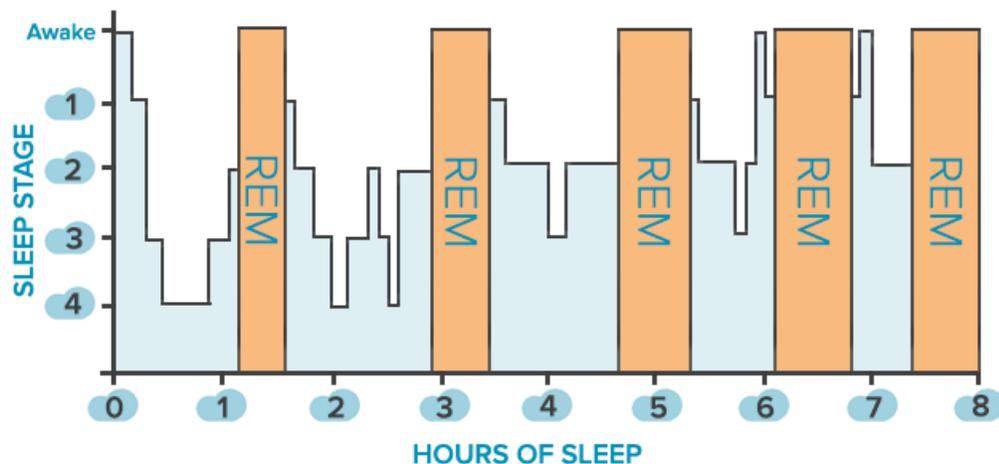
Resulta de la combinación de una onda aguda del vértex con un huso del sueño. Son ondas lentas que presentan una primera fase negativa de gran amplitud seguida por una fase positiva más lenta y de menor amplitud. Pueden ser detectados con una frecuencia de tres o cuatro por minuto (de Neurología, 2011).

4.5. FASES DEL SUEÑO

El sueño es un estado fisiológico necesario para la vida, que se caracteriza por la interrupción temporal del movimiento, la capacidad sensorial y el estado de alerta. Durante el sueño se producen cambios en las funciones del organismo y se desarrolla una actividad mental imprescindible para mantener el equilibrio físico y psíquico de las personas.

Se distinguen dos etapas en el período de sueño, denominadas fase de sueño lento o NO REM, y fase de sueño rápido o REM (siglas que corresponden a su nombre en inglés: Rapid Eye Movement o movimiento ocular rápido). El sueño NO REM, se divide, a su vez, en cuatro fases con características distintas. A continuación, se describen las cinco fases, que se alternan de forma cíclica mientras la persona permanece dormida (cada 90/100 minutos, aproximadamente, comienza un nuevo ciclo de sueño en el que los últimos 20 o 30 minutos se corresponden con la fase REM) (Targa & Vila, 2007).

Figura 6 Fases del sueño (eje y) vs Horas de sueño (eje x) saludable



Fuente: <http://www.centerforsoundsleep.com/sleep-disorders/stages-of-sleep/>

4.5.1. Fase I

Es la fase de sueño ligero, en la que las personas todavía son capaces de percibir la mayoría de los estímulos (auditivos y táctiles). El sueño en fase I es poco o nada reparador. En esta fase se presentan las ondas agudas del vértex y el tono muscular disminuye en comparación con el estado de vigilia, dando paso a movimientos oculares lentos. A esta etapa del sueño se la conoce como somnolencia.

4.5.2. Fase II

En esta fase el sistema nervioso bloquea las vías de acceso de la información sensorial, lo que origina una desconexión del entorno y facilita, por tanto, la actividad de dormir. El sueño de fase II es parcialmente reparador, por lo que no es suficiente para que el descanso sea considerado completo. Esta fase ocupa alrededor del 50% del tiempo de sueño en el adulto y aparecen dos complejos de ondas anteriormente mencionados: los husos de sueño y los complejo-k. El tono muscular es menor que en fase I, y desaparecen los movimientos oculares.

4.5.3. Fase III

Es un sueño más profundo (denominado DELTA), donde el bloqueo sensorial se intensifica. Si el individuo despierta durante esta fase, se siente confuso y desorientado. En esta fase no se sueña, se produce una disminución del 10 al 30 por ciento en la tensión arterial y en el ritmo respiratorio, y se incrementa la producción de la hormona del crecimiento. El tono muscular es aún más reducido que en fase II, y tampoco hay movimientos oculares.

4.5.4. Fase IV

Es la fase de mayor profundidad del sueño, en la que la actividad cerebral es más lenta (predominio de actividad Delta). Al igual que la fase III, es esencial para la recuperación física y, especialmente, psíquica, del organismo (déficits de fase III y IV causan somnolencia diurna). En esta fase, el tono muscular está muy reducido. No es la fase típica de los sueños, pero en ocasiones pueden aparecer, en forma de imágenes, luces o figuras sin una línea argumental. Es importante señalar que en esta fase es en la que se manifiestan alteraciones como el sonambulismo o los terrores nocturnos.

4.5.5. Fase REM

Se denomina también sueño paradójico (a propuesta de Jouvet, un importante investigador del sueño), debido al contraste que supone la atonía muscular (relajación total) típica del sueño profundo, y la activación del sistema nervioso central (signo de vigilia y estado de alerta). En esta fase se presentan los sueños, en forma de narración, con un hilo argumental, aunque sea absurdo. La actividad eléctrica cerebral de esta fase es rápida. El tono muscular nulo (atonía muscular o parálisis), impide que la persona dormida materialice sus alucinaciones oníricas y pueda hacerse daño. Las alteraciones más típicas de esta fase son las pesadillas, el sueño REM sin atonía y la parálisis del sueño.

5. PREPROCESAMIENTO DE LA SEÑAL EEG

5.1. INTRODUCCIÓN AL CAPÍTULO

Una señal es un medio de transmisión de información, y, para obtener información sobre la fuente de la señal, o ya sea, para modificarla, suele ser necesario aplicar algún tipo de operación (Guerrero Martínez, 2010).

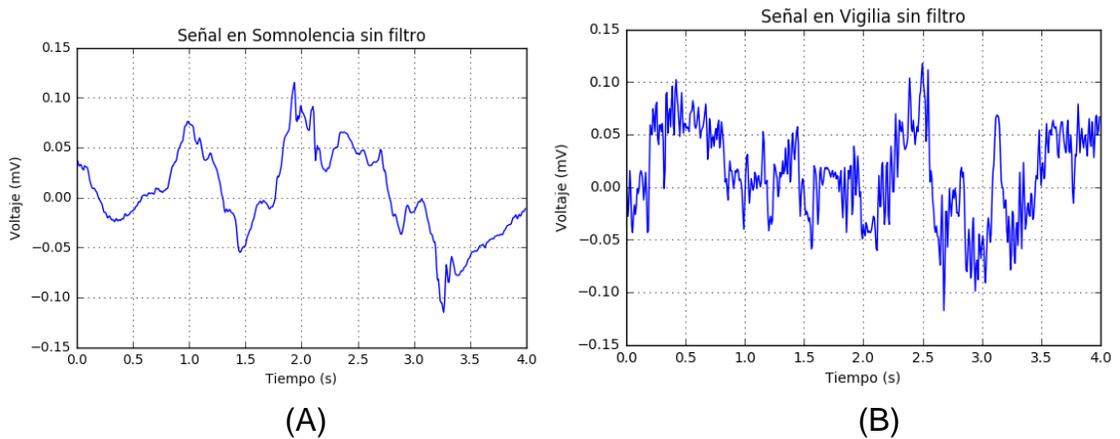
En esta etapa, se busca extraer la información, que resulta relevante para el proyecto, del resto de la señal EEG, la cual usualmente tiene ruido aditivo o multiplicativo asociado, por lo que se hace necesario suprimir artefactos tales como EOG, EMG y ECG. Siendo aplicadas técnicas de atenuación y cancelación de ruido, como lo es el filtrado IIR Butterworth y la transformada discreta de Wavelet, para lo cual, se necesita un conocimiento previo de las características de la señal y de los artefactos.

5.2. ADQUISICIÓN DE LA SEÑAL EEG

Se inicia con la adquisición de la señal a partir de un SDK con licencia GNU, desarrollado en este proyecto a partir de un script de captura de datos para la versión 1.0 del dispositivo Emotiv Epoc+. El script permite captar las señales gracias al equipo sin necesidad de su SDK comercial. Las muestras fueron tomadas en un periodo establecido de 300 segundos (5 minutos) a una tasa de muestreo de 128 SPS (de sus siglas en inglés Samples Per Second) y en cada sesión fue posible captar entre 12 y 18 muestras.

Todos y cada uno de estos ejemplares fueron almacenados en archivos CSV en forma de matriz, las columnas corresponden a los canales F3, FC5, AF3, F7, T7, P7, O1, O2, P8, T8, F8, AF4, FC6 y F4, en ese orden, y las filas conciernen a la información obtenida durante el muestreo. De manera paralela se llevaron registros filmicos de las sesiones de captura, ya que estos servirán de apoyo para realizar y corregir las notas sobre la muestra, en donde se determinará en que periodos se entró al estado de somnolencia.

Figura 7 Señales EEG en crudo del canal F3 (A) Señal de muestra en Somnolencia (B) Señal de muestra en Vigilia

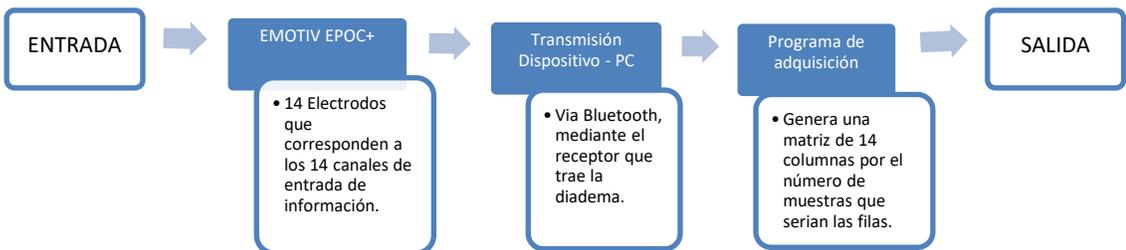


Cabe resaltar que la metodología aquí propuesta es de carácter intrapersonal, lo que quiere decir que las muestras fueron tomadas a un único individuo. Las sesiones de captura de datos se realizaron bajo condiciones ideales para estudio de polisomnografía, o inducción de sueño a la persona, con actividades repetitivas y monótonas, esto con el objetivo de causar cansancio mental. Los datos que se utilizaron para entrenamiento, validación y testeo.

El equipo Emotiv EPOC+ no exige condiciones muy ideales para ser usado en el proceso de adquisición de señales, sin embargo, se garantizaba que el cuero cabelludo estuviera limpio y sin sudor para evitar interferencias adicionales.

A continuación, se presenta un diagrama de bloques que muestra de manera concisa el procedimiento que se siguió.

Figura 8 Subproceso de adquisición de muestras



5.3. NORMALIZACIÓN DE LA SEÑAL

Todas las dimensiones de la señal deben estar en la misma escala, ya que de esta manera resulta más sencillo tomar decisiones a la hora de clasificar los tramos de señal EEG. Una aproximación simple es computar la media y la desviación estándar de los valores en cada dimensión, y normalizarlos según sus valores.

5.4. VENTANEO DE LA SEÑAL

En la bibliografía consultada se establecían ventanas de muestreo de 1 o 2 segundos con el objetivo de analizar la señal EEG como estacionaria en pequeños instantes, pero considerando que la mayoría de estas investigaciones se realizaron con equipo EEG de alta resolución y altos periodos de muestreo, se optó por experimentar con distintos tiempos de ventana, para escoger finalmente 4 segundos como duración de ventana mínima.

Además, al ventaneo se le aplica un solapamiento del 50% para garantizar que no se perderá información alguna de la señal, permitiendo realizar la distinción entre un estado y otro. Por ende, la cantidad de ventanas suficiente por muestra está dado por la **Ecuación 1**:

$$Ventanas = \left(\frac{T_{muestra}}{2 * T_{ventana}} \right)$$

***Ecuación 1** Cálculo del número de ventanas*

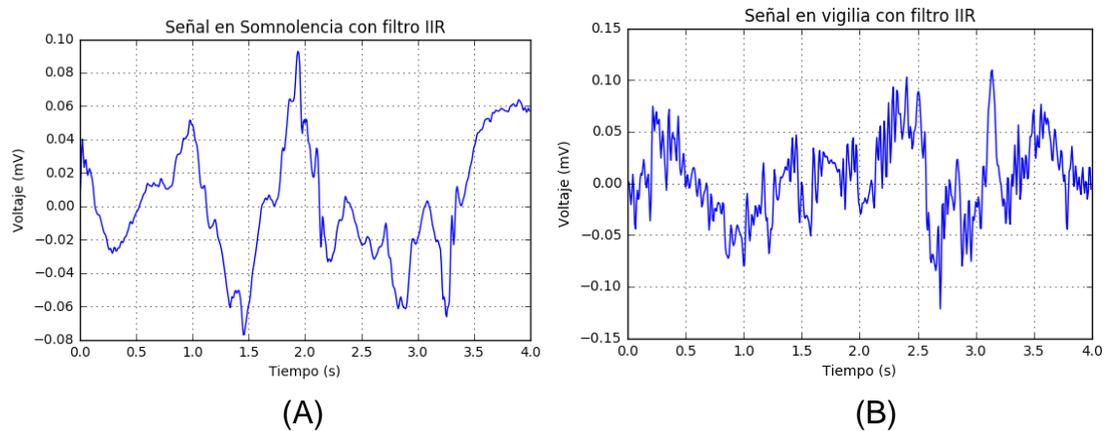
5.5. FILTRADO Y ACOTACIÓN DE LA SEÑAL

Los filtros de respuesta impulsional infinita (IIR, por sus siglas en inglés Infinite Impulse Response) son tipos de filtros digitales, que como sus siglas indican, si su entrada es una señal impulso, la salida tendrá un número infinito de términos diferentes a cero, lo que quiere decir que nunca vuelve al reposo. Este tipo de filtros presenta polos y ceros que determinan la estabilidad y la causalidad del sistema (Martínez, Gómez, Serrano, Vila, & Gómez, 2009).

Las propiedades de estos son muy similares a la de los filtros FIR (del inglés Finite Impulse Response), pero tienen una gran ventaja respecto a estos, y es que pueden cumplir sus mismas exigencias, con un orden de filtro menor; lo cual conlleva a un menor gasto computacional, que como siempre, resulta en un sistema más fluido.

Los filtros Butterworth hacen parte de los filtros electrónicos básicos. Estos se obtienen al imponer que la respuesta en magnitud del filtro sea la más plana posible (con mínimas ondulaciones) en la banda de paso hasta la frecuencia de corte y efectúa su aproximación mediante el criterio de máxima uniformidad en la banda de paso (www.ehu.eus, 2016).

Figura 9 Señales EEG del canal F3 posterior al filtro IIR butterworth (A) Señal de muestra en Somnolencia (B) Señal de muestra en Vigilia



El orden y la pendiente tienen una relación lineal, ya que a medida que aumenta el orden del filtro, su pendiente de atenuación se incrementa, lo cual no conlleva a que este tipo de filtro pierda su forma, por el contrario, es el único filtro que la mantiene, sin importar como su orden varíe.

Conociendo las características de los filtros idóneos para el presente caso, y teniendo presente que la calidad de la señal EEG medida es usualmente evaluada por qué tan alta es su relación señal a ruido (SNR, de sus siglas en inglés Signal Noise Ratio); el objetivo es maximizar la amplitud de la señal mientras se minimiza el ruido, eligiendo aplicar un filtro IIR Butterworth pasabanda entre 0.2 Hz y 35 Hz de orden 5. El orden se escogió por medio de pruebas realizadas, de manera empírica, sobre un banco de 30 muestras realizadas a un único sujeto variando únicamente este parámetro en el rango de 1 a 10, resultando ser 5 el valor que ofrecía el mejor balance entre limpieza de la señal sin distorsión.

5.6. Transformada Discreta de Wavelet

La Transformada de Wavelet recientemente se ha vuelto muy popular cuando se trata de análisis, supresión del ruido (de-noising) y la compresión de señales e

imágenes; esta consiste en una función matemática que permite obtener datos de una señal dividiéndolos en componentes frecuencia – tiempo más pequeño para facilitar su análisis de manera separada (Cano, Salcedo, & Soto, 2010).

Se eligió la Transformada de Wavelet sobre la de Fourier, debido a que las señales EEG, como muchas señales biológicas, presentan características no estacionarias y transitorias, ya que es común que contengan cambios abruptos y eventos inesperados, siendo estos de vital importancia para el correcto análisis de la señal, por ende, la Transformada de Fourier no es adecuado para detectarlos.

Comparada con la transformada de Fourier, la Transformada de Wavelet permite trabajar sobre ondas no estacionarias, con discontinuidades o picos y se distingue por su capacidad de multirresolución.

A pesar de que el filtro implementado en el apartado anterior logró atenuar en gran medida algunos artefactos que contaminan las muestras EEG, es necesario aplicar un método que pueda actuar sobre los artefactos más incidentes en la misma, es decir, que estén presentes en las bandas de frecuencia donde el EEG tiene mayor recurrencia; para esta tarea se escogió la transformada de Wavelet, para ser más exactos, la transformada discreta de Wavelet multinivel.

La Transformada Discreta de Wavelet (DWT, de sus siglas en inglés Discrete Wavelet Transform) permite realizar un análisis multinivel por diferentes ventanas de frecuencia, gracias a las cuales, se puede hallar el nivel de umbralización (en este caso umbralización suave) que se aplicará a las señales para liberarlas de impurezas y obtener contenido EEG más claro.

5.6.1. Niveles y coeficientes

Se utilizó la siguiente formula que permite calcular el máximo nivel útil de descomposición para la longitud de datos de entrada dados y la longitud del filtro de wavelet (www.pybytes.com, Discrete Wavelet Transform (DWT), 2012).

$$Max_{level} = \log_{10} \left(\frac{data_{length}}{filter_{length} - 1} \right) * \frac{1}{\log_{10}(2)}$$

Ecuación 2 *Calculo de máximo niveles de descomposición de DWT*

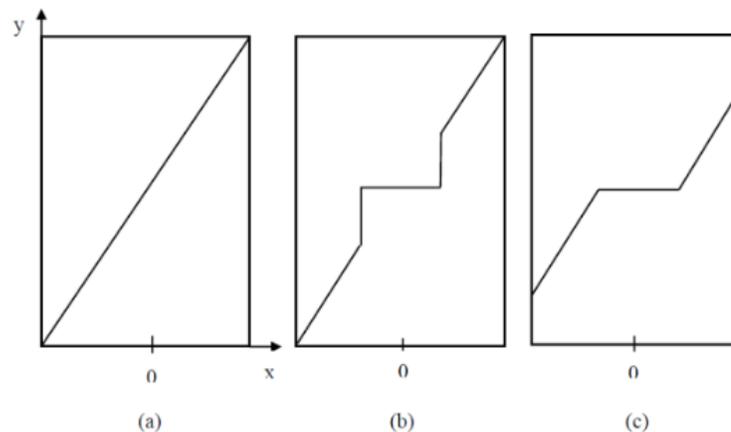
5.6.2. Umbralización

Con la descomposición en diferentes niveles de frecuencia, se prosigue a aplicar la umbralización, esto para acabar de atenuar valores de frecuencia parásita que puedan afectar de alguna manera la señal EEG (Rodríguez & Bueno, 2010).

Existen dos métodos populares de umbralización, conocidos como umbralización fuerte y umbralización suave. La primera puede ser descrita como el proceso constante de establecer cero los elementos cuyos valores absolutos están por debajo del umbral. La umbralización suave es una extensión de su hermana, primero cumpliendo con su mismo proceder, para luego ir reduciendo los coeficientes distintos de cero y dirigirlos hacia cero.

Se eligió el proceso de umbralización suave y su ajuste se llevó a cabo de manera manual, haciendo un barrido entre 0.001 y 0.020, siendo 0.005 el valor que garantizaba una reconstrucción adecuada de la señal y la eliminación de los artefactos, sin provocar pérdidas sensibles en la información del EEG.

Figura 10 (a) Señal sin umbralizar (b) señal con umbralización fuerte (c) señal con umbralización suave



Fuente: <https://www.mathworks.com/help/wavelet/ref/wthresh.html>

5.6.3. Coeficientes de aproximación y de detalle

Los coeficientes de aproximación y detalle obtenidos con los parámetros escogidos como hacer uso de una Wavelet Madre tipo Symlet de orden 4, con una ventana de 512 muestras de duración de 4 segundos y periodo de muestreo de 128 Hz fueron:

Tabla 2 Segmentos frecuenciales de coeficientes de aproximación

Coeficientes	Segmentos
D1	64 Hz – 32 Hz
D2	32 Hz – 16 Hz
D3	16 Hz – 8 Hz
D4	8 Hz – 4 Hz
D5	4 Hz – 2 Hz
D6	2 Hz – 1 Hz

Tabla 3 Segmentos frecuenciales de coeficientes de detalle

Coeficientes	Segmentos
A6	64 Hz – 32 Hz

Cada ventana, por ensayo y error, se logró sintonizar a una umbralización suave de 0.005, eliminando los valores bajo este límite se lograba eliminar el ruido que ofrecía mayor afectación a la señal EEG.

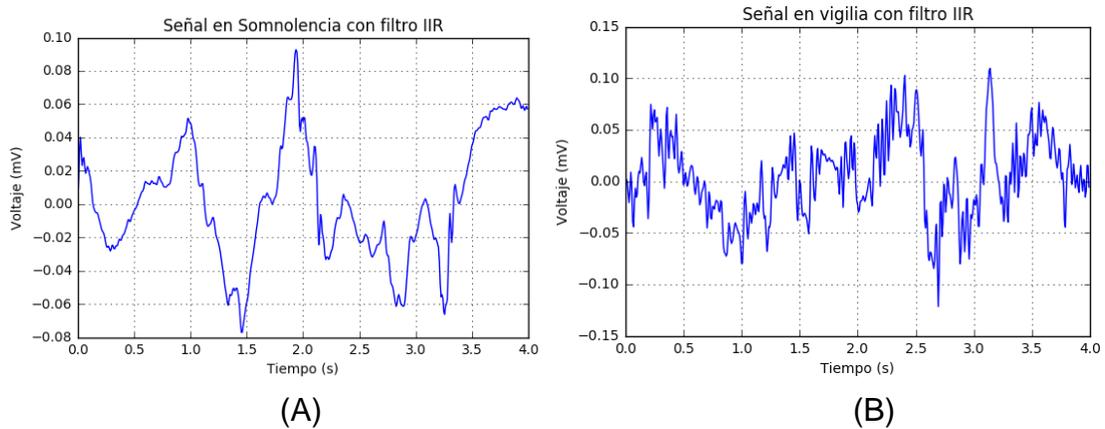
Se demostró entonces la eficiencia de la combinación de estas dos técnicas de preprocesamiento para aplicaciones de detección de somnolencia.

5.6.4. Transformada Inversa Discreta de Wavelet

Después de aplicados los procesos de umbralización suave sobre los coeficientes de detalle y de aproximación, se procede a reconstruir la señal para su procesamiento.

La señal que se encuentra descompuesta en diferentes ventanas debe ser reconstruida a partir de un banco de filtros inverso al que se usó para su descomposición en multinivel, es por esto que es de vital importancia que la wavelet madre de descomposición y reconstrucción sea la misma, en este caso Symlet 4 (Malo & de Castro Fernandez, 2002).

Figura 11 Señales EEG del canal F3 posterior al proceso de DWT – IDWT (A) Señal de muestra en Somnolencia (B) Señal de muestra en Vigilia



La biblioteca PyWavelet de Python provee las herramientas necesarias para realizar la descomposición y reconstrucción de la señal. Hay que tener especial cuidado a la hora de configurar la reconstrucción, pues es de suma importancia que el primer parámetro a especificar sea la ventana que contiene los coeficientes de aproximación, y que las siguientes ventanas sean las de coeficientes de detalle en un orden descendente, no entregar los parámetros de forma correcta corrompe la señal y la aplicación de los filtros puede fallar (www.pybytes.com, Inverse Discrete Wavelet Transform (IDWT), 2012).

Una vez aplicada la IDWT a los niveles previamente umbralizados se puede observar como la señal en el plano del tiempo está mucho más limpia y libre de ruido, mientras que, en el plano de la frecuencia, los ritmos Beta, Theta, Delta y Alpha según sea el estado del estudio, tienen una importancia y amplitud más definida y clara que cuando no se aplicaba dicho proceso.

6. PROCESAMIENTO Y CARACTERIZACIÓN DE LA SEÑAL EEG

6.1. INTRODUCCIÓN A CAPÍTULO

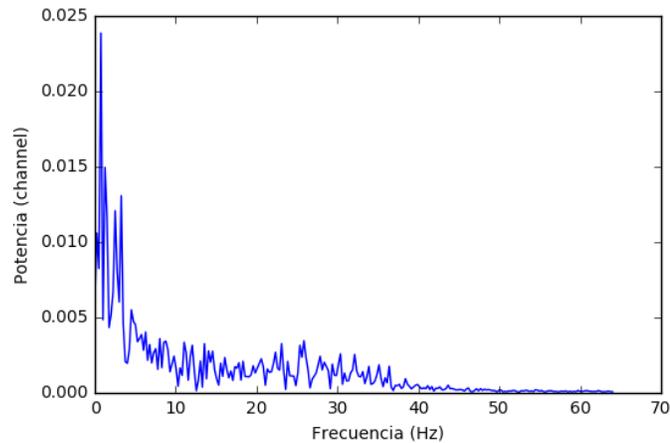
Posterior al proceso de preprocesamiento de la señal en donde se extrajeron o atenuaron los artefactos que distorsionaban el EEG, se debe realizar el procesamiento de la misma con el objetivo de tomar características propias de los estados de somnolencia o vigilia. Como el análisis se realiza en ventanas de tiempo pequeñas para asumir propiedades de onda estacionaria, es adecuado afirmar que se pueden extraer características propias de este tipo de ondas. La caracterización de la señal se hace entonces a nivel frecuencial, y según el comportamiento que se pueda observar entre un estado y otro se determinara aquellos parámetros que tenga una variación alta y brinden información propia para uno u otro estado.

6.2. DENSIDAD ESPECTRAL DE POTENCIA

La Densidad Espectral de Potencia (PSD, de sus siglas en inglés Power Spectrum Density) se obtiene a partir de la Magnitud de cada valor de la Transformada Rápida de Fourier (FFT, de sus siglas en inglés Fast Fourier Transform) (Proakis & Manolakis, 2007). Es un plano en el dominio de la frecuencia vs la potencia en donde cada valor frecuencial se le asigna un valor de potencia que resulta a partir del cálculo de FFT (Garcés Correa, Procesamiento de Señales cerebrales para la Detección de Somnolencia en Conductores., 2011). Teniendo en cuenta esta propiedad se realizó el cálculo para cada ventana de una duración de 4 segundos, donde los primeros 256 valores ofrecen información frecuencial entre 0Hz y 64Hz, lo que obedece el criterio de Nyquist debido a que nuestra frecuencia de muestreo es de 128Hz, los siguientes 256 valores obedecen a valores de frecuencia negativa que no serán tenidos en cuenta ni tienen relevancia en esta investigación.

Con la densidad espectral de potencia podemos obtener información frecuencial de cada ventana, lo que brinda una potente, elegante y eficiente herramienta para poder llevar a cabo la caracterización de la señal.

Figura 12 Diagrama de PSD de la señal EEG en Vigilia del canal F3 después del preprocesamiento



6.3. CARACTERIZACIÓN EEG

Basados en el proyecto de grado doctoral de la Dra. Agustina Garcés (Garcés Correa, Procesamiento de Señales cerebrales para la Detección de Somnolencia en Conductores., 2011), en donde toma 6 características de la señal para determinar estados de somnolencia por medio de un clasificador basado en redes neuronales con un porcentaje de confianza promedio de 84%. Y complementando con el trabajo propuesto por Anindya Bijoy Das and Mohammed Imamul Hassan Bhuiyan (Das & Bhuiyan, 2016), en donde se tiene en cuenta los procesos de entropía del PSD, proponemos el siguiente método para caracterización teniendo en cuenta los siguientes parámetros:

Calcular la energía en bandas de alta incidencia en detección de somnolencia y vigilia pueden ser tomadas como características. El aumento o disminución de energía en estas porciones de señal en cada ventana son un índice de alta variación entre un estado y otro (Garcés C., Orosco, & Laciari, 2014), por eso es de alta importancia que se tengan en cuenta a la hora de caracterizar nuestros estados de interés. La energía es la sumatoria del cuadrado de la potencia en cada frecuencia que compone un PSD (Proakis & Manolakis, 2007), y se calcula de la siguiente manera se calcula a partir de:

$$E = \sum_{i=0}^N (x_i)^2$$

Ecuación 3 Determinación de la energía de una señal

6.3.1. Energía entre 4Hz y 8Hz

Esta banda es de vital importancia a la hora de detectar somnolencia temprana, es por eso que el cálculo de la energía a partir de la en esta banda de frecuencia se puede tomar como característica clave para diferenciar entre ambos estados (Garcés, Orosco, & Laciari, 2014). Theta es el ritmo de EEG presente en esta banda, y como ya conocemos sus características, a mayor presencia de este ritmo, más evidente será la aparición de somnolencia en una persona, su concentración energética aumenta a medida que a persona entra en estado de relajación y es notoriamente más fuerte a medida que se va adentrando a estados profundos de sueño.

6.3.2. Energía entre 8Hz y 12Hz

Esta banda es de vital importancia a la hora de detectar somnolencia temprana, es por eso que el cálculo de la energía en esta banda de frecuencia se puede tomar como característica clave para diferenciar entre ambos estados (Garcés C., Orosco, & Laciari, 2014). Alpha es el ritmo de EEG presente en esta banda, y como ya conocemos sus características, a mayor presencia de este ritmo más evidente será la aparición de somnolencia en una persona, su concentración energética se hace mayor cuando el paciente tiene los ojos cerrados y en las primeras fases del sueño.

6.3.3. Frecuencia en la potencia máxima

Esta frecuencia usualmente se concentra en bajas frecuencias, en un estado de vigilia su aparición es más dada a moverse en una banda entre 5Hz y 7Hz (Garcés C., Orosco, & Laciari, 2014), pero al entrar en estados de somnolencia comienza a desplazarse hasta llegar a obtener valor por debajo de 1Hz, aunque esta medición depende mucho del canal también fue considerada una característica.

6.3.4. Entropía de Shannon

Como se ha evidenciado en trabajos anteriores, tomar la entropía para caracterizar la Señal EEG en la ventana de corta duración resulta ser un método bastante eficiente para poder distinguir entre la dominancia de un ritmo electroencefalográfico y otro. La entropía de Shannon mide la incertidumbre de la señal y fue introducida principalmente como parte de la teoría de la información (Das & Bhuiyan, 2016)

(Lerga, Saulig, Mozetic, & Lerga, 2016). Su concepto matemático mide la probabilidad del logaritmo de la probabilidad con la que un dato puede repetirse en una señal dada. Y sigue la siguiente formula:

$$H_{shannon} = \sum_{i=1}^N p_i^2 * \log_2(p_i^2)$$

Ecuación 4 Entropía de Shannon

6.3.5. Entropía energética

Esta entropía mide la irregularidad del espectro de la señal producto de su PSD (Das & Bhuiyan, 2016) (Lerga, Saulig, Mozetic, & Lerga, 2016), un número elevado de esta entropía indica que la señal es altamente regular, de lo anterior se analiza que en los estados del sueño, donde la concentración energética se concentra solo en bajas frecuencias la entropía debe ser un número menor que en el estado de vigilia, ya que la energía es un poco más distribuida en frecuencias hasta 30Hz. Se calcula a partir de:

$$H_{Log_Energy} = \sum_{i=1}^N \log_2(p_i^2)$$

Ecuación 5 Entropía energética

6.3.6. Entropía de Renyi

Esta entropía mide que tan aleatorios son los datos que conforman el PSD de la señal a analizar, un número elevado en esta entropía habla de una señal altamente aleatoria (Das & Bhuiyan, 2016) (Lerga, Saulig, Mozetic, & Lerga, 2016), rasgo típico de un PSD para una muestra en estado de vigilia, pues en somnolencia la señal está más concentrada en una banda y el resto de su distribución energética es muy simétrico entre sí. Se calcula a partir de

$$H_{Renyi} = -\log \sum_{i=1}^N p_i^2$$

Ecuación 6 Entropía de Renyi

6.4. HISTORIAL DE MUESTRAS DE EEG

En resumen, y hasta esta etapa se han obtenido 6 características definidas para cada ventana de 4 segundos de EEG, como en este proyecto se toma información total de los 14 canales disponibles en el equipo Emotiv EPOC+, se obtiene un total de 84 características por cada ventana de 4 segundos en cada uno de los canales.

Es importante y de suma importancia garantizar que cada característica será extraída en un orden establecido que no debe ser alterado bajo ninguna circunstancia. Esto quiere decir que la lista que contiene los 6 parámetros en el orden descrito anteriormente para un canal, debe ser concatenado con las otras 13 listas que contienen los 6 parámetros en el mismo orden para formar una única lista de 84 parámetros por muestra, que debe ser organizada muestra tras muestra de la misma manera. Cada lista será el resultado de 4 segundos de preprocesamiento y el procesamiento de la señal EEG.

Adicionalmente, y con ayuda del soporte audiovisual capturado paralelamente durante cada sesión de muestreo, se determinan los periodos de tiempo en los que se entraba en un estado de vigilia y de somnolencia. Estos registros servían de soporte para que una función cíclica asignara un valor de 0 para dormido y 1 para despierto a cada una de las muestras de la señal.

El vector obtenido también era sometido al mismo proceso de ventaneo de la muestra obtenida, como el vector y la matriz de datos tenían la misma longitud se realiza un proceso de ponderación para determinar cuál es el estado dominante en la ventana, con esto se determina si la ventana tiene un mayor número de muestras dormido o despierto y así mismo sería la etiqueta que recibiría las 84 características de cada ventana. 1 para despierto y 0 para dormido.

6.5. ANÁLISIS DE COMPONENTES PRINCIPALES

El análisis de componentes principales (PCA, de sus siglas en inglés Principal Analysis Component), es una técnica estadística que evalúa una lista de parámetros y elige solo aquellos que sean ortogonales entre sí para disminuir el número de parámetros analizar y dejar solo aquellos que son altamente separables y brindan información relevante para el clasificador (Bishop, 2007) (Buitinck, y otros, 2013).

6.5.1. Normalización de características

La normalización de características es un proceso estadístico previo a la aplicación del PCA; se lleva a cabo aplicando procesos de media y desviación estándar, que permitió escalar cada característica a una misma proporcionalidad y así dar relevancia a cada una de las 84 características obtenidas. El no realizar este proceso puede inferir negativamente en el entrenamiento de clasificador o un posterior análisis de selección de características. Pues algunas de ellas podrían tener erróneamente un peso mayor o menos con respecto a otras por estar hablando de magnitudes diferentes con procesos de cálculo totalmente independientes entre sí (Bishop, 2007) (Buitinck, y otros, 2013).

6.5.2. Aplicación del PCA

PCA nos permite obtener un conjunto de características no correlacionadas entre sí (Bishop, 2007) (Buitinck, y otros, 2013), esto aumenta de manera eficiente la clasificación y permite hacer aún más diferenciable un estado del otro. Por medio de diferentes experimentos usando pipeline, que será objeto de estudio en el siguiente capítulo, y observando la incidencia de disminución de características obtenidas, se observa que el número de PCA's que necesita un clasificador para discernir entre un estado de vigilia y uno de somnolencia, esta intrínsecamente ligado al tipo de clasificador que se use.

Es importante reafirmar la importancia de la normalización de las características pues ellas pertenecen a diferentes magnitudes físicas y primero deben ser medibles y proporcionables entre ellas para que su covarianza sea aplicada correctamente sin resaltar o desprestigiar ningún valor por una mala escalabilidad entre características.

7. RECONOCIMIENTO DE PATRONES PARA LA CLASIFICACIÓN DE LA SEÑAL EEG

7.1. INTRODUCCIÓN DE CAPÍTULO

Un clasificador es un algoritmo computacional que, por medio de un aprendizaje supervisado, es capaz de modelar o aprender una serie de datos con el objetivo de que pueda discernir entre dos o más diferentes tipos de conjunto de datos. Los clasificadores usados en esta sección son convexos. Esto quiere decir que a diferencia de otros métodos como las redes neuronales, algoritmos de clasificación como las Máquinas de Vectores de Soporte o K-ésimo vecino más cercano, tienen una función de error convexa que quiere decir que si se tienen parámetros adecuados y el tiempo de entrenamiento es adecuado el resultado siempre será el mismo (Bishop, 2007) (Chai, y otros, 2016) (Pedregosa, y otros, 2011), caso que no se tiene certeza de poderse presentar en las redes neuronales donde cada caso de entrenamiento es único a pesar de que sus parámetros e hiper parámetros sean los mismos.

En esta sección se describe como se entrenaron y validaron dos casos de clasificación usando dos diferentes algoritmos para determinar cuál era el mejor detectando entre uno y otro estado. Esta validación se hizo por una serie de experimentos asistidos por algoritmos robustos de entrenamiento que nos permiten obtener un resultado bastante fiable sobre el método a usar.

7.2. PREPARACIÓN DE DATOS

Para el entrenamiento de los clasificadores se tomaron en total 2248 segundos de señal, divididos en 1124 ventanas de 4 segundos de duración, que conformaban una matriz de 84 parámetros por 1124 muestras, junto a un vector de 1124 discriminados entre 0 para dormido y 1 para despierto.

Para poder obtener información precisa de toda la señal, se realizó un proceso estadístico sobre el vector de caracterización. Dicho proceso consiste en evaluar paquetes que corresponden a 512 muestras obtenidas en una ventana de 4 segundos, y por aproximación encontrar el estado dominante o que más presencia tuviera esa ventana, para así asumir que esa ventana correspondía a un estado u otro. Esto quiere decir que si una ventana de 4 segundos o 512 muestras contenía en su vector característico 300 ceros (dormido) y 212 unos (despierto) se etiquetaba esa ventana con un 0 (dormido) ya que este era el estado predominante en dicha

ventana, esto permitió dar un análisis típico de una señal variante en el tiempo a una sucesión de ventanas pequeñas de señales invariantes en el tiempo. Lo que insidó positivamente en la eficiencia de los clasificadores.

7.3. SECCIONAMIENTO DE DATOS Y VALIDACIÓN CRUZADA

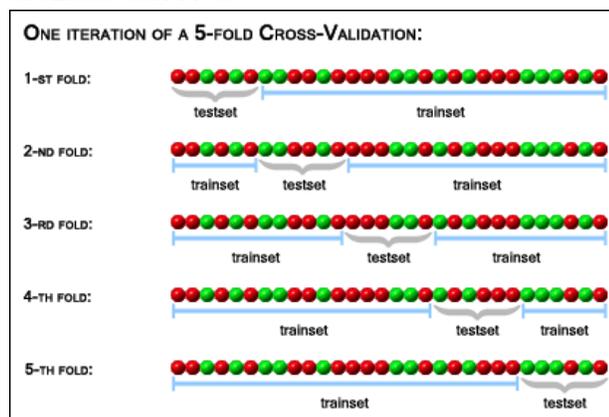
Una vez preparada la matriz de parámetros y el vector de características, es necesario fijar que porcentaje de los datos será usado para el entrenamiento y la validación, y cuáles serán usados para el testeo del clasificador. Clásicamente se toma el 80% de los datos para entrenamiento y validación y el 20% restante para testeo (Bishop, 2007) (Bermúdez, Laencina, González, González, & Dorda, 2012), lo que nos deja:

Tabla 4 División de datos para el clasificador

Elementos	Cantidad
Datos obtenidos	1124
Datos de entrenamiento/validación	900
Datos de testeo	224

La validación cruzada es un método clásico de entrenamiento en donde un número de N iteraciones se divide el conjunto de datos de entrenamiento en N conjuntos, en donde uno de los subconjuntos se utiliza para validar y el resto de conjuntos se utiliza para el entrenamiento, el proceso es iterativo y se repite N veces para probar todos los subconjuntos posibles, Finalmente se toma la media aritmética de todos estos procesos de entrenamiento y se entrega el más óptimo de ellos (Bishop, 2007) (Bermúdez, Laencina, González, González, & Dorda, 2012). Para los procesos de entrenamiento aquí descritos se usó un N = 5.

Figura 13 Validación cruzada con N=5



7.4. PIPELINE

Pipeline es un método de diseño y ajuste de parámetros e hiper parámetros, en el que se hacen procesos iterativos para ejecutar varias posibles combinaciones que permitan diseñar un clasificador altamente eficiente evaluando un rango de ajuste para varias secciones del proceso en mención (Buitinck, y otros, 2013).

La función de Pipeline es formar conjuntos de entrenamiento con cada uno de los hiper parámetros seleccionados, que pasan posteriormente a una validación cruzada y tras un proceso iterativo entrenamiento, validación y testeo de cada uno de los conjuntos de clasificación posibles se selecciona el mejor y se establece como el mejor clasificador de datos de acuerdo al rango de parámetros establecido

Pipeline está disponible en la biblioteca Scikit-Learn de Python, el Pipeline recibe una lista de hiper parámetros, estos se combinan entre si formando los conjuntos ya mencionados. Esto permite ejecutar de manera simultánea una cantidad muy elevada de entrenamientos y posibles combinaciones para elegir de forma certera el clasificador que verdaderamente ofrezca las mejores prestaciones. Este proceso puede llevar algunos segundos o incluso horas, pero siempre tendremos la confianza de obtener el mejor resultado posible a partir de los parámetros de la señal EEG y los hiper parámetros del clasificador.

7.5. STACK DE CLASIFICACIÓN

Como se expuso en el capítulo anterior, después de caracterizar la señal EEG y obtener un vector de 84 características por cada ventana de 4 segundos, fue necesario aplicar PCA con el objetivo de extraer solo las características más dicientes de este vector, pero también se dejó la observación de que PCA era variable según el clasificador que se use.

Para ello se debe formular un pipeline que me permita tomar componentes principales (PC) como un hiper parámetro para determinar cuál sería el más conveniente de usar. De manera general el pipeline del clasificador será basado en el siguiente diagrama de bloques:

Figura 14 Subproceso de clasificación



El pipeline entonces tiene como hiper parámetro adicional los PCA que se van a obtener de cada vector de características, el tipo de clasificador y los hiper parámetros de dicho clasificador, como se mencionó en el capítulo anterior el proceso de normalización de datos es indispensable, por eso se considera dentro del pipeline para que el vector de características siempre sea procesado primero por el algoritmo de normalización de parámetros.

7.6. INDICADORES DE ENTRENAMIENTO, VALIDACIÓN Y TESTEO

Una vez entrenado el clasificador es necesario evaluar la exhaustividad, precisión y algunos otros aspectos que nos darán una visión general de lo que podríamos esperar de nuestro algoritmo de aprendizaje de máquina por medio de un testeo. Como pipeline nos entrega el mejor clasificador entre miles que son evaluados bajo distintas condiciones, estamos seguros de que estos indicadores deberán ser los bastante buenos si hemos hecho un buen proceso de preprocesamiento, procesamiento y extracción de características de EEG. Los indicadores que nos darán suficiente información son:

7.6.1. Precisión

La precisión es un factor que indica el porcentaje de vectores etiquetados correctamente después de la clasificación (Pedregosa, y otros, 2011) (Duda, Hart, & Stork, 2001), por ejemplo, si envié al clasificador 40 muestras, que corresponden a 30 muestras de despierto y 10 muestras de dormido, y la respuesta de clasificador es que tengo 22 muestras de despierto y 18 de dormido, dentro de las muestras de despierto, realmente había 4 que eran de dormido, esto me da una precisión de $18/22$ o 81.82% de precisión.

7.6.2. Exhaustividad

La exhaustividad es un factor que indica cuantos el porcentaje de vectores predichos correctamente, comparando el valor de la etiqueta real (establecida por un usuario) y la etiqueta dada por el clasificador (Bishop, 2007) (Duda, Hart, & Stork, 2001) siguiendo el ejemplo dado en la subsección de precisión, en donde se detectaron 22 muestras de despierto cuando realmente eran 30 de despierto, y de esas 4 corresponden originalmente a un estado de dormido, esto me da una precisión de $18/30$ o 60% de exhaustividad.

7.6.3. Valor F

El valor F es un factor que pondera la precisión y la exhaustividad para darnos una media armónica que describe la medida de exactitud de la clasificación en un testeo (Bishop, 2007) (Daphne & Raj, 2012), siguiendo el ejemplo anterior, en donde se obtuvo 81.82% de precisión y 60% de exhaustividad obtenemos un valor F del 69.23%.

7.6.4. Vectores

Vector es un factor que me indica justamente cuantos vectores fueron los más relevantes y representativos para realizar el entrenamiento, según sea el algoritmo que se use para el clasificador y los diferentes Pipeline establecidos, este número podría variar, pero a nivel general podemos decir que el número de vectores usados para realizar el clasificador son aquellos que son más compactos entre si y muestran la menor dispersión posible entre sus parámetros (Bermúdez, Laencina, González, González, & Dorda, 2012) (Bishop, 2007) (Duda, Hart, & Stork, 2001).

7.7. K-ÉSIMO VECINO MAS CERCANO

El algoritmo del K-ésimo Vecino más Cercano (K Nearest Neighbors – KNN) es un algoritmo de aprendizaje de maquina no supervisado y no paramétrico, esto quiere decir que él no “aprende” y modela un grupo de datos de entrenamiento, solo los convierte en un vector en un plano cuyas dimensiones está dado por el número de características elegidas para clasificar (Bishop, 2007) (Guo, Lu, Liu, & Xu, 2015). Estos vectores reciben una etiqueta, en nuestro caso “Dormido” o “Despierto” y crean un universo de probabilidades que serán el criterio de evaluación para los vectores de entrada cuya etiqueta se tratara de predecir.

Este método es considerado un estándar de oro (Gold Standard) pues sirve como parámetro para compararlo con otros algoritmos que en teoría deberían ser muchos más robustos que él obtengan un mejor grado de asertividad, aunque en algunos casos se ha demostrado que a nivel práctico que en algunas aplicaciones la sencillez y eficiencia de KNN está por encima de muchos otros algoritmos complejos de aprendizaje de máquina.

7.7.1. Vecinos

Se considera vecinos al grupo de vectores que conforman el universo de posibilidades con que se entrena KNN. El número de vecinos está dado por un hiper parámetro llamado K, que es el valor que determina el número de vecinos más cercanos que se va a evaluar cuando por el clasificador entra un vector con etiqueta desconocida y que se intenta predecir si pertenece a un estado de “Despierto” o “Dormido”. Siendo K quien determina cuantos vecinos serán los necesarios para que el clasificador haga una predicción.

7.7.2. Pesos

Otro hiper parámetro a tener en cuenta en KNN es la forma con que se evaluará la incidencia de los vecinos en la predicción. Para esto existen dos métodos que son:

7.7.2.1. Distancia

Analizar la incidencia de los vecinos por distancia quiere decir que se asignara una etiqueta al vector que entre al clasificador, dependiendo de la cantidad mayoritaria de vecinos que determine K sobre el vector desconocido, esto quiere decir que, si tengo un K de 10, y tengo 7 vecinos con etiqueta de “Dormido” y solo 3 con etiqueta “Despierto, el vector desconocido será etiquetado como “Dormido”.

7.7.2.2. Peso

Analizar la incidencia de los vecinos por eso quiere decir que se asignara una etiqueta al vector que entre al clasificador, dependiendo de la cantidad mayoritaria de vecinos que estén más cerca o tengan una influencia más cercana sobre el vector desconocido, esto quiere decir que, si tengo un K de 10, y tengo 7 vecinos con etiqueta de “Dormido” que se encuentran más lejos que solo 3 con etiqueta “Despierto”, el vector desconocido será etiquetado como “Despierto”.

7.7.3. Resultados de implementación de KNN

Este método, potente, liviano y eficiente, nos brinda entre un 82% y 84% de eficiencia en la identificación entre estados de somnolencia y vigilia. Teniendo en cuenta los parámetros e hiper parámetros, se hace necesario realizar una serie de

experimentos donde se puedan variar los hiper parámetros de tal manera que se pueda encontrar el mejor ajuste posible según las características procesadas en el capítulo anterior. Los resultados son mostrados a continuación:

Tabla 5 Pipeline entrenamiento programado para KNN

Híper parámetro	Valor
Numero de PC	47
Número de vecinos	1
Peso	Uniforme
Exactitud	88.71%
conjuntos de Pipeline	67220
Tiempo de ejecución de todos los Pipeline	22,1 Minutos

Analizando el mejor Pipeline o hiper parámetros seleccionados obtenemos los siguientes resultados:

Tabla 6 Indicadores de entrenamiento para el test del mejor entrenamiento para KNN

Etiqueta	Precisión	exhaustividad	Valor-F	Vectores
Dormido	89%	89%	89%	136
Despierto	88%	88%	88%	121

7.8. MAQUINA DE VECTORES DE SOPORTE

El algoritmo de Maquinas de Vectores de Soporte (SVM, de sus siglas en inglés Support Vector Machine), es un algoritmo de aprendizaje de maquina supervisado y paramétrico, muy popular en el campo de la clasificación y reconocimiento de parámetros en el procesamiento digital de señales biomédicas. Fue desarrollado por Vladimir Vapnik y su equipo en los laboratorios AT&T. Este algoritmo de manera básicamente toma los diferentes vectores de entrenamiento y comienza a elevarlos a un hiper plano en un espacio mucho mayor al original, de tal manera que se pueda llegar a uno en donde se pueda trazar una frontera entre vectores de un estado y otro y así ofrecer una predicción para futuros vectores desconocidos.

Entre sus principales ventajas está en que SVM usa un proceso de clasificación convexo, lo que quiere decir que su entrenamiento siempre dará el mismo resultado para el mismo grupo de parámetros y de hiper parámetros. Esto ofrece una ventaja frente a otros métodos como redes neuronales cuya función no es convexa.

SVM como clasificador de estados de somnolencia en señales EEG utilizó los siguientes hiper parámetros para ser evaluados por medio de un pipeline.

7.8.1. Kernel

Este hiper parámetro en una SVM establece la forma en la que se llevaran a un hiper plano de orden muy superior los vectores a clasificar para poder ser divididos por una línea recta. Este ejercicio hace que los vectores no puedan tener una representación clara por el orden elevado de la dimensión donde están representados. Existen diferentes tipos de kernel, para nuestro clasificador de estados de somnolencia en EEG usamos dos de ellos, estos son:

7.8.1.1. Lineal

Este Kernel busca un hiper plano elevando la dimensión del mismo tantas veces sea requerido para hacer una separación lineal entre una y otra característica, este es el método más sencillo de usar y con más aplicaciones.

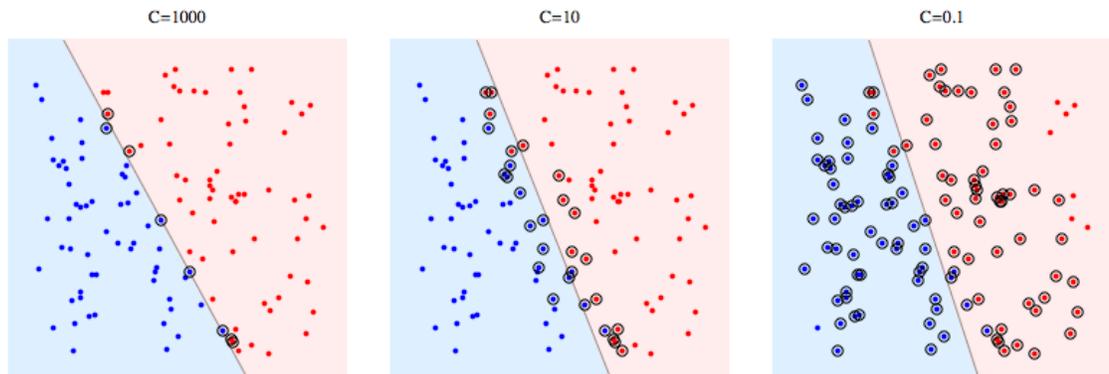
7.8.1.2. Radial Gaussiano

Este Kernel busca un hiper plano elevando la dimensión del mismo tantas veces sea requerido para hacer una separación radial entre una y otra característica, este método se ajusta muy eficientemente a los diferentes vectores, por lo que podría ser muy preciso y confiable.

7.8.2. C

C es un parámetro de penalti, lo que quiere decir que es quien indica a la SVM que tan ajustado o no será el método de ajuste de kernel. Si se tiene un C muy bajo, el entrenamiento será muy permisivo y el kernel se ajustará no muy eficientemente dando espacio a un sub entrenamiento. Caso contrario a un C bastante grande donde se obtenga una función kernel bastante ajustada a los datos de entrenamiento pero que será incapaz de predecir datos que no se acerquen bastante al valor de los datos entrenados.

Figura 15 Efectos de C en la selección de Vectores de Soporte



Fuente: <http://stackoverflow.com/questions/4629505/svm-hard-or-soft-margins>

7.8.3. Gamma

Gamma es el hiper parámetro de varianza Guadiana, solo disponible en SVM de base radial. Un Gamma pequeño indica que la función kernel tendrá alta varianza y poca polarización, lo que determina que tanta influencia tendrán algunos vectores en la clasificación para ser o no considerados vectores de soporte, por lo que si Gamma no se escoge correctamente podría causar que los vectores a predecir sean clasificados incorrectamente por no estimar muy bien la varianza de su gaussianidad.

7.8.4. Optimización convexa

Este hiper parámetro está disponible para Kernel Lineal, y es el que se ajusta para proponer la optimización convexa de forma dual o primaria, si se elige hacer una optimización dual, quiere decir que el número de vectores de soporte será mayor que el número de vectores característicos y se hace necesario un ajuste de mínimos globales y locales para poder clasificar los vectores a predecir, lo que conlleva a realizar optimización por minimización, un optimización primaria por el contrario es un problema de maximización y se debe usar cuando el número de características supera al número de muestras.

7.8.5. Resultados de Implementación de SVM

7.8.5.1. Resultados para SVM kernel lineal

Tabla 7 Pipeline de entrenamiento programado para SVM de kernel Lineal

Hiperparámetro	Valor
Numero de PC	65
C	0.207
Optimización	Dual
Exactitud	82.88%
conjuntos de Pipeline	6400
Tiempo de ejecución de todos los Pipeline	9.9 Minutos

Analizando el mejor Pipeline o hiper parámetros seleccionados obtenemos los siguientes resultados:

Tabla 8 Indicadores de entrenamiento para el test del mejor entrenamiento para SVM de kernel lineal

Etiqueta	Precisión	Exhaustividad	Valor-F	Vectores
Dormido	81%	89%	85%	137
Despierto	86%	76%	81%	120

7.8.5.2. Resultados para SVM kernel radial gaussiano

Tabla 9 Pipeline de entrenamiento programado para SVM de kernel radial

Hiperparámetro	Valor
Numero de PC	45
C	3,792
Gamma	0.0335
Exactitud	92.67%
conjuntos de Pipeline	38400
Tiempo de ejecución de todos los Pipeline	75,1 Minutos

Analizando el mejor Pipeline o hiper parámetros seleccionados obtenemos los siguientes resultados:

Tabla 10 Indicadores de entrenamiento para el test del mejor entrenamiento para SVM de kernel radial

Etiqueta	Precisión	Exhaustividad	Valor-F	Vectores
Dormido	94%	93%	93%	147
Despierto	94%	91%	92%	110

La SVM, al ser un algoritmo paramétrico y más robusto que KNN mostro efectivamente un índice más alto de exactitud en la clasificación entre estados de vigilia y somnolencia, por ende, será el algoritmo encargado de hacer reconocimiento de patrones para el sistema EEG. En el siguiente capítulo analizaremos los resultados de todo el algoritmo necesario para poder realizar esta clasificación usando como fuente de información la señal EEG.

8. ANÁLISIS DE RESULTADOS

8.1. INTRODUCCIÓN DE CAPÍTULO

Esta sección está dedicada a mostrar los resultados en la metodología propuesta para hacer una correcta detección entre estados de sueño y vigilia a nivel intrapersonal. El sistema propuesto en este proyecto de grado cumple con altos estándares en la detección de somnolencia, aun siendo comparado con los resultados que equipos médicos de alta gama podrían brindar. El Emotiv EPOC+ fue más que suficiente para obtener las señales que pudieron ser procesadas y clasificadas. Las cuales sirven de base para aplicaciones de detección de somnolencia en conductores, operarios y demás personas que requieren monitoreo permanente en sus labores, sin el riesgo de caer en estado de adormecimiento. Este estado en ocasiones es imperceptible visualmente, pero fácilmente percibido por el cambio de potenciales en la banda de frecuencias que conforman el EEG.

La metodología propuesta por nosotros en este trabajo de proyecto de grado, muestra dos sistemas, uno para el entrenamiento y uno para la identificación, ambos funcionan de manera offline, y sus bases de preprocesamiento y procesamiento son iguales. Las variaciones entre ambas están en el bloque de clasificación. El sistema de entrenamiento usa este bloque para que un conjunto de datos entrene un algoritmo de clasificación; con SVM de Kernel Radial. El sistema de reconocimiento usa este bloque previamente entrenado como sistema de reconocimiento de patrones entre los estados de vigilia y de somnolencia.

Los resultados mostrados en este capítulo demuestran que este sistema es capaz de discriminar entre ambos estados, somnolencia y vigilia.

8.2. ANÁLISIS DEL SUBPROCESO DE PREPROCESAMIENTO DE LA SEÑAL

El algoritmo de preprocesamiento descrito en el capítulo 3 de este documento es lo suficientemente robusto para atenuar los artefactos encontrados en el EEG. Como se puede apreciar en el capítulo 3, se intentaron usar diferentes técnicas de preprocesamiento para el filtrado y remoción de artefactos, siendo lo más efectivo, sencillo y robusto usar el stack que consta de un filtro IIR, un banco de filtros a partir de la DWT para aplicar umbralización suave y su posterior reconstrucción como una señal considerablemente más limpia que la original.

Por medio de procesos de correlación, entre la señal sin filtrar y la señal obtenida luego del preprocesamiento, es evidente que la señal tiene diferencias muy significativas, atribuidas a la presencia de artefactos en la misma. Los resultados del proceso de correlación para los 14 canales, en una ventana escogida de manera aleatoria se muestran a continuación:

Tabla 11 Correlación entre señal sin filtrar y después de filtrar con el subsistema propuesto

Canal	Correlación entre señal filtrada y no filtrada en (%)
F3	25.49
FC5	23.78
AF3	27.05
F7	26.34
T7	27.67
P7	24.87
O1	26.78
O2	25.45
P8	24.97
T8	22.47
F8	23.76
AF4	24.08
FC6	26.12
F4	27.01

En estos resultados se puede observar que la señal tuvo un porcentaje de cambio importante, reflejado en la incidencia de los artefactos sobre la señal EEG y como el proceso de filtrado fue lo suficientemente efectivo para atenuarlos eficientemente.

8.3. ANÁLISIS DEL SUBPROCESO DE PROCESAMIENTO DE LA SEÑAL

El algoritmo de procesamiento de la señal surgió de la combinación de dos trabajos previamente expuestos en la comunidad científica. Aprovechando las bondades detectadas en cada uno de los trabajos (Garcés M. A., 2011) (Das & Bhuiyan, 2016) se limitó a extraer 6 características por canal, suficientes y muy dicentes de los estados a clasificar. Una observación que se detectó, es que algunos electrodos no son eficientes a la hora de caracterizar somnolencia o vigilia. Los electrodos frontales son eficientes en detectar vigilia, pues el ritmo Beta es fácilmente percibido a través de ellos. En cambio, en somnolencia, los ritmos como Alpha o Delta se concentran en las regiones occipital o posterior, y no son tan fácilmente percibidos

en la parte frontal, por lo que las características en electrodos de zonas muy definidas no serán percibidas de forma eficiente.

Por lo expuesto anteriormente es que se vio la necesidad de aplicar PCA a las características obtenidas. Esto resultó ser muy efectivo a la hora del entrenamiento de aprendizaje de máquina. Pero además se observó que PCA no debería ser analizado como una variable fija, sino una variable dependiente del clasificador a usar. Esta técnica en el sistema de entrenamiento hace parte del pipeline de entrenamiento, mientras que en el sistema de reconocimiento es un hiper parámetro fijado previamente en el entrenamiento que entrega al clasificador los datos procesados y listo para ser clasificados.

Es importante hacer hincapié en que el procesamiento aquí planteado es lo suficientemente efectivo para hacer una correcta extracción de características. A pesar de estar basado en extracción de características de sistemas LTI, al hacer un ventaneo con solapamiento se permite que a través del tiempo estas características cambien, haciendo absoluta compatibilidad con las características de un sistema no LTI. Tal como se demuestra en los resultados obtenidos, se pueden detectar cambios entre vigilia y somnolencia de manera efectiva y temprana.

8.4. ANÁLISIS DEL SUBPROCESO DE CLASIFICACIÓN Y RECONOCIMIENTO DE PATRONES DE LA SEÑAL

Estos resultados son los más importantes en el desarrollo de este proyecto, pues le dan peso y validez al mismo. Esta es finalmente la prueba visible y tangible de que todo el sistema es eficiente y suficientemente capaz de hacer detección de estados y discriminar entre vigilia y somnolencia.

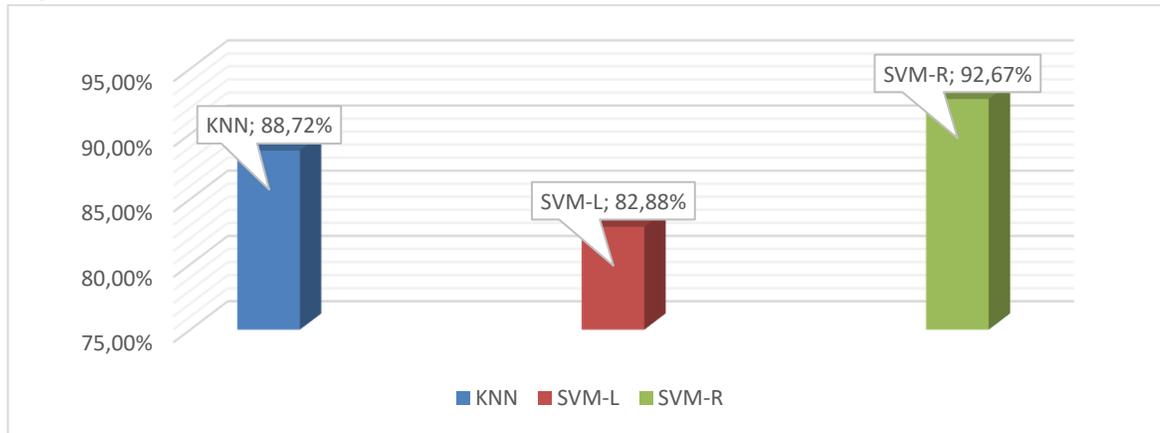
Lo primero que hay que resaltar es la eficiencia y gran legitimidad del método de entrenamiento planteado, pues se lograron realizar miles de entrenamientos en cuestión de minutos para diferentes clasificadores. De ese gran conjunto se eligió el mejor clasificador. Pipeline es entonces una metodología de entrenamiento para aprendizaje de máquina muy eficiente y que no da lugar a dudas sobre si los parámetros, el clasificador y los hiper parámetros son los adecuados para llevar a cabo las tareas de reconocimiento que se quieren realizar.

Hay que reconocer la importancia de KNN como estándar de oro, pues con solo este método sencillo de clasificación se obtuvo una exactitud de detección bastante

elevada. Esto permitió elegir un Kernel adecuado para SVM. Los resultados se resumen a continuación.

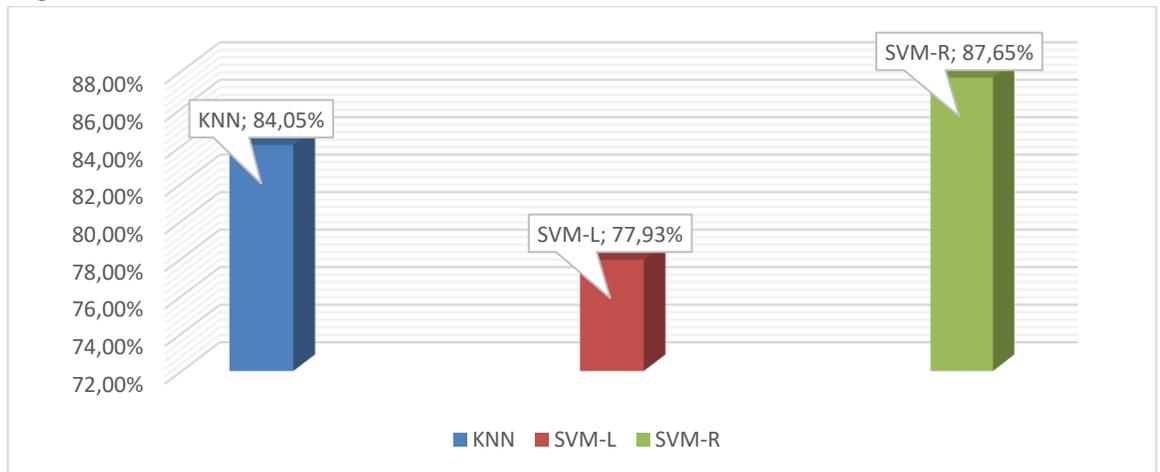
Al ser KNN el clasificador a superar y lograr hacerlo con una SVM de kernel radial, es otro resultado a destacar. La implementación de múltiples clasificadores en este proyecto permitió elegir el mejor de ellos para llegar a un resultado bastante superior, con lo cual valió la pena profundizar con el objetivo de mejorar el sistema de clasificación y realizarlo de manera online.

Figura 16 Comparación de exactitud de los clasificadores



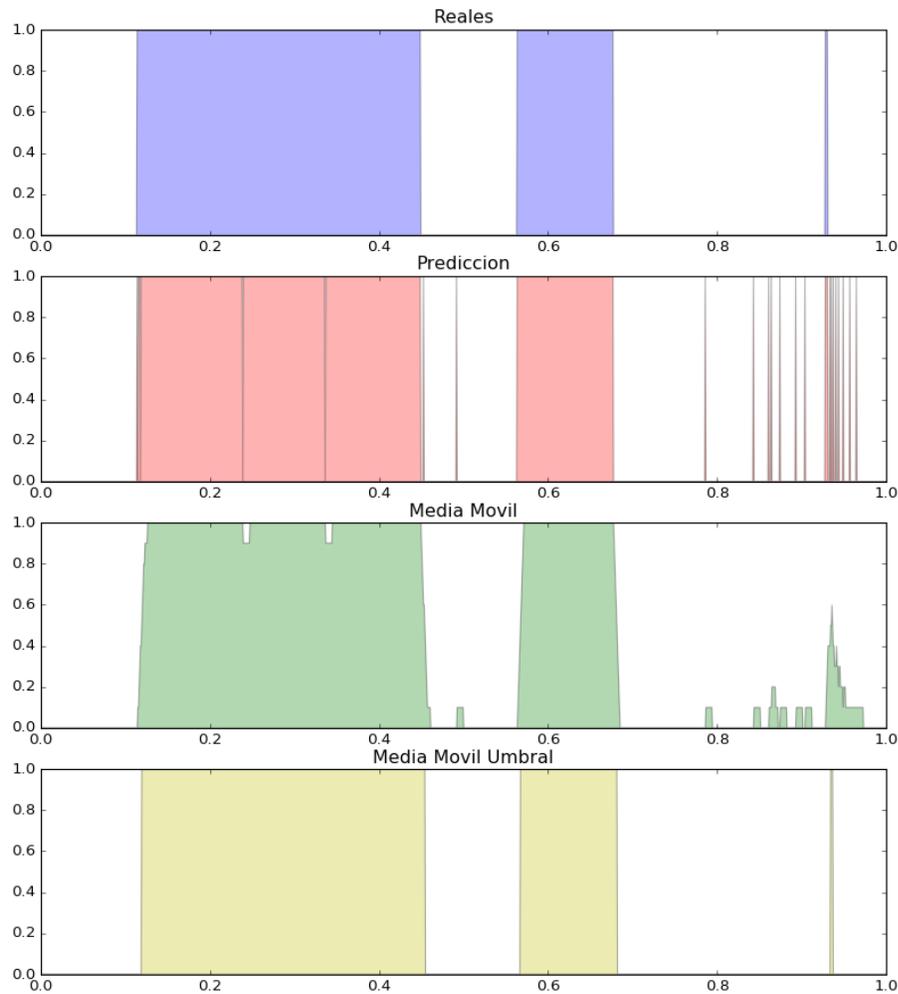
De manera experimental se decidió romper con el estándar de seccionamiento de datos de entrenamiento y se invirtieron los porcentajes, dejando tan solo 20% de los datos para entrenamiento/validación y 80% para testeo, los resultados son mostrados a continuación:

Figura 17 Exactitud de clasificadores con seccionamiento invertido



Utilizar tan pocos datos de entrenamiento, debería haber afectado de forma significativa la exactitud de los clasificadores, pero como puede verse en la representación gráfica, con tan pocos datos de entrenamiento y a pesar de tener una validación cruzada, el resultado no fue golpeado de forma significativa. Esto no solo refirma la robustez y correcto diseño del sistema, si no que sirve para validar todo el proceso previo al bloque clasificador.

Figura 18 Resultado del proceso de reconocimiento de patrones a) estados clasificados por medio del soporte audiovisual b) datos a la salida del clasificador c) datos con media móvil d) datos con umbralización fuerte a media móvil



La eficiencia y exactitud del algoritmo de clasificación se puede elevar si se llevan a cabo el procesamiento de los resultados del predictor. En la ilustración 12, se muestra la representación gráfica de un proceso de reconocimiento de patrones con procesamiento posterior al clasificador.

Esta grafica podría resumir el éxito de los resultados del proyecto. Allí se observa como la comparación entre datos que SVM no conocía y los caracterizados previamente de manera manual son casi perfectos. Además, después de un proceso de suavizado con media móvil, en donde los datos se predicen calculando la media aritmética de orden 10 se obtienen resultados interesantes. Con estos datos, podríamos dar un valor estadístico de que tan dormido o despierto estaba la persona a la hora de tomar el test, lo que constituye un valor agregado al clasificador. El mismo fue diseñado para discriminar solo entre dos estados, pero con media móvil se puede volver un clasificador con porcentaje de actividad de vigilia, lo que aumenta la detección temprana de somnolencia y la transición entre ambos estados.

Para la figura 6.d se aplican procesos de umbralización dura, con esto se elimina la posibilidad de obtener un porcentaje de despierto o dormido, pero se tiene una exactitud del 97% en la predicción en este set de datos. Lo que hace que este sistema funcione muy eficientemente de manera intrapersonal.

Un último logro a destacar consiste en el algoritmo estadístico que clasifica o etiqueta el estado dominante en una ventana de corta duración de EEG. Sin este algoritmo ventanas tan importantes como aquellas donde se da la transición entre vigilia y somnolencia hubiesen sido descartadas. La influencia de que estas ventanas se tuvieran en cuenta a la hora de entrenar el clasificador es evidente cuando observamos los resultados del testeado de los datos.

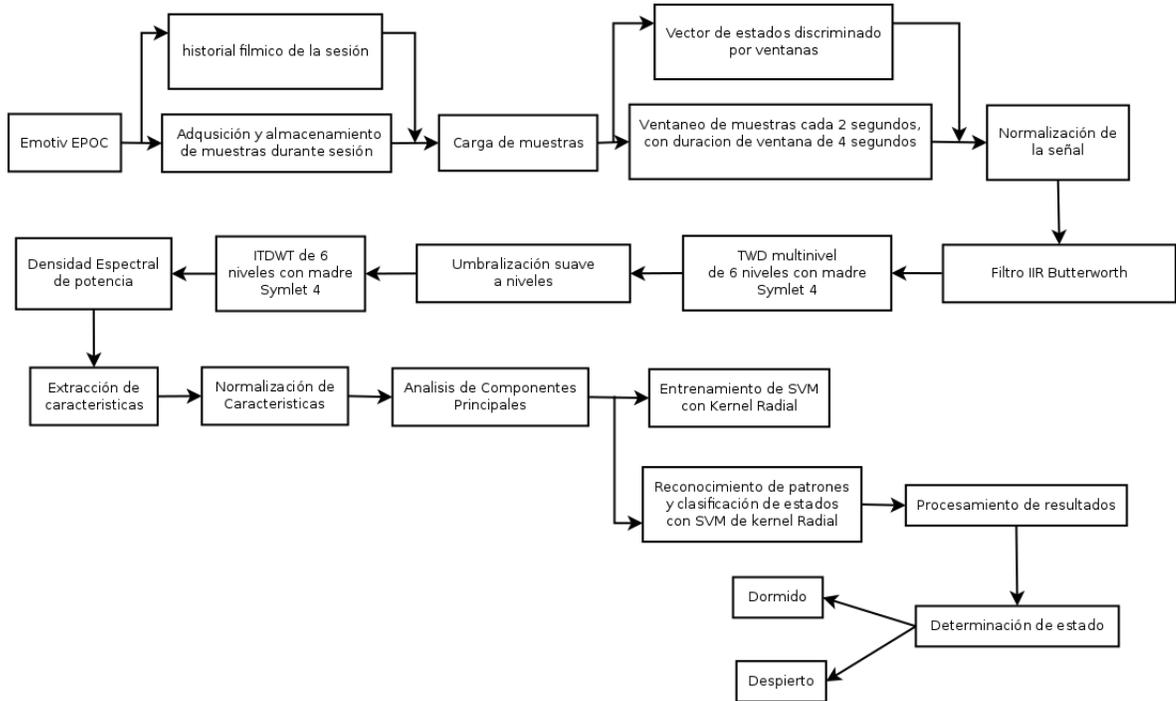
Debemos destacar que todos los resultados aquí mostrados realmente tienen una calidad superior a los trabajos como los de (Ambulkar & Sharma, 2015) (Garcés, Orosco, & Laciari, 2014) (Daphne & Raj, 2012) (Phothisonothai & Nakagawa, 2008). En dichos trabajos se obtienen grados de exactitud entre el 80% y el 90%. Nuestro sistema tiene un grado de exactitud del 92% con el clasificador y 95% con los datos procesados posterior a la clasificación. Nuestro sistema, además, usa un equipo que no tiene la categoría de médico y emplea algoritmos de clasificación robustos que garantizan una detección eficiente como lo demuestran los resultados obtenidos.

8.5. ANÁLISIS DE LOS SISTEMAS DE ENTRENAMIENTO Y CLASIFICACIÓN

Después de describir los resultados en cada subsistema de este proyecto se obtiene un sistema que integra todos los bloques. Así, finalmente se muestra un

sistema para clasificación y otro para detección y reconocimiento de patrones de estados somnolencia por medio de EEG. Esto se presenta a continuación.

Figura 19 Diagrama de bloques específico de los sistemas de entrenamiento y clasificación de reconocimiento de patrones para la detección de somnolencia a partir de señales EEG



Se plantean dos sistemas porque a pesar de utilizar los mismos bloques, en el proceso de entrenamiento se realizan tareas adicionales y que se ejecutan una sola vez (tareas en paralelo que se observan en la figura anterior), mientras que el sistema de clasificación y reconocimiento de patrones es cíclico y se ejecuta cada vez que se pretenda reconocer patrones de somnolencia o vigilia a través de un historial previo de EEG obtenido desde el dispositivo Emotiv EPOC+. La división de este proceso en dos sistemas podrá facilitar la integración del mismo en diferentes equipos de cómputo, teniendo en cuenta que el proceso de entrenamiento tiene un coste computacional más alto que el proceso de clasificación y reconocimiento de patrones EEG.

El sistema es eficiente a nivel de detección de somnolencia temprana a nivel intrapersonal, por lo que será necesario re entrenarlo para cada individuo que pretenda usarlo, en la sección de trabajos propuesto se sugiere realizar el re entrenamiento con muestras a diferentes individuos para que el reconocimiento pueda hacerse a nivel interpersonal.

La calidad de los resultados expuestos aquí tendrá alto impacto en la comunidad científica que investiga esta área, pues la mayoría de trabajos consultados usaban bases de datos de registros EEG obtenidos en laboratorios especializados, o usaban equipos EEG de alto costo y poco portables. Por lo que detectar somnolencia o vigilia con un equipo básico y no medico como el Emotiv EPOC+ constituye un logro elevado y destacado.

9. CONCLUSIONES

Se logró construir y formular un sistema integral o embebido capaz de realizar detección temprana de somnolencia usando señales EEG. El sistema funciona con un equipo de fácil acceso que por medio un interfaz cerebro – computador, estableciendo una conexión cifrada vía bluetooth es capaz de realizar la clasificación entre los estados de vigilia y somnolencia.

A nivel de preprocesamiento se lograron aportes a la comunidad científica en la metodología de filtrado de señales no estacionarias. El subsistema propuesto para el preprocesamiento permite que la señal pueda tener un tratamiento típico de señales invariantes en el tiempo, pero refleja claramente las variaciones propias de las señales no estacionarias como el EEG. Esto permite que el análisis sea lo suficientemente robusto en su proceso de atenuación de artefactos, y a su vez liviano en su coste computacional. Por lo anterior mencionado y teniendo en cuenta que es un subsistema programado en un lenguaje multiparadigma como lo es Python, podría ser integrado en dispositivos portables como Raspberry PI, Beagle Bone o Intel Galileo como bloque de preprocesamiento para interfaz cerebro - computador. Este subsistema será dado a conocer a través de un artículo que se presentará a la comunidad científica al final del 4er trimestre del 2016 o principios del 1er trimestre de 2017, la fecha depende del editor que está en proceso de evaluación del artículo.

A nivel de procesamiento se plantea una metodología que reúne los resultados de dos trabajos bastante interesantes en uno solo. Con características tomadas a nivel frecuencial se logró reunir un conjunto de operaciones estadísticas y probabilísticas, cuyos resultados fueron más que suficientes y diferenciables entre los estados de vigilia y somnolencia. La energía en ciertas bandas de frecuencia, y los procesos de entropía que fueron lo suficientemente efectivos a la hora de formular un vector característico propio de cada estado. Además, se propone un procesamiento secuencial de cada uno de los canales que luego es condensado en un solo vector nombrado como vector característico. Para asegurarse que fuese lo suficientemente dicente de cada estado, fue sometido a un proceso de Análisis de Componentes Independientes, que compila cada vector de características para minimizar el número de datos que no brinden información suficiente de cada estado. De esta manera se forma un nuevo vector con características ortogonales entre sí, lo que nos lleva a un vector con características suficientes y diferenciables que permiten realizar un buen entrenamiento del clasificador. Finalmente, se llega a la conclusión

de que no se puede llegar a un número exacto de componentes principales, pues dependiendo del clasificador y la calidad de las muestras, el número puede variar. Así que se consideró pertinente dejar PCA como parte del pipeline de clasificación para encontrar el mejor número de componentes principales para cada caso particular de entrenamiento.

El subsistema de clasificación y reconocimiento de patrones es el corazón del proyecto, pues les dio validez a los dos subsistemas anteriores. Al ser conscientes de la importancia de este subsistema se plantearon 3 algoritmos de clasificación, uno de ellos es considerado un estándar de oro en los procesos de formulación de algoritmo de clasificación y reconocimiento de patrones. KNN sirvió como meta propia a superar usando algoritmos más robustos, en este caso dos tipos de SVM, una de kernel radial y otra de kernel lineal. Finalmente se determina después de la realización de más de 500 mil experimentos distribuidos en 15 sesiones de entrenamiento con 3 algoritmos de aprendizaje supervisado de maquina diferentes, que SVM de kernel radial es el algoritmo más idóneo para servir como clasificador en el reconocimiento de patrones de estados de somnolencia en señales EEG. Esto queda demostrado con el logro de un 92% de exactitud del sistema de predicción, que después de un procesamiento básico de estos resultados se logró elevar a un 95% de exactitud en la predicción y detección de estados de somnolencia y vigilia de manera temprana. Este subsistema demostró la eficacia del preprocesamiento y procesamiento de la señal EEG, pues también se realizó un barrido en el porcentaje de datos de entrenamiento. Allí fue evidente que el clasificador solo necesita entre una y dos características obtenidas para cada estado para realizar una clasificación con una exactitud entre el 85% y 90%. Con una cantidad de datos 7 veces mayor al número de características obtenidas para cada estado, se logró el porcentaje que podemos ver en este trabajo. Este resultado es excelente teniendo en cuenta que la literatura sobre aprendizaje de maquina dice que mínimo se debe realizar el entrenamiento de un clasificador con 10 veces la cantidad de datos obtenidos por característica (Bishop, 2007) (Buitinck, y otros, 2013) (Buitinck, y otros, 2013).

Finalmente, la unión de los subsistemas, preprocesamiento, procesamiento, clasificación y reconocimiento de patrones, propone la formulación de un sistema de entrenamiento y uno de detección de estados de somnolencia intrapersonal; que se fundamentan en los dos subsistemas anteriores.

El sistema de detección es lo suficientemente robusto para permitir diferenciar por medio del análisis de señales EEG si un individuo está en estado de vigilia o somnolencia. Una gran ventaja es que su coste computacional es bajo, y por estar

escrito en Python, permitirá ser integrado en sistemas computacionales portables y de bajo costo. El sistema de entrenamiento requiere un poco más de coste computacional en el sistema donde será ejecutado, pues el tiempo de ejecución de pipeline que realiza miles de entrenamientos en cada sesión dependerá directamente de los recursos de hardware disponible para el procesamiento paralelo de esta cantidad elevada de entrenamientos propuestos.

El sistema propuesto en este proyecto de grado es un aporte significativo a la comunidad científica que ahonda esfuerzos en la formulación de sistemas efectivos, robustos y de bajo coste computacional capaces de detectar somnolencia usando señales EEG.

Los resultados de esta investigación serán presentados a la comunidad científica a través de la publicación de un artículo presentado a una revista de importante prestigio, (artículo en proceso de revisión), los resultados obtenidos también se pretenden dar a conocer los resultados en alguno de los congresos internacionales desarrollados por IEEE que se realizarán en 2017 y cuyo llamado a trabajos comienza a partir del 1er trimestre del mismo año. Esto garantizará y promoverá una divulgación suficientemente amplia de los logros que aquí se describen.

10. RECOMENDACIONES Y TRABAJOS FUTUROS

A nivel de software se necesita trabajar en la creación de una interfaz amigable con el usuario que además permita realizar una visualización más clara de los datos analizados por medio del algoritmo obtenido. Además, es necesario explorar tecnologías para manejo denso de información, pues como se especificó se obtienen 128 muestras cada segundo, se recomienda que para aplicaciones más extensa se utilicen bases de datos no relacionales para almacenar y analizar los datos.

A nivel de hardware se requiere trabajar en la implementación de otros dispositivos, preferiblemente Open Source como OpenBCI, pues al ser modular será posible explorar con otra clase de electrodos la adquisición de datos, ya que los suministrados por Emotiv Systems tienen a deteriorarse rápidamente por la solución salina usada para mejorar la captura de biopotenciales.

Este proyecto crea las bases necesarias para realizar una investigación más profunda en el área de detección de somnolencia usando señales EEG. Es por eso que se dejan propuestas para futuros trabajos que se podrían realizar.

Para aumentar aún más el ahorro del coste computacional se debe implementar una metodología que permita descartar canales que no ofrezcan características ampliamente diferenciables entre un estado y otro.

Realizar una implementación del sistema de detección de manera online debe ser el siguiente paso. Detectar somnolencia en tiempo real permitirá la formulación de aplicaciones con base a los sistemas aquí propuestos.

La transformada de Wavelet multinivel podría ofrecer características de la señal más significativas teniendo en cuenta que el EEG es una señal no estacionaria, se propone usar el banco de filtros no solo en el bloque de preprocesamiento, sino que también en el bloque de procesamiento.

Realizar estudios que permitan hacer una clasificación interpersonal y detectar somnolencia en diferentes personas con un solo entrenamiento del algoritmo, esto tiene algunas implicaciones éticas pues requiere que se hagan estudios con diferentes individuos por lo que requiere especial atención.

Mejorar el procesamiento de datos después de la predicción del clasificador y aumentar la exactitud del sistema.

Integrar el sistema de detección aquí propuesto en dispositivos computacionales portables como Raspberry PI, Beagle Bone o Intel Galileo.

11. BIBLIOGRAFÍA

- Alipoor, M., Pooyan, M., & Suratgar, A. A. (2010). Classification of EEG signals in four groups, including healthy subjects with open/closed eyes and epilepsy subjects with/without seizure by PSD estimate (using the multitaper method) and ANN. *Health Informatics and Bioinformatics (HIBIT), 2010 5th International Symposium on*, (págs. 98-103).
- Alonso, I. D. (9 de 2016). *Claves para dormir bien*. (W. T. centro médico online, Editor) Obtenido de <http://www.webconsultas.com/belleza-y-bienestar/habitos-saludables/si-no-dormimos-bien-que-sucede-7135>
- AlSharabi, K., Ibrahim, S., Djemal, R., & Alsuwailem, A. (March de 2016). A DWT-entropy-ANN based architecture for epilepsy diagnosis using EEG signals. *2016 2nd International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)*, (págs. 288-291).
- Ambulkar, N. K., & Sharma, S. N. (Sept de 2015). Detection of epileptic seizure in EEG signals using window width optimized S-transform and artificial neural networks. *2015 IEEE Bombay Section Symposium (IBSS)*, (págs. 1-6).
- Bengio, Y., Courville, A., & Vincent, P. (Aug de 2013). Representation Learning: A Review and New Perspectives. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 35(8), 1798-1828.
- Bermúdez, G. R., Laencina, P. J., González, J. L., González, J. R., & Dorda, J. R. (April de 2012). Técnicas de reconocimiento de patrones para la clasificación de señales EEG en sistemas BCI. En U. P. de Cartagena (Ed.), *V Jornadas de Introducción a la investigación en la UPCT 2012*, 5, pág. 3. Obtenido de <http://hdl.handle.net/10317/2911>
- Bishop, C. M. (2007). *Pattern Recognition and Machine Learning* (6 ed.). (M. Jordan, Ed.) Springer.
- Buitinck, L., Louppe, G., Blondel, M. a., Mueller, A., Grisel, O. a., Prettenhofer, P., . . . Varoquaux, G. (2013). {API} design for machine learning software: experiences from the scikit-learn project. *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*, (págs. 108-122).
- Cano, E., Salcedo, R., & Soto, G. (2010). *Análisis de principios y aplicaciones de la transformada Wavelet*. unpublished.
- Chai, R., Naik, G., Nguyen, T. N., Ling, S., Tran, Y., Craig, A., & Nguyen, H. (2016). Driver Fatigue Classification with Independent Component by Entropy Rate Bound Minimization Analysis in an EEG-based System. *IEEE Journal of Biomedical and Health Informatics, PP(99)*, 1-1.
- Chai, R., Smith, M. R., Nguyen, T. N., Ling, S. H., Coutts, A. J., & Nguyen, H. T. (Aug de 2015). Comparing features extractors in EEG-based cognitive fatigue

- detection of demanding computer tasks. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (págs. 7594-7597).
- Daphne, R. R., & Raj, A. A. (2012). A Drowsiness Detection Architecture using Feature Extraction Methodology . *Procedia Engineering* , 38(0), 959-963. Obtenido de <http://www.sciencedirect.com/science/article/pii/S1877705812020346>
- Das, A. B., & Bhuiyan, M. I. (2016). Discrimination and classification of focal and non-focal {EEG} signals using entropy-based features in the EMD-DWT domain . *Biomedical Signal Processing and Control* , 29, 11-21. Obtenido de <http://www.sciencedirect.com/science/article/pii/S1746809416300465>
- de Medicina Avanzada (RIMA), R. I. (9 de 2016). Trastornos del sueño y afectividad: ¿cuál es la relación? Obtenido de <http://www.rima.org/Noticia.aspx?IdNota=3013>
- de Neurología, S. E. (2011). Características del sueño normal: Fases de sueño. Obtenido de <http://www.neurowikia.es/content/caracteristicas-del-sueno-normal-fases-de-sueno>
- de Servicios Forenses División de Referencia de Información Pericial, S. (12 de 2007). Boletín Epidemiológico Cuatrimestral DRIP. Obtenido de <http://www.medicinalegal.gov.co/documents/10180/28521/6+Boletin3deseptiembre2007.pdf/625a341d-1ac1-4d00-9022-05761666400f>
- Diaz, D. R. (2012). Módulo 3. Diagnóstico. *Epilepsia*. Obtenido de <http://www.neurodidacta.es/es/comunidades-tematicas/epilepsia/epilepsia/cuestiones-relativas-diagnostico/las-pruebas-electroencefalografia-eeg>
- Dkhil, M. B., Neji, M., Wali, A., & Alimi, A. M. (May de 2015). A new approach for a safe car assistance system. *Advanced Logistics and Transport (ICALT), 2015 4th International Conference on*, (págs. 217-222). doi:10.1109/ICAdLT.2015.7136627
- Duda, R. O., Hart, P. E., & Stork, D. G. (2001). *Pattern Classification* (2 ed.). (W.-I. Publication, Ed.) Library of Congress Cataloging-in-publication Data.
- EMOTIV, I. (2014). *EMOTIV EPOC & TESTBENCH™ SPECIFICATIONS*. Tech. rep., EMOTIV Inc. Obtenido de <https://www.emotiv.com/files/Emotiv-EPOC-Product-Sheet-2014.pdf>
- EMOTIV, I. (2015). *Comparison Chart - Epoc+ vs Insight*. Tech. rep., EMOTIV Inc. Obtenido de <https://www.emotiv.com/comparison/>
- EMOTIV, I. (2016). *EMOTIV EPOC+ 14 Channel Mobile EEG*. Tech. rep., EMOTIV Inc. Obtenido de <https://www.emotiv.com/product/emotiv-epoc-14-channel-mobile-eeg/>

- Espectador, E. (Ed.). (2 de 2009). Cerca de la mitad de accidentes de tránsito se producen por sueño. Obtenido de <http://www.lespectador.com/noticias/salud/articulo118647-cerca-de-mitad-de-accidentes-de-transito-se-producen-sueno>
- for Genomics, I., & Bioinformatics. (2008). *Cross-Validation Explained*. Tech. rep., Graz University of Applied Sciences. Obtenido de <http://genome.tugraz.at/proclassify/help/pages/XV.html>
- Garcés C., A., Orosco, L., & Laciari, E. (2014). Automatic detection of drowsiness in EEG records based on multimodal analysis. *Medical Engineering & Physics*, 36, 244-249.
- Garcés Correa, A. (2011). *Procesamiento de Señales cerebrales para la Detección de Somnolencia en Conductores*. Ph.D. dissertation, Universidad Nacional de San Juan.
- Garcés Correa, A., & Laciari Leber, E. (Aug de 2010). An automatic detector of drowsiness based on spectral analysis and wavelet decomposition of EEG records. *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*, (págs. 1405-1408).
- Garcés, A., Orosco, L., & Laciari, E. (2014). Automatic detection of drowsiness in \{EEG\} records based on multimodal analysis . *Medical Engineering & Physics* , 36(2), 244-249. Obtenido de <http://www.sciencedirect.com/science/article/pii/S1350453313001690>
- Gil-Nagel A, P. J. (2002). Manual de electroencefalografía. McGraw-Hill Interamericana. 1ª ed. en español.
- Guerrero Martínez, J. F. (2010). Tema 4: Procesado Digital de Bioseñales. Escola Tècnica Superior d' Enginyeria. Obtenido de http://ocw.uv.es/ingenieria-y-arquitectura/1-5/ib_material/IB_T4_OCW.pdf
- Guerrero, G. L., Dimas, V. K., Parra, V. L., & Pérez, F. J. (2015). EL IMPACTO DEL INSOMNIO EN EL RENDIMIENTO ACADÉMICO. *REVISTA DE PSICOLOGÍA Y CIENCIAS DEL COMPORTAMIENTO DE LA UACJS*, 5, 46-59.
- Guo, C., Lu, F., Liu, S., & Xu, W. (Dec de 2015). Sleep EEG Staging Based on Hilbert-Huang Transform and Sample Entropy. *2015 International Conference on Computational Intelligence and Communication Networks (CICN)*, (págs. 442-445).
- Hazarika, N., Tsoi, A. C., & Sergejew, A. (Apr de 1997). Nonlinear considerations in EEG signal classification. *Signal Processing, IEEE Transactions on*, 45(4), 829-836.

- Ingle, V., & Proakis, J. (2011). *Digital Signal Processing Using MATLAB*. Cengage Learning. Obtenido de <https://books.google.com.co/books?id=kZkIAAAQBAJ>
- Jo, J., Lee, S. J., Park, K. R., Kim, I.-J., & Kim, J. (2014). Detecting driver drowsiness using feature-level fusion and user-specific classification. *Expert Systems with Applications*, 41(4, Part 1), 1139-1152. Obtenido de <http://www.sciencedirect.com/science/article/pii/S0957417413006106>
- Kandel, E. R., Schwartz, J. H., Jessell, T. M., Siegelbaum, S. A., & Hudspeth, A. J. (2000). *Principles of neural science* (Vol. 4). McGraw-hill New York.
- Lerga, J., Saulig, N., Mozetic, V., & Lerga, R. (July de 2016). Number of EEG signal components estimated using the short-term Renyi entropy. *2016 International Multidisciplinary Conference on Computer and Energy Science (SpliTech)*, (págs. 1-6).
- Li, P., Yan, C., Karmakar, C., & Liu, C. (2015). Distribution entropy analysis of epileptic EEG signals. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (págs. 4170-4173).
- Malo, D. J., & de Castro Fernandez, R. M. (2002). *Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Fundamentos*. unpublished.
- Martínez, M., Gómez, L., Serrano, A. J., Vila, J., & Gómez, J. (2009). 2.- Revisión de los tipos de filtros analógicos más comunes. VNIVERSITAT DE VALÈNCIA Escola Tècnica Superior d' Enginyeria. Obtenido de http://ocw.uv.es/ingenieria-y-arquitectura/filtros-digitales/tema_2._revisio_n_de_los_tipos_de_filtros_analogicos_mas_comunes.pdf
- Merzagora, A. C., Bunce, S., Izzetoglu, M., & Onaral, B. (Aug de 2006). Wavelet analysis for EEG feature extraction in deception detection. *Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE*, (págs. 2434-2437).
- Ming, M., Shaona, L., Haitao, M., Yuliang, M., & Yunyuan, G. (July de 2015). Feature extraction method of motor imagery EEG based on DTCWT sample entropy. *Control Conference (CCC), 2015 34th Chinese*, (págs. 3964-3968).
- Murugavel, A., Ramakrishnan, S., Balasamy, K., & Gopalakrishnan, T. (Dec de 2011). Lyapunov features based EEG signal classification by multi-class SVM. *Information and Communication Technologies (WICT), 2011 World Congress on*, (págs. 197-201).
- Navarro, R. B. (2010). Tema 3: Sistemas de Acondicionamiento y Adquisición de Señales Bioeléctricas. En *Instrumentación Biomédica*. UNIVERSIDAD DE

- ALCALÁ - DEPARTAMENTO DE ELECTRÓNICA. Obtenido de <http://www.depeca.uah.es/depeca/repositorio/asignaturas/5/Tema3.PDF>
- Navarro, R. B. (2011). Tema 5: Electroencefalografía. En *Instrumentación Biomédica*. UNIVERSIDAD DE ALCALÁ - DEPARTAMENTO DE ELECTRÓNICA. Obtenido de <http://www.bioingenieria.edu.ar/academica/catedras/bioingenieria2/archivos/apuntes/tema%205%20-%20electroencefalografia.pdf>
- Pajares, M. G., & de la Cruz Garcia, J. M. (2011). *Aprendizaje Automático* (1 ed.). (E. de la U, Ed.) Ra-ma Editorial.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., . . . Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Pereyra, J. S. (2011). *Métodos en neurociencias cognoscitivas*. Editorial El Manual Moderno.
- Pérez, C. (9 de 2016). *Somnolencia: Síntomas, causas y tratamiento*. (COSMOPOLITAN, Editor) Obtenido de <http://www.natursan.net/somnolencia-sntomas-causas-y-tratamiento/>
- Phothisonothai, M., & Nakagawa, M. (Aug de 2008). EEG signal classification method based on fractal features and neural network. *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, (págs. 3880-3883).
- Portellano, J. A. (2005). *Introducción a la neuropsicología*. Madrid: Universidad Complutense-McGrau-Hill. Interamericana.
- Proakis, J., & Manolakis, D. (2007). *Tratamiento digital de señales*. Pearson Educación. Obtenido de <https://books.google.com.co/books?id=8rhdNQAACAAJ>
- Rajeev, S., Bilas, P. R., & U., R. A. (2015). Application of Entropy Measures on Intrinsic Mode Functions for the Automated Identification of Focal Electroencephalogram Signals. *Entropy*. Obtenido de <http://www.mdpi.com/1099-4300/17/2/669>
- Rodríguez, O. J., & Bueno, D. A. (2010). DETERMINACIÓN DE LOS PARÁMETROS ASOCIADOS AL FILTRO WAVELET POR UMBRALIZACIÓN APLICADO A FILTRADO DE INTERFERENCIAS ELECTROCARDIOGRÁFICAS. *REVISTA UIS INGENIERÍAS*, 6. Obtenido de <http://revistas.uis.edu.co/index.php/revistauisingenierias/article/viewFile/404/670>

- Russell, S. J., Norvig, P., Canny, J. F., Malik, J. M., & Edwards, D. D. (2003). *Artificial intelligence: a modern approach* (Third ed., Vol. 2). Prentice hall Upper Saddle River.
- saludemia (Ed.). (9 de 2016). *Descanso y sueño - Lo fundamental - Trastornos del sueño*. Obtenido de <http://www.saludemia.com/-/vida-saludable-descanso-sueno-lo-fundamental-trastornos-del-sueno>
- Samir Kouro, R., & Rodrigo Musalem, M. (7 de 2002). Tutorial introductorio a la Teoría de Wavelet. *Técnicas Modernas en Automática*.
- Sanei, S., & Chambers, J. A. (2013). *EEG signal processing*. John Wiley & Sons.
- Sinha, A., Chatterjee, D., Das, R., Datta, S., Gavas, R., & Saha, S. K. (2015). Artifact Removal from EEG Signals Recorded Using Low Resolution Emotiv Device. *Systems, Man, and Cybernetics (SMC), 2015 IEEE International Conference on*, (págs. 1445-1451).
- Sun, S., & Zhou, J. (July de 2014). A review of adaptive feature extraction and classification methods for EEG-based brain-computer interfaces. *Neural Networks (IJCNN), 2014 International Joint Conference on*, (págs. 1746-1753).
- Tandle, A., & Jog, N. (2015). Classification of Artefacts in EEG Signal Recordings and Overview of Removing Techniques. *International Journal of Computer Applications*. Obtenido de <http://research.ijcaonline.org/icct2015/number7/icct201595.pdf>
- Targa, A., & Vila, M. (#feb# de 2007). *Impacto de la Privación de Sueño en las Funciones Cognitivas y las Constantes Basales*. Master's thesis, Aula Escola Europea. Obtenido de <http://www.aula-ee.com/escola/sites/aula-ee.com.escola/files/content/arxiu/Impacto%20de%20la%20privaci%C3%B3n%20de%20sue%C3%B1o.pdf>
- Tiempo, E. (Ed.). (4 de 2004). QUÉ SUCEDE CUANDO DORMIMOS. Obtenido de <http://www.eltiempo.com/archivo/documento/MAM-1554134>
- Torres, D. C. (9 de 2016). *Trastornos del sueño*. (C. U. de Navarra, Editor) Obtenido de <http://www.cun.es/enfermedades-tratamientos/enfermedades/trastornos-sueno>
- Wang, Z., Quan, X., Gong, D., & Yu, C. (Sept de 2008). Study of signal processing system for Electroencephalogram based on TMS320LF2407. *Automation Congress, 2008. WAC 2008. World*, (págs. 1-4).
- www.ehu.eus. (9 de 2016). *Resumen de las Características de los Filtros Analógicos de Butterworth y Chebyshev*. Obtenido de <http://www.ehu.eus/Procesadodesenales/tema6/tx33.html>

- www.pybytes.com. (8 de 2012). *Discrete Wavelet Transform (DWT)*. (S. 1.1.3, Editor) Obtenido de <http://www.pybytes.com/pywavelets/ref/dwt-discrete-wavelet-transform.html#maximum-decomposition-level-dwt-max-level>
- www.pybytes.com. (8 de 2012). *Inverse Discrete Wavelet Transform (IDWT)*. (S. 1.1.3, Editor) Obtenido de <http://www.pybytes.com/pywavelets/ref/idwt-inverse-discrete-wavelet-transform.html>
- Yeo, M. V., Li, X., Shen, K., & Wilder-Smith, E. P. (2009). Can SVM be used for automatic EEG detection of drowsiness during car driving? *Safety Science* , 47(1), 115-124. Obtenido de <http://www.sciencedirect.com/science/article/pii/S0925753508000246>
- Yu, W., Zhuang, F., He, Q., & Shi, Z. (2015). Learning deep representations via extreme learning machines . *Neurocomputing* , 149, Part A(0), 308-315. Obtenido de <http://www.sciencedirect.com/science/article/pii/S0925231214011461>