

Benemérita Universidad Autónoma de Puebla  
Facultad de Ciencias de la Computación



**MÉTODO DE CLASIFICACIÓN PARA DETECCIÓN  
DE ESTRÉS EMPLEADO  
ELECTROENCEFALOGRAMA**

**T E S I S**

PARA OBTENER EL TÍTULO DE:

**Licenciado en Ciencias de la Computación**

P R E S E N T A:

**Ivan Colula Medel**

A S E S O R E S:

**Dra. Maya Carillo Ruiz**

**Dr. Luis Enrique Colmenares Guillen**

Heroica Puebla de Zaragoza, diciembre 2018

*A mi familia que siempre estuvo ahí para apoyarme.  
A mis profesores, amigos y todos aquellos que me formaron en esta etapa  
de mi vida.*

# Agradecimientos

*A mis padres y hermanos que siempre han estado ahí para guiarme y apoyarme pese a todas las dificultades que surgieron en mi camino. Gracias por ser el pilar más importante de mi vida, porque sin ustedes nada de esto sería posible pues me han dado algo invaluable conseguido con el sacrificio de todos, siempre encontraré un refugio en sus brazos y sabias palabras. Muchas gracias por su esfuerzo, cariño y sobre todo por su amor incondicional.*

*A mis profesores por ser partícipes de mi formación profesional y personal, por sus enseñanzas dentro y fuera del aula de clases. Al esfuerzo, dedicación y compromiso con el que imparten sus conocimientos para formar profesionales de calidad, pero sobre todo por sembrar en mi la semilla de la curiosidad que personalmente considero de gran importancia para seguir aprendiendo. Por sus palabras, pues en más de una ocasión estas llegan en el momento adecuado.*

*A mis amigos, compañeros y todos aquellos con los que he compartido esta bonita etapa de mi vida, por las risas, las bromas, enseñanzas y momentos de complicidad que pasamos juntos, por todo lo anterior gracias.*

*A mi asesora por enseñarme a pensar de forma diferente, por no imponerme su forma de ver el mundo y darme la posibilidad de desarrollarme libremente, encausando mi camino solo cuando era necesario y sobre todo por haber creído en mí.*

*A todos los que en algún momento ayudaron en mi formación, Muchas Gracias.*

# Resumen

La presente investigación tuvo como objetivo desarrollar e implementar un método para detección de estrés empleando electroencefalograma. Para lograrlo se tomó el Electroencefalograma (EEG) a 25 participantes con la diadema Emotiv Epoc plus. Además, a dichos participantes, se les aplicó el test “Escala de Estrés Percibido”(PSS), que mide el estrés general. Los participantes fueron estudiantes Universitarios de la Benemérita Universidad Autónoma de Puebla con una edad promedio de 24 años.

Una vez obtenidas las señales EEGs de cada participante se analizaron con un software desarrollado en matlab. El software implementa tres familias wavelet: coiflet, Daubichies y biorthogonal. Posteriormente se tomaron los coeficientes wavelet que corresponden a las frecuencias beta, pues el estrés se produce a frecuencias altas de las ondas beta. Dichos coeficientes se etiquetaron de acuerdo a los resultados obtenidos por el test PSS en dos clases: estrés bajo y estrés alto. Ya etiquetados los coeficientes se clasificaron utilizando weka y los siguientes algoritmos de aprendizaje automático: máquinas de soporte vectorial(SVM), random forest y naive bayes .

Los mejores resultados se obtuvieron utilizando coiflet de orden 1 para descomponer la señal y random forest para la clasificación, obteniendo un 70.25 % de precisión.

# Índice general

<b>Índice</b>	<b>V</b>
<b>Lista de figuras</b>	<b>VI</b>
<b>Lista de tablas</b>	<b>VIII</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Objetivo General .....	2
1.2. Objetivos Específicos .....	2
<b>2. Marco Teórico</b>	<b>3</b>
2.1. La Neurona.....	3
2.2. Encéfalo .....	4
2.2.1. Hemisferio Cerebral y Corteza Cerebral .....	5
2.3. Electroencefalograma .....	9
2.4. Sistema de electrodos 10-20 de la Federación Internacional .....	10
2.5. Estrés .....	13
2.6. Transformada Wavelet Discreta.....	16
2.7. Aprendizaje Automático .....	18
2.7.1. SVM .....	19
2.7.2. Naive Bayes.....	20
2.7.3. Random Forest .....	21
<b>3. Estado del Arte</b>	<b>23</b>
3.0.1. Electroencefalograma y estrés .....	24
<b>4. Método propuesto</b>	<b>28</b>
4.1. Infraestructura .....	28
4.2. Adquisición de EEG .....	29
4.3. Preprocesamiento.....	31
4.4. Extracción de características .....	32

4.5. Selección de características .....	33
4.6. Clasificación de características .....	34
4.7. Aplicación que implementa el método propuesto .....	37
<b>5. Experimentos y Resultados</b>	<b>42</b>
5.1. Experimentos con todos los canales EEG.....	42
5.2. Experimentos con canales EEG izquierdos.....	46
5.3. Experimentos con canales EEG derechos .....	47
<b>6. Conclusiones y Trabajo Futuro</b>	<b>49</b>
<b>A. Escala de Estrés Percibido (PSS) y División del Estrés en Dos Clases</b>	<b>55</b>
<b>B. Ejemplo del archivo arff generado</b>	<b>58</b>
<b>C. Código para analizar señales EEG</b>	<b>60</b>

# Índice de figuras

2.1. Regiones del Encéfalo [Kandel et al., 2001].	5
2.2. Lobulos del cerebro [Kandel et al., 2001].	6
2.3. Vista lateral del cráneo para mostrar los métodos de medición de nasion ainion en la línea media [Klem et al., 1999].	11
2.4. Vista frontal del cráneo que muestra el método de medición para la línea central de electodos [Klem et al., 1999].	11
2.5. Vista superior con una sección transversal del cráneo [Klem et al., 1999].	12
2.6. La vista lateral de los hemisferios izquierdo y derecho que muestra todas las posiciones estándar de los electodos, omitiendo las posiciones intermedias [Klem et al., 1999].	13
2.7. Algoritmo piramidal o codificación sub-banda. Descomposición de la señal $x$ a través de filtros pasa bajos ( $H$ ) y pasa altos ( $G$ ) con submuestreo por 2 obteniendo coeficientes de detalle ( $d_1$ ) y aproximación ( $c_1$ ) repitiéndose el proceso dependiendo el nivel de descomposición de la señal y reconstrucción de la señal siguiendo el procedimiento descrito anteriormente en sentido inverso, de modo que las señales son interpolada por 2 ( $d_n$ y $c_n$ ) y pasada a través de los filtros de síntesis pasa altos ( $g^*[x]$ ) y pasa bajos ( $h^*[x]$ ) para posteriormente sumarse ambas salidas, repitiéndose el proceso por cada nivel, hasta reconstruir la señal $x$ . [de Castro Fernández, 2002].	18
2.8. Frontera de decisión entre clases [Betancourt, 2005].	20
4.1. Electroencefalógrafo Emotiv Epoc Plus.	29
4.2. Software Utilizado: Emotiv Pro, Matlab R2015b, IBM SPSS 25, Weka 3.8.	29
4.3. Software para adquirir datos sin procesar de diadema Emotiv Epoc Plus.	31
4.4. Diagrama de codificación en sub-bandas.	33
4.5. Captura de las preguntas del cuestionario Perceived Stress Scale (PSS) de Cohen.	35

4.6.	Puntuación de estrés percibido de cada participante. ....	36
4.7.	Clases generadas: Estrés bajo y Estrés alto. ....	37
4.8.	Método propuesto para detección de estrés usando EEG. ....	37
4.9.	Interfaz que permite cargar los datos sin procesar de la diadema Emotiv Epoc Plus. ....	38
4.10.	Interfaz que permite seleccionar wavelet, canales y umbrales para eliminar ruido en la señal. ....	39
4.11.	Interfaz que permite seleccionar el etiquetado de las señales EEG. ....	40
4.12.	Interfaz que une los archivos arff con los que se trabaja en un solo archivo. ....	41
5.1.	Proceso de análisis de las señal usando todas las señales del cerebro usando distintos parámetros. ....	44
5.2.	Resultados de la clasificación tomando en cuenta todas las señales EEG con diferentes algoritmos de aprendizaje automático.....	45
5.3.	Resultados de la clasificación tomando en cuenta las señales EEG del hemisferio izquierdo usando diferentes algoritmos de aprendizaje automático. ....	47
5.4.	Resultados de la clasificación tomando en cuenta las señales EEG del hemisferio derecho usando diferentes algoritmos de aprendizaje automático. ....	48
6.1.	Precisión de cada experimento usando diferentes wavelet y algoritmos de aprendizaje automático. ....	49
A.1.	Puntos de corte generados automáticamente en el software IBM SPSS para crear las clases: estrés bajo y estrés alto .....	57



# Índice de tablas

4.1. Frecuencias en las que se divide la actividad cerebral.....	32
5.1. Resultados de la clasificación tomando todas las señales, usando las tres wavelet seleccionadas y los 3 algoritmos de aprendizaje utilizados .....	45
5.2. Resultados de la clasificación usando las 7 señales del lado izquierdo del cerebro, usando las tres wavelet seleccionadas y los 3 algoritmos de aprendizaje utilizados.....	46
5.3. Resultados de la clasificación usando las 7 señales de la derecha del cerebro, usando las tres wavelet seleccionadas y los 3 algoritmos de aprendizaje utilizados.....	48
6.1. Precisión de la clasificación en ordenados descendente. ....	51

# Capítulo 1

## Introducción

Actualmente el estrés es uno de los problemas que más padecen los mexicanos en el ámbito laboral y escolar, la exposición a largos periodos de estrés degrada el estado general de salud, esto se puede confirmar en publicaciones como la realizada por el semanario de la Universidad Autónoma Metropolitana (UAM), donde exponen la investigación de Pulido Navarro [Navarro et al., 2012, ?]. Dicha investigación fue realizada a un grupo de trabajadoras de la industria maquiladora, este grupo al estar expuesto a un estrés prolongado mostró en las mujeres niveles disminuidos de anticuerpos, tal situación concordaba con una presencia elevada de padecimientos inflamatorios: faringitis, amigdalitis y sinusitis, así como depresión, ansiedad, trastornos del sueño, problemas cardiocirculatorios, psicosomáticos y digestivos. Los problemas mencionados, ocasionan males crónico degenerativos por los que mueren miembros de la clase trabajadora del país [Navarro et al., 2012].

Otro estudio relacionado al estrés que nos muestra la importancia de su estudio, fue el realizado a estudiantes universitarios en la ciudad de México [Ramírez and Hernández, 2007]. En este estudio se tomaron en cuenta diversos estresores como: el desempeño en la escuela, el proceso de adaptación al ambiente universitario para los recién egresados, las exigencias de sus estudios, la preocupación por su futuro, exámenes, la espera de calificaciones, selección de horarios. Al final del estudio, una de las conclusiones de éste es que un adecuado manejo del estrés es importante debido a que los estudiantes con mayores niveles de estrés tienen menores expectativas de terminar sus estudios con éxito y están menos preparados para enfrentar el mundo laboral.

En los artículos analizados anteriormente, podemos darnos cuenta de la importancia que tiene el estudio del estrés en México, pues repercute en la salud física y mental de los involucrados, cualquier persona puede desarrollar estrés crónico donde factores como el ambiente o entorno propician condicio-

nes para que este tenga mucho más efectos dañinos que positivos.

Todo lo expuesto con anterioridad motiva a estudiar el estrés desde distintas perspectivas y desarrollar un método para detección de estrés mediante el uso del electroencefalograma.

A continuación se presenta la organización de este trabajo, donde se desarrolla el método para detección de estrés mencionado anteriormente. En el capítulo 2 se presentan los conceptos utilizados, el capítulo 3 muestra estudios que se relacionan con señales EEG y estrés, posteriormente el capítulo 4 expone el método propuesto para analizar señales EEG de participante con estrés, seguido del capítulo 5 donde se exponen los resultados de los experimentos realizados. Por último el capítulo 6 muestra las conclusiones obtenidas en base al trabajo realizado y el trabajo futuro en esta área de investigación.

## **1.1. Objetivo General**

Desarrollar un método para procesar señales de electroencefalograma, con el objetivo de verificar si una persona sufre estrés.

## **1.2. Objetivos Específicos**

1. Seleccionar el cuestionario para detección de estrés.
2. Diseñar el protocolo para elección de participantes.
3. Determinar la plataforma y el dispositivo para la adquisición de señales EEG.
4. Determinar el mecanismo de procesamiento de las señales EEG.
5. Elegir el algoritmo de aprendizaje automático adecuado para clasificar las señales EEG.
6. Implementar una herramienta de software para el análisis de señales EEG.

# Capítulo 2

## Marco Teórico

En este capítulo se presentan los conceptos relevantes que ayudan a entender la parte teórica de los experimentos realizados en este trabajo, estos fueron tomados de distintas áreas del conocimiento como las ciencias sociales, ciencias de la salud y matemáticas.

En la siguiente sección se describe cada concepto de forma breve, los conceptos presentados son: neurona, encéfalo, corteza cerebral, lóbulos, electroencefalograma, sistema internacional 10-20, estrés, transformada wavelet discreta y aprendizaje automático.

### 2.1. La Neurona

La neurona es una célula y es la unidad básica estructural y funcional del sistema nervioso humano. Se estima que un humano tienen  $10^{10}$  neuronas. La función de la neurona es recibir e integrar información que proviene de receptores sensitivos u otras neuronas y transmitir información a otras neuronas u órganos efectores. La neurona está altamente especializada pues cada neurona es una entidad independiente con una membrana celular que la limita. La información se transmite entre neuronas en regiones especializadas denominadas sinapsis [A. R. Crossman, 2007].

Una neurona típica tiene cuatro regiones definidas morfológicamente: el cuerpo celular, las dendritas, el axón y las terminales presinápticas. Cada una de estas regiones desempeña una función diferenciada en la generación de señales y la comunicación entre neuronas.

El cuerpo celular (soma) es el centro metabólico de la célula. El cuerpo celular habitualmente es el origen de dos clases de prolongaciones: varias dendritas cortas y un único axón largo, tubular. Las dendritas se ramifican como un árbol y son la parte principal de recepción de señales procedentes

de otras neuronas. Por el contrario el axón sale del cuerpo celular y es la principal unidad de conducción de señales a otras neuronas. Un axón puede transmitir señales eléctricas a distancias que oscilan entre 0.1 mm y 3 mm. Estas señales eléctricas, denominadas potenciales de acción, son impulsos nerviosos rápidos, fugaces, todo o nada, con una amplitud de  $100mV$  y una duración aproximada de  $1ms$ .

Los potenciales de acción viajan a velocidades de entre 1 y 100 m por segundo. Los potenciales de acción constituyen las señales mediante las cuales el cerebro recibe, analiza y transmite información [Kandel et al., 2001].

La información es codificada dentro de las neuronas mediante cambios de energía eléctrica. La neurona en reposo posee un potencial eléctrico (potencial de reposo) a través de su membrana del orden de  $60 - 70mV$ , siendo el interior negativo respecto al exterior. Cuando una neurona es estimulada o excitada por encima de un cierto nivel de umbral, hay una breve inversión de la polaridad del potencial de su membrana, denominada potencial de acción. Los potenciales de acción se propagan a lo largo del axón e invaden las terminales nerviosas. La transmisión de información entre neuronas casi siempre ocurre mediante medios químicos antes que eléctricos [A. R. Crossman, 2007].

## 2.2. Encéfalo

El encéfalo es la masa nerviosa contenida dentro del cráneo y forma parte del sistema nervioso central. Esta compuesto de seis regiones, cada una de ellas se puede subdividir en varias áreas diferenciadas desde el punto de vista anatómico y funcional, las seis partes principales del encéfalo son el bulbo, la protuberancia, el cerebelo, el mesencéfalo, el diencéfalo y los hemisferios cerebrales o telencéfalo, cada una de estas divisiones se encuentra en los dos hemisferios del encéfalo, pero pueden diferir en su tamaño y su forma (figura: 2.1).

El encéfalo esta dominado por los voluminosos hemisferios cerebrales (hemisferio derecho e izquierdo), la superficie de estos no es lisa, sino que tiene unas arrugas o salientes llamadas circunvoluciones y unos surcos denominados cisuras. Los hemisferios tienen un manto externo de sustancia gris muy replegada conocida como corteza cerebral, compuesta por neuronas (materia gris) y un núcleo interno de sustancia blanca que se dirigen tanto a otras partes del cerebro como al resto del cuerpo (materia blanca). Los dos hemisferios cerebrales están incompletamente separados por la gran fisura longitudinal del cerebro y en su profundidad se sitúan el cuerpo caloso, que contiene fibras comisurales que unen regiones correspondientes de los dos hemisferios [A. R. Crossman, 2007, Kandel et al., 2001].

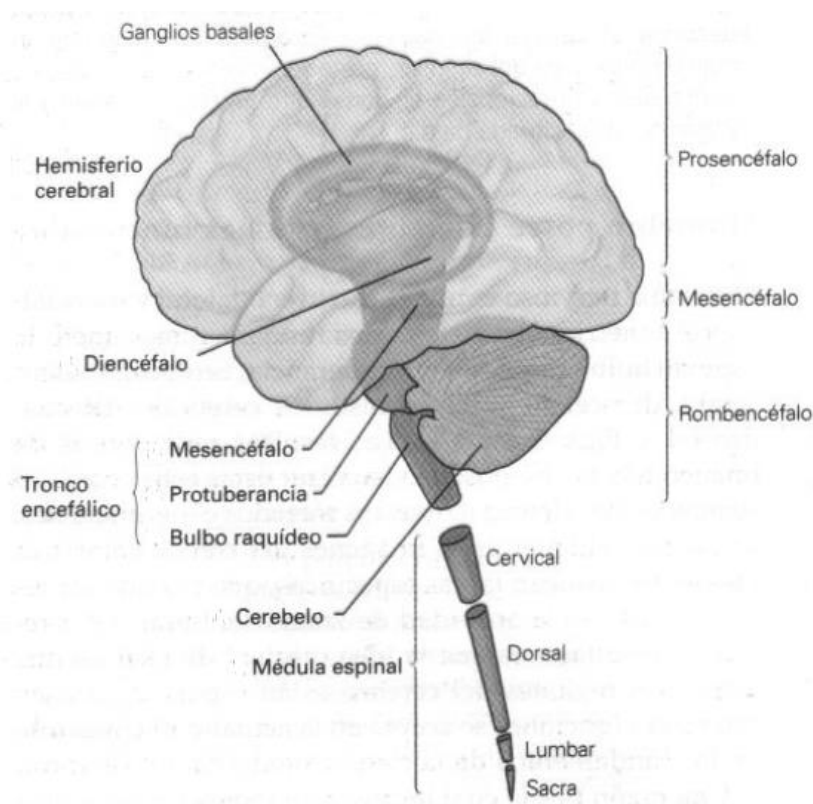


Figura 2.1: Regiones del Encéfalo [Kandel et al., 2001].

### 2.2.1. Hemisferio Cerebral y Corteza Cerebral

El encéfalo está constituido en su gran mayoría por dos mitades, la mitad derecha llamada hemisferio derecho y la mitad izquierda llamada hemisferio izquierdo. Ambos hemisferios están conectados entre sí por una estructura denominada Cuerpo Calloso, formado por millones de fibras nerviosas que recorren todo el cerebro.

Superficialmente, el hemisferio cerebral consta de una capa de sustancia gris, la corteza cerebral, que está muy replegada para formar un complejo patrón de relieves (giros o circunvoluciones) y depresiones (surcos). Éstos sirven para ampliar al máximo el área de la superficie de la corteza cerebral, de la que casi un 70 % se oculta en la profundidad de los surcos. Por debajo de la superficie, los axones que discurren hacia y desde las células de la corteza forman una extensa masa de sustancia blanca. Los dos hemisferios cerebrales están separados por una profunda hendidura, la gran fisura longitudinal del cerebro [A. R. Crossman, 2007].

### Lóbulos del hemisferio cerebral

Algunos giros o circunvoluciones y surcos de la superficie del hemisferio son constantes en su localización entre diferentes individuos, por lo que forman la base para dividir el hemisferio en cuatro lóbulos, denominados lóbulos frontal, parietal, temporal y occipital (figura: 2.2). Sus principales características topográficas y su significación funcional se describen mas adelante [A. R. Crossman, 2007].




Figura 2.2: Lobulos del cerebro [Kandel et al., 2001].

### Corteza cerebral

La corteza cerebral forma la superficie externa del hemisferio cerebral. Consta de una capa de varios milímetros de espesor, compuesta por cuerpos de células nerviosas, arborizaciones dendríticas e interconexiones sinápticas. La corteza cerebral es necesaria para la noción de la conciencia y del pensamiento, la memoria y la inteligencia. Es la región a la que ascienden finalmente todas las modalidades sensitivas (la mayoría por vía del tálamo) y donde se perciben conscientemente e interpretan en relación con experiencias previas. La corteza cerebral es el nivel más elevado en el que está representado el sistema motor. Es aquí donde se generan e inician las acciones. La parte posterior del cerebro recibe información sensitiva del mundo exterior en las áreas sensitivas primarias del lóbulo parietal (somatosensorial o somestésica), lóbulo occipital (visión) y lóbulo temporal (audición). En zonas corticales adyacentes se elabora la información para permitir la identificación de objetos mediante el tacto, la visión y la audición, siendo un acto específico de

cada modalidad de percepción. Las áreas de la corteza en la unión de los tres lóbulos cerebrales, conocida como corteza de asociación, son críticas para el reconocimiento multimodal y espacial del medio ambiente. Las partes mediales del hemisferio cerebral (sistema límbico) hacen posible el almacenamiento y recuperación de la información procesada en regiones posteriores del hemisferio. La porción anterior del cerebro (lóbulo frontal) se encarga de la organización del movimiento (área motora principal; áreas premotora y motora suplementaria) y de la dirección estratégica del complejo comportamiento motor a lo largo del tiempo (área prefrontal). En la mayoría de los individuos, las áreas de la corteza de asociación de los lóbulos frontal, parietal y temporal del hemisferio izquierdo son responsables de la comprensión y expresión del lenguaje. El hemisferio izquierdo es, por tanto, considerado como dominante del lenguaje [A. R. Crossman, 2007].

### **Lóbulo frontal**

El lóbulo frontal se sitúa anterior al surco central, inmediatamente anterior al surco central, y corriendo paralelo a él, se encuentra el giro o circunvolución precentral. Funcionalmente, se le conoce como corteza motora primaria. El área de corteza destinada a una determinada parte corporal es proporcional, no a su tamaño, sino al grado de precisión con que pueden ejecutarse los movimientos. La función de esta región es el control de movimientos voluntarios y especializados, a veces descritos como movimientos fraccionados. Los movimientos evocados desde la corteza motora suplementaria tienden a ser de la naturaleza postural, e implican la musculatura axial y a la proximal de los miembros. Las áreas corticales premotoras se cree que actúan en la programación y preparación del movimiento y en el control de la postura. En el giro o circunvolución frontal media se sitúa el campo ocular frontal. Esta región controla la desviación conjugada voluntaria de la mirada, como ocurre cuando exploramos el campo visual. En el giro o circunvolución frontal inferior del hemisferio dominante (normalmente el izquierdo) se encuentra el área motora del lenguaje, también conocida como área de Broca. El área de Broca tiene importantes interconexiones con porciones de los lóbulos temporal, parietal y occipital homolaterales implicadas en el mecanismo del lenguaje. Las extensas regiones de la corteza del lóbulo frontal que se describen como la corteza pre-frontal tienen funciones cognitivas muy superiores, que incluyen facultades intelectuales, de discernimiento, predictivas y la planificación de la conducta [A. R. Crossman, 2007] .



### **Lóbulo parietal**

El lóbulo parietal se sitúa por detrás del lóbulo frontal y ésta rodeado posteriormente e inferiormente por los lóbulos occipital y temporal, respectivamente. Funcionalmente, esta región es la corteza somatosensorial primaria, donde terminan las neuronas talamocorticales, receptores periféricos de la sensibilidad general hacia un nivel consciente. El lobulillo parietal superior es el responsable de la interpretación de la información sensitiva general y de la noción consciente de la mitad contralateral del cuerpo. El lobulillo parietal inferior hace de conexión entre la corteza somatosensorial y las cortezas de asociación visual y auditiva de los lóbulos occipital y temporal, respectivamente, y contribuye a las funciones del lenguaje en el hemisferio dominante [A. R. Crossman, 2007]..

### **Lóbulo temporal**

La cara lateral del lóbulo temporal está dividida en giros o circunvoluciones temporales superior, media e inferior, que discurren paralelas al surco lateral. Dentro del giro o circunvolucion temporal superior se localiza la corteza auditiva primaria. La corteza auditiva primaria es responsable del la percepción consciente del sonido. Es crucial para la comprensión del lenguaje hablado y tiene importantes conexiones con otras áreas del lenguaje del encéfalo. La parte inferomedial del lóbulo temporal se curva hacia dentro para formar el hipocampo. Las funciones principales del hipocampo se encuentran relacionadas con la memoria y los aspectos emocionales de la conducta. Además el lóbulo temporal es responsables de la apreciación consciente del sentido del olfato [A. R. Crossman, 2007].

### **Lóbulo occipital**

El lóbulo occipital se sitúa por detrás de los lóbulos parietal y temporal. En la cara medial del hemisferio, el límite con el lóbulo parietal está marcado por el profundo surco parietooccipital. También en la cara medial, el surco calcarino indica la localización de la corteza visual primaria, que es la responsable de la percepción visual. Cada mitad lateral del campo visual está representada en la corteza visual primaria del hemisferio contralateral. El resto del lóbulo occipital constituye la corteza de asociación visual, esta región está implicada en la interpretación de las imágenes visuales [A. R. Crossman, 2007].

### 2.3. Electroencefalograma

Hans Berger, un psiquiatra alemán, fue pionero en el electroencefalograma (EEG) en humanos en 1924. El EEG es una técnica electrofisiológica para registrar la actividad eléctrica que surge del cerebro humano [Britton et al., 2016].

Dicho registro se realiza a través del cuero cabelludo mediante la colocación de electrodos de superficies e impresos en un papel en movimiento, por medio del electroencefalógrafo cuando se trata de un aparato convencional o en un monitor cuando se trata de un aparato computarizado o digital [Barros and Guardiola, 2006].

Dada su sensibilidad temporal, la principal utilidad del EEG está en la evaluación del funcionamiento cerebral dinámico. Se cree que el EEG es generado principalmente por neuronas piramidales corticales en la corteza cerebral que están orientadas perpendicularmente a la superficie del cerebro. La actividad neuronal detectable por el EEG es la suma de los potenciales postsinápticos excitadores e inhibidores de grupos relativamente grandes de neuronas que disparan sincrónicamente.

Una desafortunada realidad del EEG, es que la actividad cerebral puede verse afectada por otra actividad eléctrica generada por el cuerpo o en el ambiente. Para ser visto en la superficie del cuero cabelludo, los voltajes EEG minúsculos generados cerebralmente deben pasar primero filtros biológicos múltiples que reducen la amplitud de la señal de su fuente original. Los voltajes cerebrales deben atravesar el cerebro, el líquido cefalorraquídeo, las meninges, el cráneo y la piel antes de llegar al sitio de registro donde se encuentran. Además, otra actividad eléctrica generada biológicamente (por los músculos del cuero cabelludo, los ojos, la lengua e incluso el corazón) crea potenciales de voltaje masivo que con frecuencia afectan y oscurecen la actividad cerebral, a esta actividad eléctrica se le denomina artefacto. Los desprendimientos temporales de los electrodos de registro pueden afectar aún más el EEG, o incluso imitar los ritmos cerebrales y convulsiones. Los artefactos eléctricos biológicos y ambientales con frecuencia interfieren con la capacidad del intérprete para identificar con precisión tanto los ritmos normales como los patrones patológicos. Afortunadamente, los artefactos poseen muchas características distintivas que son fácilmente identificables por observadores cuidadosos y bien entrenados. Los filtros digitales también se pueden aplicar para reducir el artefacto en ciertos entornos, pero se deben usar con gran precaución ya que también filtran la actividad de EEG de interés y pueden distorsionar severamente las ondas de EEG [Britton et al., 2016].

Antes de iniciar la interpretación de un electroencefalograma (EEG), es indispensable el conocimiento de la actividad normal en las diferentes eda-

des y estados clínicos del paciente, así como la identificación de artefactos, problemas técnicos y patrones marginales [Barros and Guardiola, 2006].

## **2.4. Sistema de electrodos 10-20 de la Federación Internacional**

El electroencefalograma registra la actividad eléctrica del cerebro mediante electrodos colocados sobre el cuero cabelludo. Éstos electrodos siguen el estándar 10-20, que especifica la colocación de cada uno de ellos en las diferentes regiones cerebrales.

Las pautas para estandarizar la colocación de electrodos para EEG fueron presentadas en el reporte del Dr. Herbert H. Jasper en el segundo congreso internacional en París en 1949 [Klem et al., 1999], pautas que son seguidas en la técnica de colocación presentada a continuación:

La técnica de medición se basa en el estándar de puntos de referencia en el cráneo. Estos son el nasion, inion y los puntos preauriculares izquierdo y derecho la técnica que se describe a continuación es tomada de [Klem et al., 1999] donde se describen las mediciones que son realizadas para colocar los electrodos y explica su relación con la anatomía del cráneo.

La primera medición se realiza en el plano anteriorposterior a través del vértice craneal, desde el nasion hasta el inion. Esta medida se divide en 5 áreas separadas (figura: 2.3), la primera marca se coloca en el 10 por ciento de la medición total y se etiqueta como Fp. La segunda, tercera, cuarta y quinta marca se colocan a intervalos de 20 por ciento de la medición total y se etiquetan como F, C, P y O. Debe tenerse en cuenta que la marca O se ubicará al 10 por ciento de la medición por encima del inion. La expresión Fp, F, C, P y O representan las áreas frontopolar, frontal, central, parietal y occipital, respectivamente.

La medición lateral del plano coronal central comienza en el punto preauricular izquierdo a través de la marca del vértice C hasta el punto preauricular derecho (figura: 2.4). Se coloca una marca al 10 por ciento de esta medida sobre los puntos preauriculares y se etiqueta como T. La expresión T representa el área temporal. Las marcas se ubican al 20 por ciento de la medición lateral y se etiquetan con C a la izquierda y derecha, y se cruza la ubicación del vértice C.




Figura 2.3: Vista lateral del cráneo para mostrar los métodos de medición de nasion a inion en la línea media [Klem et al., 1999].




Figura 2.4: Vista frontal del cráneo que muestra el método de medición para la línea central de electrodos [Klem et al., 1999].

Luego se toma una medida circunferencial (figura: 2.5) sobre los lóbulos temporales desde la posición Fp de la línea media hasta la posición O de la línea media. Una marca está hecha al 10 % de esta medida que indica la posición del electrodo Fp izquierdo o derecho. Las marcas se realizan al 20 % de la medición y se denominan occipital frontal inferior, temporal media y posterior e izquierda o derecha (tenga en cuenta que las posiciones de los electrodos en el medio temporal están cruzadas). La medición restante del 10 % de las marcas occipitales izquierda y derecha sería la posición O de la línea media.




Figura 2.5: Vista superior con una sección transversal del cráneo [Klem et al., 1999].

Las mediciones anteroposteriores se toman desde la posición Fp izquierda y derecha a través de la posición lateral C hacia la posición O izquierda y derecha. Luego, esta medida se divide en partes iguales en un 25 % de las marcas y se etiqueta como lateral F, lateral C y lateral P. Las mediciones coronales anteriores se toman desde la posición frontal inferior izquierda y derecha a través de la posición F de la línea media y dividida en segmentos del 25 %, haciendo cruces en el frontal lateral izquierdo, el vértice F y las posiciones frontales laterales derechas. Una medida coronal posterior se toma de la marca temporal posterior izquierda a través de la posición P en la línea media y esto también se divide en segmentos de 25 por ciento y las marcas se etiquetan como P lateral izquierda, línea media P y P lateral derecha (figura: 2.6).

Las mediciones descritas anteriormente indican la ubicación de los electrodos para el sistema 10-20 es importante mencionar que los electrodos se nombran en términos anatómicos de las áreas corticales registradas, excepto los electrodos C que están ubicados en el surco central. Además utilizaron un sistema de numeración para diferenciar la región izquierda y derecha, números impares para el hemisferio izquierdo, Fp1, F3, F7, C3, T3, P3, T5 y O1. Números pares para el hemisferio derecho, Fp2, F4, F8, C4, T4, P4, T6 y O2. originalmente se llamó a los electrodos de vértice F, C y P como F0, C0 y P0, pero luego cambió a Fz, Cz y Pz (z para cero).




Figura 2.6: La vista lateral de los hemisferios izquierdo y derecho que muestra todas las posiciones estándar de los electrodos, omitiendo las posiciones intermedias [Klem et al., 1999].

## 2.5. Estrés

El estudio del estrés ha generado una gran cantidad de investigaciones por parte de la comunidad científica debido a los efectos psicofisiológicos que provoca en los seres vivos en general, efectos que pueden ser positivos (eustres) o negativos (distres) pero que se originan debido a que el ser vivo que los experimenta puede percibir una situación como peligrosa o amenazante para su supervivencia e integridad, pero también estos efectos han ayudado a la supervivencia y adaptación de los mismos.

Sin embargo, el estrés no siempre tiene una connotación negativa. De acuerdo a Hans Selye [Selye, 1936, Selye et al., 1950, Selye et al., 1952] es una respuesta específica y normal del organismo a una demanda del ambiente externo. En otras palabras, es una respuesta a cualquier situación física, biológica o psicosocial que el sujeto deba afrontar, debido a que el estrés no es el estímulo sino la reacción a éste. Así mismo el estrés es una forma que el sujeto tiene para enfrentar las demandas de su entorno, permitiéndole adaptarse y sobrevivir. Por lo tanto, el estímulo estresante puede generar una respuesta positiva o una negativa. Esta última respuesta depende de la capacidad del individuo para encontrar los recursos necesarios para hacer frente a una situación de emergencia, cuando esta capacidad es rebasada puede desencadenar patología psicosomática y agotamiento funcional. Como el estrés puede tener efectos negativos o positivos en el organismo, pasaremos

al estudio de trabajos donde se estudian solo los efectos negativos.

Estas investigaciones inician en 1930, Hans Selye un joven de origen austriaco, estudiante del segundo año en la carrera de medicina de la Universidad de Praga desarrolla una serie de experimentos con ratas, los cuales demuestran que si un organismo vivo está seriamente dañado por agentes inespecíficos como la exposición al frío, lesiones quirúrgicas o intoxicaciones con dosis que no son letales para este, aparece un síndrome típico, cuyos síntomas son independientes de la naturaleza del daño provocado o del fármaco que fue administrado y representa más bien una respuesta al daño que estos están causando, de esta manera surge el termino de estrés el cual proviene de la física y hace referencia a la presión que ejerce un cuerpo sobre otro (la fatiga de materiales), siendo aquel que más presión recibe el que puede destrozarse y fue adoptado por Hans Selye para denominar el conjunto de síntomas psicofisiológicos antes mencionado, y que también se conocen como síndrome general de adaptación o GAS por sus siglas en ingles por esto Hans es considerado el padre del estrés por ser el primero en asociar el concepto de física a este síndrome (GAS) [Selye, 1936, Selye et al., 1950, selye et al., 1952].

Además es importante mencionar que a pesar de que Hans Selye es el primero en usar este término para describir el síndrome de adaptación general, éste se basó en el trabajo previo de Walter B. Cannon fisiólogo norteamericano el cual da una de las primeras definiciones de homeostasis, un concepto que ayudo a Hans para relacionar el síndrome de adaptación general con la definición de estrés proveniente de la física. Esto porque la homeostasis de acuerdo a Walter B. Cannon son las reacciones fisiológicas coordinadas que mantienen en equilibrio la mayoría de los estados en el cuerpo. Estas reacciones son tan complejas y particulares de los organismos vivos, que según el autor debían definirse empleando un termino particular, así dicho autor las nombro como homeostasis. La homeostasis permite que el organismo vivo este estable para preservar su supervivencia, ya que todos los mecanismos que son vitales para su supervivencia, por variados que sean, sólo tiene un objetivo, preservar constantes las condiciones de vida [Cannon, 1929].

Continuando con el trabajo de Selye, al observar las reacciones de las ratas en su laboratorio, así como los pacientes que trató por diversas enfermedades, y una vez identificado el síndrome de adaptación general, pudo determinar las etapas por las que atraviesa el organismo vivo. Identificó tres etapas universales. La primera llamada reacción de alarma, involucra cambios bien definidos como hipertrofia e hiperactividad de la corteza suprarrenal, involución del timo e hipersecreción de corticotroina y tirotroina. Si el organismo sobrevive a esta primera etapa y el estímulo nocivo persiste, ingresa en una segunda etapa donde los órganos estabilizan su función a niveles prácticamente normales; es decir, se constituye una resistencia. Por último, si la situación se

prolonga en el tiempo (uno a tres meses), el organismo ingresa en una tercera etapa de agotamiento, que culmina con la muerte [Selye et al., 1950].

En artículos más recientes podemos encontrar una definición más General de estas tres etapas propuestas inicialmente por Hans Selye.

1. Fase de alarma: “La fase de alarma, constituye el aviso claro de la presencia de un agente estresante. Las reacciones fisiológicas ante este agente son las primeras que aparecen para advertir a la persona que debe ponerse en estado de alerta una vez percibida la situación” [Pereira, 2009].

2. Fase de Resistencia: “Cuando el estrés prolonga su presencia más allá de la fase de alarma, la persona entra en la segunda fase, denominada de resistencia. Intenta continuar enfrentado la situación, pero se da cuenta de que su capacidad tiene un límite y, como consecuencia de esto, se frustra y sufre. Empieza a tomar conciencia de que está perdiendo mucha energía y su rendimiento es menor, lo cual la hace tratar de salir adelante, pero no encuentra la forma; esto hace que esta situación se convierta en un círculo vicioso, sobre todo cuando va acompañada de ansiedad por un posible fracaso” [Pereira, 2009].

3. “Fase de agotamiento: la fase de agotamiento que es la fase terminal del estrés. Esta se caracteriza por la fatiga, la ansiedad y la depresión, las cuales pueden aparecer por separado o simultáneamente. La fatiga incluye un cansancio que no se restaura con el sueño nocturno, y generalmente va acompañada de nerviosismo, irritabilidad, tensión e ira” [Pereira, 2009].

Ahora que ya definimos que es el estrés desde el punto de vista psicofisiológicos, pasaremos a los enfoques más recientes sobre el efecto que tiene el estrés en áreas específicas como el ámbito laboral.

Uno de los enfoques en el ámbito laboral es el artículo: Estrés laboral, liderazgo y salud organizacional [Rodríguez and Peiró, 2008]. Este trabajo plantea que el estrés se maneja como un desajuste que tiene su origen en una percepción subjetiva de la situación que se vive, dando la sensación de que las demandas del trabajo son excesivas o amenazantes y difíciles de controlar teniendo consecuencias negativas para la persona, al sentirse sin los recursos necesarios para afrontar o controlar la situación. Las fuentes de estrés se denominan estresores un ejemplo de ello es el despido de la persona, siendo estos los estímulos que desencadenan las experiencias de estrés-tensión. En dicho trabajo también se habla de los recursos que se tienen para afrontar situaciones estresantes a nivel grupal u organizacional, no sólo a nivel individual, debido a que existen fuentes de estrés que no pueden ser resueltas por un sólo individuo. La identificación de dichos recursos, sirve para poder determinar cuáles son las fuentes de estrés que deben ser resueltas a nivel grupal, delimitando hasta donde cada individuo puede actuar sin que se enfrente a una fuerte fuente de estrés. Es aquí donde entra la figura del líder pues las



conductas y prácticas de éste, juegan un papel importante para amortiguar o potenciar los efectos de los diferentes estresores ayudando al bienestar del empleado [Rodríguez and Peiró, 2008].

Otro de los trabajos donde es abordado el estrés desde una perspectiva social es en: Escala de cansancio emocional (ECE) para estudiantes universitarios: Propiedades psicométricas en una muestra de México. Este trabajo es relevante en nuestra investigación debido a que se lleva a cabo en jóvenes universitario el cual se adecua a nuestro contexto. Identifica situaciones que generan estrés (estresores) en universitarios algunas de ellas son: preocupación por el desempeño en la escuela, el proceso de adaptación al ambiente universitario y a las exigencias de sus estudios y al mismo tiempo se preocupan por su futuro. Otros estresores frecuentes entre los universitarios tiene que ver con condiciones estructurales de su situación académica como horarios, aulas y traslados, además de la realización de exámenes, la espera de calificaciones y la incertidumbre hacia el futuro. Este trabajo también tomo en cuenta el rol del profesor como un detonante de estrés, se menciona que en algunas ocasiones contribuyen a que se intensifiquen las preocupaciones, cuando podrían contribuir a facilitar la adaptación de los estudiantes a las condiciones de la vida universitaria y enseñarles un adecuado manejo del estrés generado por estas condiciones [Ramírez and Hernández, 2007].

A continuación se describen las técnicas computacionales para procesar y clasificar EEGs.

## 2.6. Transformada Wavelet Discreta

El termino wavelet significa onda pequeña. El termino pequeña, se refiere al hecho de que esta función es de longitud finita y el término onda a su naturaleza oscilatoria. Las wavelet son un técnica que se desarrolló como una alternativa para superar los problemas de la transformada rápida de fourier, haciendo posible la representación de una señal tanto en tiempo como en frecuencia de forma simultánea. Hecho de gran interés para el análisis de señales no estacionarias como electroencefalogramas [de Castro Fernández, 2002, Orozco and Nieto, 2008].

La transformada wavelet discreta (DWT) analiza la señal descomponiéndola en coeficientes de aproximación y detalle para ello se emplean dos conjuntos de funciones denominadas: funciones de escalamiento y funciones wavelet, las que están asociadas a filtros pasa bajo y pasa alto, respectivamente. Existen diversas familias de funciones wavelet que sirven como prototipo para generar otras funciones por medio de escalamientos y traslaciones, a estas funciones se le conoce como wavelet madre [de Castro Fernández, 2002].

La DWT filtra la señal en el dominio del tiempo mediante filtros pasa bajos y pasa altos esto elimina ciertas componentes de baja o alta frecuencia de la señal, cada filtro obtiene la mitad de las frecuencias de la señal original pero el mismo número de elementos, cada filtros realiza un sub-muestreo por dos reduciendo la señal a la mitad. Se toma la salida de cualquier filtro (generalmente el filtro pasa bajos) o ambas y se hace nuevamente el mismo proceso, esta operación se denomina descomposición. Descomponiendo la señal en coeficientes wavelet de aproximación y detalle por cada nivel de descomposición. El proceso se repite hasta que la señal es descompuesta en cierto numero de niveles predefinidos. Al final se cuenta con un grupo de señales que representan la señal original, pero corresponden a diferentes bandas de frecuencias [de Castro Fernández, 2002, Odegard and Selesnick, 1998]. El proceso anterior se denomina codificación de sub-bandas.

Con la Transformada wavelet las altas frecuencias tiene mejor resolución en el tiempo mientras que las bajas frecuencias tienen mejor resolución en el dominio de la frecuencia.

Lo anterior queda expresado matemáticamente de la siguiente manera:

Sea la señal a analizar  $f[n]$  una función discreta. En este caso la transformada wavelet de la señal viene dada por:

$$C[j, k] = \sum_{n \in \mathbb{Z}} f[n] \Psi_{j,k}[n] \quad (2.1)$$

donde  $\Psi_{j,k}$  es una wavelet discreta definida como:

$$\Psi_{j,k}[n] = 2^{-j/2} \cdot \Psi[2^{-j}n - k] \quad (2.2)$$

Los parámetros  $T$  (traslación),  $S$  (escala) están definidos según la escala diádica, de manera que  $T = 2^j$ ,  $S = 2^j k$ . La transformación inversa se define de forma similar como:

$$f[n] = \sum_{j \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} C[j, k] \cdot \Psi_{j,k}[n] \quad (2.3)$$

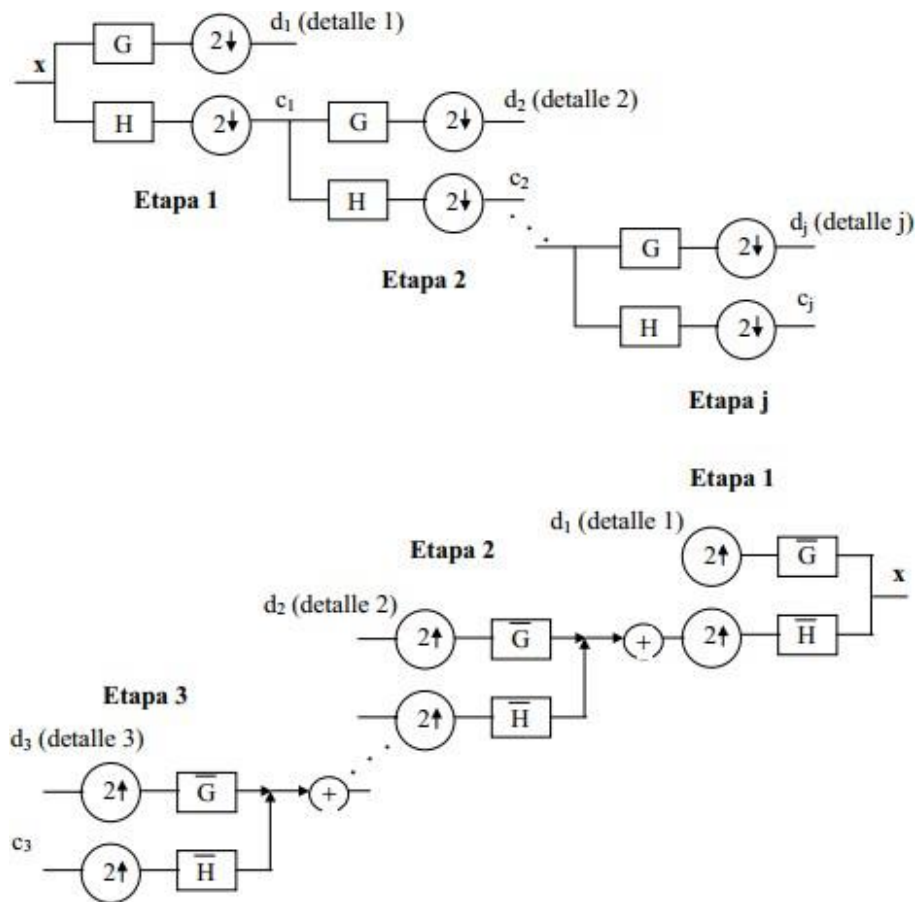


Figura 2.7: Algoritmo piramidal o codificación sub-banda. Descomposición de la señal  $x$  a través de filtros pasa bajos (H) y pasa altos (G) con submuestreo por 2 obteniendo coeficientes de detalle ( $d_1$ ) y aproximación ( $c_1$ ) repitiéndose el proceso dependiendo el nivel de descomposición de la señal y reconstrucción de la señal siguiendo el procedimiento descrito anteriormente en sentido inverso, de modo que las señales son interpolada por 2 ( $d_n$  y  $c_n$ ) y pasada a través de los filtros de síntesis pasa altos ( $\bar{g}[x]$ ) y pasa bajos ( $\bar{h}[x]$ ) para posteriormente sumarse ambas salidas, repitiéndose el proceso por cada nivel, hasta reconstruir la señal  $x$ . [de Castro Fernández, 2002].

## 2.7. Aprendizaje Automático

El aprendizaje se refiere a un amplio número de situaciones en las cuales el aprendiz incrementa su conocimiento o sus habilidades para cumplir una tarea.

De acuerdo con [Moreno et al., 1994] el aprendizaje automático también llamado aprendizaje artificial es la resolución de problemas como una forma de aprendizaje y una vez resuelto el problema, poder identificar la situación problemática y reaccionar utilizando la estrategia aprendida. Se da por hecho con este enfoque que un agente atómico tiene la capacidad de realizar una misma tarea de varias maneras de ser posible y de acuerdo a las circunstancias. Siendo capaz de tomar decisiones sobre cual es el camino mas adecuado que se debe seguir para la resolución del problema y ser capaz de modificar las decisiones cuando las condiciones lo requieran. El objetivo principal es construir sistemas (agentes) que sean capaces de adaptarse a situaciones nuevas y aprender como resultado de resolver el problema que estas situaciones presentan. El aprendizaje automático se caracteriza como: Aprendizaje = Selección + adaptación [Moreno et al., 1994]. Ahora que tenemos una idea sobre lo que es el aprendizaje automático, abordaremos de forma breve tres algoritmos de aprendizaje utilizados para el desarrollo de los experimentos realizados en el presente trabajo.

### 2.7.1. SVM

Las máquinas de soporte vectorial están basada en la teoría estadística del aprendizaje. Se basan en transformar el espacio de entrada en otro de dimensión superior (infinita) en el que el problema puede ser resuelto mediante un hiperplano óptimo (de máximo margen). Las máquinas de vectores soporte presentan un buen rendimiento al generalizar en problemas de clasificación, pese a no incorporar conocimiento específico sobre el dominio. La solución no depende de la estructura del planteamiento del problema.

La idea es construir una función clasificadora que:

1. Minimice el error en la separación de los objetos dados. Error en clasificación.
2. Maximice el margen de separación (mejora la generalización del clasificador)

En [Betancourt, 2005] una SVM primero mapea los puntos de entrada a un espacio de características de una dimensión mayor y encuentra un hiperplano que los separe y maximice el margen  $m$  entre las clases en este espacio (figura: 2.8).

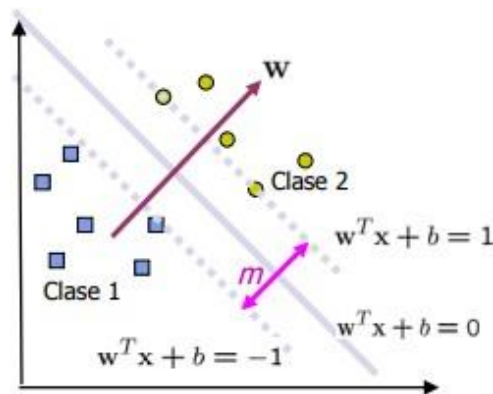


Figura 2.8: Frontera de decisión entre clases[Betancourt, 2005].

Sin ningún conocimiento del mapeo, la SVM encuentra el hiperplano óptimo utilizando el producto punto con funciones en el espacio de características que son llamadas kernels. La solución del hiperplano óptimo puede ser descrita como la combinación de unos pocos puntos de entrada que son llamados vectores de soporte.

### 2.7.2. Naive Bayes

Naive Bayes es un clasificador de aprendizaje automático basado en el teorema de Bayes, asume que la presencia o ausencia de una característica particular no está relacionada con la presencia o ausencia de cualquier otra característica, dada la clase variable.

Para analizar esto en [Zhang, 2004] se supone que  $E$  es una tupla de valores de atributo  $(x_1, x_2, \dots, x_n)$ , donde  $x_i$  es el valor del atributo  $X_i$ .  $C$  representa la variable de clasificación y  $c$  es el valor de  $C$ . También se asume que solo hay dos clases:  $+(la\ class\ positiva)$  or  $\neg(la\ class\ negativa)$ . Tomando en cuenta que un clasificador es una función que asigna una etiqueta de clase a un ejemplo. Desde la perspectiva de probabilidad, según la regla de Bayes, la probabilidad de un ejemplo  $E = (x_1, x_2, \dots, x_n)$  de ser de la clase  $c$  es:

$$p(c|E) = \frac{p(E|c)p(c)}{p(E)} \quad (2.4)$$

$E$  es clasificada como clase  $C = +$  si y solo si

$$f_b(E) = \frac{p(C = + | E)}{p(C = - | E)} \geq 1, \quad (2.5)$$

Donde  $f_b(E)$  es llamado clasificador Bayesiano. Supongamos que todos los atributos son independientes dado el valor de la variable de clase, es decir:

$$p(E | c) = p(x_1, x_2, \dots, x_n | c) = \prod_{i=1}^n p(x_i | c), \quad (2.6)$$

El clasificador resultante es:

$$f_{nb}(E) = \frac{p(C = +) \prod_{i=1}^n p(x_i | C = +)}{p(C = -) \prod_{i=1}^n p(x_i | C = -)} \quad (2.7)$$

Donde la función  $f_b(E)$  es el clasificador bayesiano o naive bayes.

### 2.7.3. Random Forest

El aprendizaje automático mediante random forest en [Breiman, 2001] es un método que combina una cantidad grande de árboles de decisión independientes probados sobre conjuntos de datos aleatorios con igual distribución. En muchos problemas el rendimiento del algoritmo random forest es muy similar a la de boosting, y es más simple de entrenar y ajustar. En consecuencia random forest es popular y es ampliamente utilizado. A grandes rasgos el proceso que sigue random forest para clasificar es el siguiente: Selecciona individuos al azar (usando muestreo con reemplazo) para crear diferentes set de datos. Crea un árbol de decisión con cada set de datos, obteniendo diferentes árboles, ya que cada set contiene diferentes individuos y diferentes variables en cada nodo. Al crear los arboles se eligen variables al azar en cada nodo del árbol, dejando crecer el árbol en profundidad (es decir, sin podar). Pre- dice los nuevos datos usando el "voto mayoritario", donde clasificará como "positivo" si la mayoría de los arboles predicen la observación como positiva. A continuación se describe de forma breve la fase de entrenamiento. Ésta consiste en crear muchos árboles de decisión independientes, construyéndolos a partir de datos de entrada ligeramente distintos. Se altera, por tanto, el conjunto inicial de partida, haciendo lo siguiente:

1. Se selecciona aleatoriamente con reemplazamiento un porcentaje de datos de la muestra total. Es habitual incluir un segundo nivel de aleatoriedad, esta vez afectando los atributos:
2. En cada nodo, al seleccionar la partición óptima, tenemos en cuenta sólo una porción de los atributos, elegidos al azar en cada ocasión.

Una vez que tenemos muchos árboles, 1000 por ejemplo, la fase de clasificación se lleva a cabo de la siguiente forma:

3. Cada árbol se evalúa de forma independiente y la predicción del bosque será la media de los 1000 árboles. La proporción de árboles que toman una misma respuesta se interpreta como la probabilidad de la misma.

# Capítulo 3

## Estado del Arte

Existe una gran cantidad de estudios en relación al estrés, las revisiones realizadas a diversos trabajos nos mostraron diferentes puntos de vista desde los que puede abordarse su estudio. Así puede tratarse desde una perspectiva social, fisiológica o psicológica. Cada una de ellas tiene aportaciones valiosas, mismas que fueron tomadas en cuenta para elaborar el método de detección de estrés que se ha propuesto en el capítulo 4.

En el presente capítulo se presentan algunos de los estudios revisados que fueron realizados en México y se analizan algunos trabajos previos relacionados a la detección de estrés usando Electroencefalogramas.

De acuerdo a [Navarro et al., 2012] el estrés es uno de los problemas que más padecen los mexicanos en el ámbito laboral y escolar. La investigación se realizó en un grupo de trabajadoras de la industria maquiladora, donde se encontró que al estar expuestas a un estrés prolongado las mujeres mostraron niveles disminuidos de anticuerpos, tal situación concordaba con una presencia elevada de padecimientos inflamatorios: faringitis, amigdalitis y sinusitis, así como depresión, ansiedad, trastornos del sueño, problemas cardiocirculatorios, psicosomáticos y digestivos. Los problemas mencionados, ocasionan males crónico degenerativos, por los que mueren miembros de la clase trabajadora del país.

Otro trabajo revisado estudio los efectos negativos en hospitales de la ciudad de México [Nava and del Pilar Paz-Román, 2014]. En este participaron 724 médicos donde se determinó que 61 por ciento de los médicos presentaban estrés moderado y 15 por ciento estrés alto.

También se realizó un estudio con estudiantes universitarios en la ciudad de México [Ramírez and Hernández, 2007] que tuvo como objetivo confirmar la estructura unifactorial de la Escala de Cansancio Emocional (ECE) que es una prueba que se aplicó en estudiantes universitarios de México. Con el objetivo de valorar la asociación entre estrés, autoestima y ansiedad. El estudio



se realizó con 506 estudiantes de psicología de dos universidades del norte de México, 365 de una universidad pública y 141 de una privada, de los cuales 19.2 por ciento fueron hombres y 80.8 por ciento fueron mujeres, la edad promedio fue de 20.71 años. Los resultados del estudio confirmaron correlaciones significativas con estrés, ansiedad y autoestima. Además se tomaron en cuenta diversos estresores como: el desempeño en la escuela, el proceso de adaptación al ambiente universitario para los recién egresados, las exigencias de sus estudios, exámenes, la espera de calificaciones, selección de horarios, etc.

En los artículos analizados anteriormente podemos darnos cuenta de la importancia que tiene el estudio del estrés negativo (diestres) en México pues repercute en la salud física y mental de los involucrados, se puede considerar un problema de salud pública pues origina una gran variedad de malestares, cualquier persona puede desarrollar estrés negativo donde factores como el ambiente o entorno propician condiciones para que este tenga mucho más efectos dañinos que positivos.

Las investigaciones analizadas nos llevan a cuestionarnos: ¿Cómo saber hasta que punto el estrés me favorece?, ¿En qué medida el nivel de estrés depende de nuestra personalidad, el entorno, nuestra predisposición genética, etc.?, ¿Qué métodos existen para la detección de estrés?, ¿Cuál es la efectividad de los métodos diseñados para medir el estrés?

A continuación se muestra la revisión de los artículos que nos ayudaron a responder las últimas dos preguntas. Analizamos los métodos propuestos con anterioridad para tener un punto de partida para proponer un método de detección de estrés.

### **3.0.1. Electroencefalograma y estrés**

El objetivo de [Seo and Lee, 2010] fue estudiar la fiabilidad existente entre el estrés y el electroencefalograma. Para lograrlo midieron los niveles de cortisol en la saliva, hormona asociada a niveles altos de estrés, también se utilizó la variabilidad de la frecuencia cardíaca ya que la presión de la sangre y la frecuencia cardíaca aumenta durante el estrés. Además indican que estudios recientes de neuroimagen, sugieren que la corteza prefrontal derecha puede estar relacionada con la respuesta al estrés, pues es un componente fundamental de las redes emocionales y de vigilancia. El experimento que realizaron tuvo 33 voluntarios diestros (9 mujeres y 24 hombres) de 30 a 40 años de edad. Para evaluar el estrés utilizaron el inventario de respuesta al estrés (SRI) y el maniquí de auto evaluación (SAM) dos pruebas que les ayudaron a determinar el estrés antes de tomar alguna medida fisiológica. Durante el experimento expusieron a cada participante a estímulos visuales

agradables y desagradables mientras se les tomaba su EEG y ECG , al final de la prueba les tomaron sus niveles de cortisol salival. Concluyen que existe una fuerte correlación entre el cortisol salival, la variabilidad de frecuencia cardíaca y las ondas beta altas en la región temporal del cerebro. Esta correlación indica que la detección de estrés crónico puede ser evaluada de manera confiable mediante EEG.

En [Haak et al., 2014] grabaron el Electroencefalograma(EEG) de los participantes mientras utilizaban un simulador de manejo en el que se presentaron distintos estímulos que generaran estrés. La grabación fue realizada por un operador, que en tiempo real agrega marcas a la grabación en momentos de interés. Por ejemplo cuando el participante choca el coche. Durante el análisis del EEG se puede relacionar este hecho con la actividad cerebral medida y así poder etiquetarla con la respuesta que se espera en este caso estrés. Eligieron el EEG porque este mide la actividad eléctrica generada por el parpadeo de forma confiable y sencilla. Para la adquisición de los EEG utilizaron un electroencefalógrafo de 19 electrodos llamado TruScan32 que usa el sistema internacional 10-20 para la colocación de los electrodos. La carga de los datos EEG capturados y filtros básicos que aplicaron, así como el análisis de la señal se realizó con el software TruScan Explorer. Por último utilizaron Matlab para realizar análisis estadístico de los datos que obtuvieron. A pesar de que en algunos trabajos se indica que el parpadeo genera artefactos en la señal este trabajo se centra en analizar estos artefactos para verificar la relación existente entre el parpadeo y el nivel de estrés percibido, pues la actividad eléctrica es mayor facilitando su caracterización. Después de analizar los datos concluyen que existe una fuerte correlación entre la frecuencia de parpadeo y el estrés emocional por lo tanto puede usarse como una medida de estrés pero los resultados obtenidos no son lo suficientemente precisos para ser utilizados en aplicaciones comerciales. Indican que se puede mejorar la efectividad si se utilizan sensores en los parpados de los ojos.

Otro estudio relacionado fue el de [Hou et al., 2015] donde se realizó un experimento con 9 participantes entre 21 y 28 años sin antecedentes de enfermedades mentales a quienes se les indujo cuatro niveles de estrés y por cada nivel se tomó su EEG durante 3 minutos con el electroencefalógrafo Emotiv Epoc de 14 canales. Durante la grabación de sus ondas cerebrales cada participante contestó un test para inducir estrés, dicho test utilizó el efecto stroop que es una clase de interferencia semántica en el tiempo de reacción de una tarea, (ejemplo: la palabra rojo escrita con tinta azul) que aumenta el tiempo de reacción y favorece los errores. Al finalizar la grabación EEG se les aplicó un cuestionario para determinar el nivel de estrés percibido durante el test realizado. El cuestionario sirvió para dividir en diferentes niveles el estrés que los participantes percibieron, la primera división fue de 2 niveles

de estrés, la segunda de 3 niveles de estrés y la tercera considero 4 niveles de estrés. El análisis que utilizaron para extraer las características de la señal, fue realizado mediante la transformada rápida de fourier para separar la actividad cerebral en sus diferentes frecuencias: delta (0.5-4 Hz), theta (4-8 Hz), alpha (8-12 Hz), beta (12-30 Hz) y gamma (mayor a 30 Hz). Además el cuestionario que realizaron en un inicio sirvió para poder etiquetar las señales EEG que obtuvieron, las cuales fueron clasificadas con algoritmos de aprendizaje automático implementados en python usando la biblioteca Scikit-learn que incluye una amplia gama de algoritmos de aprendizaje. Los algoritmos que utilizaron para clasificar los EEG fueron la máquina de soporte vectorial (SVM) y los k vecinos mas cercanos K-NN. Al realizar los experimentos de clasificación determinaron que con 2 niveles de estrés se obtenía una clasificación mas exacta de las señales EEG de cada participante, que si se usaban 3 o 4 niveles y el algoritmo de aprendizaje. Los mejores resultados se obtuvieron con SVM con un porcentaje de acierto del 85.17 porciento contra un 76.72 porciento de K-NN. Por último implementaron un programa que mide el nivel de estrés instantáneo con el procedimiento descrito anteriormente en Visual Studio 2010 en C++ usando el api de Emotiv. La aplicación monitoria en tiempo real el estrés y como el algoritmo que usa depende del sujeto incluye un módulo de entrenamiento y calibración. La prueba en la interfaz comienza cuando se preciosa el botón para empezar el entrenamiento durante la cual el sujeto completa la prueba stroop para inducir diferentes niveles de estrés mientras se graban el EEG. Acto seguido el participante contesta el formulario para determinar su nivel de estrés actual, después se pulsa el botón para clasificar con SVM y con esto se guarda el modelo generado por el clasificador para que pueda usarse posteriormente. Ya por ultimo se presiona el botón de iniciar reconocimiento con el que el software determina el nivel de estrés en tiempo real, mediante un marcador donde un puntero marca el nivel de estrés instantáneo.

Por otro lado [Gandhi et al., 2011] estudió cuál es la familia wavelet con mejores resultados para procesar señales EEG. Coiflet de orden 1 (coif1) fue la mejor, por su semejanza con la señal, así como una alta precisión de clasificación y mejor tiempo computacional, seguida de Daubichies, este resultado se obtuvo después de comparar cuatro familias wavelet estas fueron coifles, haar, biorthogonal (bior1.1) y Daubichies (db2) esté trabajo después de realizar análisis en señales EEG normales y anormales (personas con epilepsia), usando la DWT descompusieron las señales con las wavelet mencionadas y usaron vectores de caracterización para modelar y entrenar una red neuronal probabilistica y las exactitudes de clasificación fueron evaluadas para cada caso. Los resultados obtenidos, los comparan con los obtenidos con SVM, siendo los primeros superiores a los segundos. Esto lo realizaron porque indi-

can no existe un estándar para elegir la mejor wavelet para el procesamiento de señales EEG.

# Capítulo 4

## Método propuesto

En este capítulo se presenta el método propuesto para detección de estrés mediante el uso del electroencefalograma(EEG) compuesto por 5 pasos. Además se explica y detalla la forma en la que se realizó cada experimento. Este método se puso a prueba en un grupo de estudiantes universitarios con una edad promedio de 24 años, donde 6 participantes fueron mujeres y 19 hombres. Los experimentos se realizaron en la Facultad de Ciencias de la Computación de la Benemérita Universidad Autónoma de Puebla. El método propuesto consta de las siguientes etapas:

1. Adquisición de la señal EEG.
2. Preprocesado de la señal.
3. Extracción de características.
4. Selección de características.
5. Clasificación de características.

Dichas etapas se describen a continuación, pero antes se presentara la infraestructura utilizada.

### 4.1. Infraestructura

La adquisición de los electroencefalogramas (EEG) se realizó con la diadema Emotiv Epoc plus (Figura: 4.1). Esta utiliza frecuencia de muestreo a 128 Hz y 14 canales, así como el sistema internacional 10-20 que determina la ubicación de los electrodos. Además se utilizó una suscripción de pago del software EmotivPro v 1.3.73 (Figura 4.2) para obtener señales EEG sin procesar.



Figura 4.1: Electroencefalógrafo Emotiv Epoc Plus.

También se utilizó Matlab R2015b para el procesamiento de señales y obtención de características de los EEG mediante una aplicación gráfica que se desarrolló como parte de este trabajo. En la fase de clasificación se hizo uso del software Weka v 3.8 y la prueba "Perceived Stress Scale (PSS)" que determina el estrés percibido en el último mes. Además se reservó un cubículo con capacidad para 7 personas en la biblioteca central universitaria por 5 días durante 2 horas, en áreas de silencio.

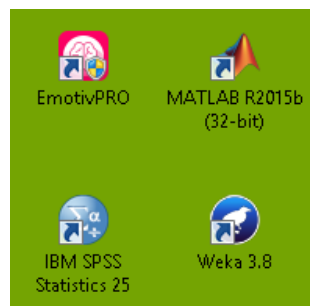


Figura 4.2: Software Utilizado: Emotiv Pro, Matlab R2015b, IBM SPSS 25, Weka 3.8.

## 4.2. Adquisición de EEG

El primer paso realizado fue la grabación de electroencefalogramas(EEG), para esto se eligió a un grupo de 25 participantes con características similares (edad, nivel de estudios, carrera, estado de salud) de los cuales 6 fueron mujeres y 19 hombres todos estudiantes de la Facultad de Ciencias de la Computación con una edad promedio de 24 años, quienes aceptaron participar de forma voluntaria.

Una vez que se contó con el grupo de participantes a quienes se les tomaría su EEG, surgió la interrogante de cuanto tiempo debería durar la grabación.

De acuerdo con [Tatum et al., 2008] un EEG estándar dura entre 20 a 30 minutos. Si tomamos en cuenta este tiempo y la frecuencia de muestreo de la diadema Emotiv Epoc+ a 128 Hz, la cantidad de muestras que se obtendrían sería demasiado alta para ser procesada con la infraestructura que se tiene, por este motivo y basados en el trabajo de [Hou et al., 2015] quien utilizó 12 minutos de grabación EEG al inducir cuatro niveles de estrés con una duración de 3 minutos por nivel, se decidió que la duración sería de 12 minutos, de los cuales sólo se utilizarían hasta 10 minutos, pues se quitaría el primer y último minuto de la grabación para obtener datos más precisos.

La grabación EEG de cada participante se realizó en un cubículo de la biblioteca central de la universidad durante 5 sesiones de dos horas distribuidas en 2 semanas. Se eligió dicho cubículo, porque es un lugar donde no hay ruido, tampoco existen distracciones o situaciones que interrumpieran en algún momento la toma del EEG, cuenta con el mobiliario necesario y permitió que el participante permaneciera solo durante la toma del EEG pero sin dejar de ser observado durante el proceso. Todo lo descrito anteriormente tuvo como fin tener grabaciones de EEGs confiables. Además a los participantes, se les dio la indicación de no usar productos para el cabello el día de la grabación (gel, crema para el cabello, cera, no usar acondicionador, etc.). Durante la grabación se pide sentarse con una postura erguida con los pies en el suelo y la columna contra la parte posterior de la silla, los codos descansando contra el cuerpo y mantener el cuello flexible, moviéndolo y estirándolo solo cuando fuese necesario. En el caso de la mirada se invitó a mantenerla al frente y parpadear sólo cuando fuera necesario, pues el parpadeo puede generar interferencias (artefactos) en la señal por la actividad eléctrica registrada proveniente de los músculos usados en cualquier movimiento incluyendo el movimiento ocular el cual es registrado en el EEG [Pivik et al., 1993].

Los datos se registraron mediante el software EmotivPro (Figura 4.3) este se conecta a la diadema Emotiv Epoc+ mediante bluetooth y nos permite grabar los EEG sin procesar en formato EDF, este formato es el que usa Emotiv pero también podemos exportar a formato csv. El formato elegido para trabajar fue csv pues nos permite trabajar con él directamente en Matlab para extraer las características que nos interesan.

Es importante mencionar que aproximadamente una semana antes de realizar las grabaciones EEG, los participantes contestaron un test que mide el estrés general percibido en el último mes llamado 'Perceived Stress Scale (PSS)' este instrumento sirvió para clasificar los EEG en la última etapa del método propuesto.

El contexto en el que se realizó el experimento fue en el último mes del cuatrimestre que cursaban los participantes, donde la probabilidad de encontrar situaciones estresantes era alta, de hecho la grabación de los EEG

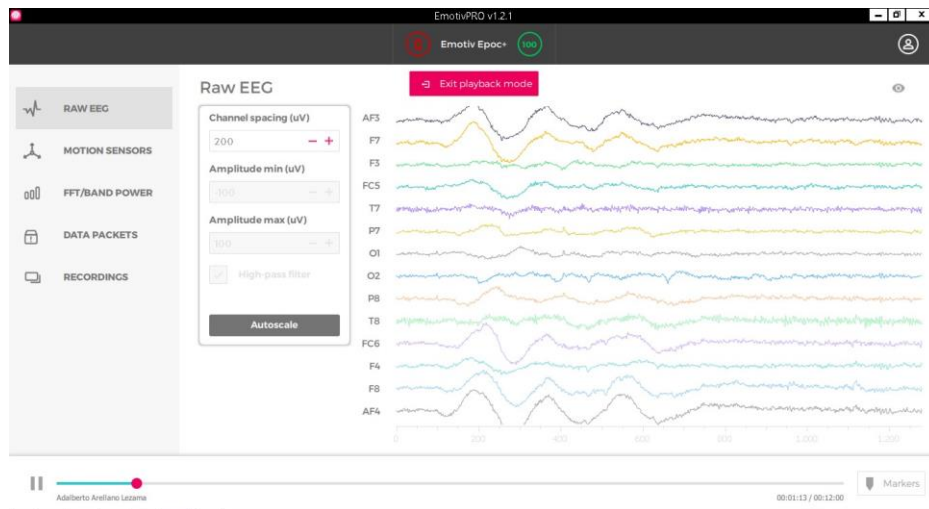


Figura 4.3: Software para adquirir datos sin procesar de diadema Emotiv Epoc Plus.

fue durante la semana de exámenes finales y entrega de proyectos, dos de muchas situaciones que de acuerdo a [Ramírez and Hernández, 2007] suponen un aumento en los niveles de estrés.

### 4.3. Preprocesamiento

El preprocesado para reducción de ruido en las señales EEG no fue utilizado en los experimentos de este trabajo, pues antes se deben caracterizar las distintas fuentes generadoras de ruido en la señal EEG para ser eliminadas y evitar remover información relevante, esto porque el ruido contenido en las señales EEG en muchos casos proviene de interferencias electromagnéticas o de movimientos del paciente que genera actividad eléctrica y son registrados por el EEG, ejemplo de esto es el parpadeo, el movimiento ocular y el movimiento de músculos en la cara. Por este motivo, el preprocesado de la señal que forma parte del método para detección de estrés empleando EEG del capítulo 4 en la sección 4.7 no fue utilizado en este trabajo. A pesar de no utilizar la reducción de ruido en la señal, se implementó esta función en el software desarrollado en matlab para trabajos posteriores de acuerdo al trabajo realizado por [Lemus, 2008]. Para realizar la reducción del ruido en la señal en los trabajos futuros se seguirá el siguiente procedimiento:

1. Descomponer la señal EEG. Eligir la wavelet y los niveles en los que se descompondrá la señal, realizando la descomposición calculando los



coeficientes wavelet de aproximación y detalle.

2. Calcular el umbral de los coeficientes wavelet por cada nivel de descomposición. Para cada nivel seleccionar un umbral y aplicar el umbral a los coeficientes de detalle.
3. Reconstruir la señal EEG. Reconstruir la señal con la wavelet elegida utilizando los coeficientes de aproximación y los coeficientes de detalle a los que se les aplico el umbral.

#### 4.4. Extracción de características

El segundo paso consiste en extraer las caracterizaras asociadas al estrés. para esto es importante recordar que en el capitulo 2 el electroencefalograma es el registro de la actividad eléctrica y formas de onda generadas por las neuronas corticales. De acuerdo a [Tatum et al., 2008, Daube and Rubin, 2009] la actividad eléctrica registrada (EEG) la podemos dividir en 4 frecuencias (tabla:4.1) asociadas a diferentes estados de conciencia, presentadas a continuación:

Delta	0.2 - 4 Hz
Theta	4 - 8 Hz
Alfa	8-13
Beta	13 Hz >

Tabla 4.1: Frecuencias en las que se divide la actividad cerebral.

Lo anterior sirvió como un punto de partida, pues nos permitió identificar que técnicas usaríamos para extraer las características de cada EEG. Para esto se eligió la transformada wavelet discreta (DWT) que permite descomponer la señal en sus componentes de frecuencia y porque tiene mejores resultados en tiempo-frecuencia para procesar señales no estacionarias en comparacion con la transformada rapida de Fourier [Orozco and Nieto, 2008]. La descomposición de la señal EEG con la DWT de cada participante en sus diferentes frecuencias, se realizo tomando en cuenta la frecuencia de muestreo del electroencefalógrafo utilizado llamado Emotiv Epoc plus, de acuerdo al fabricante la frecuencia de muestreo es de 128 Hz, tomando en cuenta el teorema de Nyquist que dice: la frecuencia de muestreo debe ser por lo menos el doble de la frecuencia a muestrear. Se dedujo que la frecuencia máxima representada en la señal seria de 64 Hz.

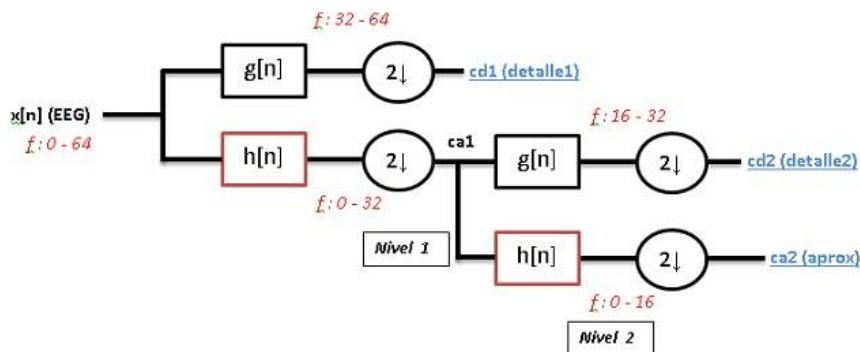


Figura 4.4: Diagrama de codificación en sub-bandas.

Lo anterior permitió definir el diagrama de descomposición de la señal, este permitió saber en cuantos niveles descomponer la señal y el rango de las frecuencias que contendrían los coeficientes de aproximación y detalle obtenidos con la DWT para así obtener las características deseadas.

Como podemos observar en la figura: 4.4 la señal  $x[n]$  se descompone en sus componentes de alta y baja frecuencia mediante filtros pasa altos  $g[n]$  y pasa bajos  $h[n]$  y tiene 2 niveles de descomposición, en el primer nivel solo obtendremos los coeficientes de detalle (cd1, 32-64 Hz) ya que los coeficientes de aproximación nuevamente se descomponen a través de los filtros pasa altos y pasa bajos. En el nivel dos tenemos los coeficientes de detalle (cd2, 16-32 Hz) y aproximación (ca2, 0-16 Hz).

Una vez determinados los parámetros que nos permitirían extraer las características de interés de la señal surgió la siguiente interrogante ¿Cuál sería la wavelet que nos brindara mejores resultados para extraer características en señales EEG?, de acuerdo a [Gandhi et al., 2011] la familia wavelet con mejores resultados al procesar señales EEG es coiflet de orden 1 (coif1) como se explica en el capítulo 3 en la sección 3.0.1. De acuerdo a lo anterior la wavelet elegida para procesar las señales en este trabajo fue coiflet (coif1) pero también se decidió usar Daubichies (bd2) y biorthogonal (bior2.2) para comparar los resultados obtenidos.

## 4.5. Selección de características

En los experimentos realizados por [Seo and Lee, 2010] explicados en el capítulo 3 en la sección 3.0.1 se concluyó que el estrés puede ser medido por EEG de forma confiable. Tomando esto como punto de partida las características seleccionadas en los EEG fueron las ondas beta que son aquellas con frecuencias de 13 a 30 Hz. La descomposición de la señal se definió en

la sección de extracción de características dónde podemos observar que los coeficientes de detalle (cd2) en el nivel 2 corresponden a ondas beta, dichos coeficientes son los que se tomaron para ser almacenados en un archivo y de esta manera realizar la clasificación de las características asociadas al estrés de los 25 participantes.

## 4.6. Clasificación de características

Después de haber extraído y seleccionado las características en las señales EEG usando la DWT asociadas al estrés (ondas beta) se paso a las clasificación de estas por medio del software weka que utiliza algoritmos de aprendizaje automático. Para realizar la clasificación, los algoritmos elegidos fueron los siguientes: maquinas de soporte vectorial (SVM), random forest y naive bayes. Para que el software weka realice la clasificación de las características EEG elegidas, es necesario que estén asociadas a una determinada clase, esto se obtiene con el etiquetado de las características. Las clases elegidas fueron: estrés alto y estrés bajo.

Las clases se determinaron al realizar dos particiones de acuerdo al puntaje mínimo y máximo que tiene el test PSS, mínimo 0 y máximo 56 puntos. Recuerdese que este test que se aplicó en la etapa de adquisición de las señales, para medir el nivel de estrés percibido en los participantes en los últimos 30 días. Este test consta de 14 ítems con una escala de cinco puntos (0 = nunca, 1 = casi nunca, 2 = de vez en cuando, 3 = a menudo, 4 = muy a menudo), la puntuación directa obtenida indica que a una mayor puntuación corresponde un mayor nivel de estrés percibido. Con esto en mente, se realizó la partición de datos en dos clases, una negativa y otra positiva (Apendice A), en el software IBM SPSS statistics se capturaron las preguntas y respuestas de los 14 ítem (Figura 4.5), se calcularon los puntajes, el mínimo fue de 14 puntos y el máximo de 47 (Figura 4.6) y se realizó la partición del puntaje en dos clases, de forma que un puntaje de 0-29 puntos se considera estrés bajo y de 30-56 estrés alto (Figura A.1), obtenido así las clases que servirán para etiquetar los coeficientes wavelet de cada eeg asociados a la clase estrés alto o estrés bajo.

R11	R12	R13	R14	Edad	Sexo	Puntuacion	Estres
casi nunca	de vez en ...	nunca	nunca	24	masculino	14,00	estres_bajo
de vez en ...	a menudo	casi nunca	de vez en ...	25	femenino	17,00	estres_bajo
casi nunca	a menudo	casi nunca	casi nunca	26	masculino	19,00	estres_bajo
casi nunca	a menudo	de vez en ...	casi nunca	24	masculino	20,00	estres_bajo
casi nunca	muy a men...	a menudo	nunca	25	masculino	21,00	estres_bajo
de vez en ...	muy a men...	nunca	de vez en ...	23	masculino	21,00	estres_bajo
casi nunca	a menudo	casi nunca	casi nunca	24	masculino	22,00	estres_bajo
de vez en ...	a menudo	casi nunca	casi nunca	21	masculino	23,00	estres_bajo
nunca	a menudo	casi nunca	casi nunca	17	femenino	23,00	estres_bajo
casi nunca	muy a men...	nunca	de vez en ...	32	masculino	25,00	estres_bajo
a menudo	muy a men...	nunca	de vez en ...	28	masculino	26,00	estres_bajo
a menudo	de vez en ...	de vez en ...	a menudo	28	masculino	29,00	estres_bajo
muy a men...	a menudo	casi nunca	casi nunca	23	masculino	29,00	estres_bajo
muy a men...	a menudo	a menudo	a menudo	21	femenino	30,00	estres_alto
a menudo	de vez en ...	de vez en ...	de vez en ...	22	masculino	30,00	estres_alto
casi nunca	a menudo	casi nunca	a menudo	23	femenino	31,00	estres_alto
de vez en ...	muy a men...	a menudo	de vez en ...	25	masculino	31,00	estres_alto
casi nunca	muy a men...	muy a men...	de vez en ...	24	masculino	31,00	estres_alto
muy a men...	muy a men...	nunca	muy a men...	23	masculino	32,00	estres_alto
a menudo	a menudo	de vez en ...	a menudo	23	masculino	32,00	estres_alto
a menudo	muy a men...	de vez en ...	muy a men...	24	masculino	34,00	estres_alto
casi nunca	a menudo	a menudo	a menudo	24	masculino	35,00	estres_alto
de vez en ...	a menudo	muy a men...	de vez en ...	25	masculino	35,00	estres_alto
a menudo	muy a men...	a menudo	muy a men...	25	femenino	37,00	estres_alto

Figura 4.5: Captura de las preguntas del cuestionario Perceived Stress Scale (PSS) de Cohen.

R11	R12	R13	R14	Edad	Sexo	Puntuacion	Estres
1	2	0	0	24	1	14,00	1
2	3	1	2	25	0	17,00	1
1	3	1	1	26	1	19,00	1
1	3	2	1	24	1	20,00	1
1	4	3	0	25	1	21,00	1
2	4	0	2	23	1	21,00	1
1	3	1	1	24	1	22,00	1
2	3	1	1	21	1	23,00	1
0	3	1	1	17	0	23,00	1
1	4	0	2	32	1	25,00	1
3	4	0	2	28	1	26,00	1
3	2	2	3	28	1	29,00	1
4	3	1	1	23	1	29,00	1
4	3	3	3	21	0	30,00	2
3	2	2	2	22	1	30,00	2
1	3	1	3	23	0	31,00	2
2	4	3	2	25	1	31,00	2
1	4	4	2	24	1	31,00	2
4	4	0	4	23	1	32,00	2
3	3	2	3	23	1	32,00	2
3	4	2	4	24	1	34,00	2
1	3	3	3	24	1	35,00	2
2	3	4	2	25	1	35,00	2
3	4	3	4	26	0	37,00	2

Figura 4.6: Puntuación de estrés percibido de cada participante.

R11	R12	R13	R14	Edad	Sexo	Puntuacion	Estres
casi nunca	de vez en ...	nunca	nunca	24	masculino	14,00	estres_bajo
de vez en ...	a menudo	casi nunca	de vez en ...	25	femenino	17,00	estres_bajo
casi nunca	a menudo	casi nunca	casi nunca	26	masculino	19,00	estres_bajo
casi nunca	a menudo	de vez en ...	casi nunca	24	masculino	20,00	estres_bajo
casi nunca	muy a men...	a menudo	nunca	25	masculino	21,00	estres_bajo
de vez en ...	muy a men...	nunca	de vez en ...	23	masculino	21,00	estres_bajo
casi nunca	a menudo	casi nunca	casi nunca	24	masculino	22,00	estres_bajo
de vez en ...	a menudo	casi nunca	casi nunca	21	masculino	23,00	estres_bajo
nunca	a menudo	casi nunca	casi nunca	17	femenino	23,00	estres_bajo
casi nunca	muy a men...	nunca	de vez en ...	32	masculino	25,00	estres_bajo
a menudo	muy a men...	nunca	de vez en ...	28	masculino	26,00	estres_bajo
a menudo	de vez en ...	de vez en ...	a menudo	28	masculino	29,00	estres_bajo
muy a men...	a menudo	casi nunca	casi nunca	23	masculino	29,00	estres_bajo
muy a men...	a menudo	a menudo	a menudo	21	femenino	30,00	estres_alto
a menudo	de vez en ...	de vez en ...	de vez en ...	22	masculino	30,00	estres_alto
casi nunca	a menudo	casi nunca	a menudo	23	femenino	31,00	estres_alto
de vez en ...	muy a men...	a menudo	de vez en ...	25	masculino	31,00	estres_alto
casi nunca	muy a men...	muy a men...	de vez en ...	24	masculino	31,00	estres_alto
muy a men...	muy a men...	nunca	muy a men...	23	masculino	32,00	estres_alto
a menudo	a menudo	de vez en ...	a menudo	23	masculino	32,00	estres_alto
a menudo	muy a men...	de vez en ...	muy a men...	24	masculino	34,00	estres_alto
casi nunca	a menudo	a menudo	a menudo	24	masculino	35,00	estres_alto
de vez en ...	a menudo	muy a men...	de vez en ...	25	masculino	35,00	estres_alto
a menudo	muy a men...	a menudo	muy a men...	26	femenino	37,00	estres_alto

Figura 4.7: Clases generadas: Estrés bajo y Estrés alto.

## 4.7. Aplicación que implementa el método propuesto

Lo descrito anteriormente conforma el método propuesto para la detección de estrés (Figura 4.8).




Figura 4.8: Método propuesto para detección de estrés usando EEG.

Respecto a la implementación del método se tomó la decisión de integrar todo lo anterior en una aplicación hecha en matlab que permitiera un análisis

mucho mas rápido y eficiente al permitir cambiar los distintos parámetros con los que se procesa la señal siguiendo el método propuesto, por ejemplo cambiar el tipo de wavelet madre usada, el tipo de filtrado de la señal, elegir que canales EEG utilizar, el nivel de descomposición de la señal, etc., así como la mejora constante y uso de esta herramienta en trabajos posteriores. A continuación se explica la aplicación desarrollada y su correspondiente relación con cada paso del método propuesto.

En el primer paso del método que pertenece a la adquisición de las señales EEG, se graban los datos mediante Emotiv Epoc Plus y el software emotiv pro que nos permitió exportar los datos a formato csv, los archivos csv se cargan a la aplicación desarrollada mediante un botón con la leyenda Folder con EEG. Esto carga todos los archivos que estén dentro de determinada carpeta, también nos permite seleccionar la muestra inicial para extraer los datos de cada archivo y la muestra final, recordemos que tenemos 12 minutos de grabación con una frecuencia de 128 Hz, esto nos permite cambiar los intervalos de los datos a usar (Figura 4.9), la aplicación nos indica cuantos datos se encontraron. Esta sección de la aplicación corresponde a la etapa de la adquisición de los datos.



Figura 4.9: Interfaz que permite cargar los datos sin procesar de la diadema Emotiv Epoc Plus.

En el segundo modulo de la aplicación (Figura 4.10)corresponde a la extracción de características del paso 3 del método propuesto. Este modulo permite selecciona la wavelet madre para analizar la señal. Se puede escoger entre coiflet, Daubechies o biorthogonal, además se pueden seleccionar los canales con los que se desea trabajar mediante una representación visual de su posición en la cabeza. Se puede también eliminar ruido de la señal, mediante diversos umbrales. Como trabajo futuro se realizarán experimentos con esta opción.

Pre-procesado

Wavelet

Coiflet  Biorthogonal

Daubechies

Canal(s)

Todos

F7  AF3  AF4  F8

FC5  F3  F4  FC6

T7  T8

P7  P8

O1  O2

Selección

Rigrsure  Sqtwolog

Heursure  Minimaxi

Aplicación

Hard  Soft

Figura 4.10: Interfaz que permite seleccionar wavelet, canales y umbrales para eliminar ruido en la señal.

El tercer módulo que corresponde al paso 4 del método (Selección de características) se decidió que los coeficientes wavelet elegidos para detectar el estrés, que corresponden al nivel 2 de descomposición se mantuviera fijo pues este corresponde a las ondas beta las cuales no cambian su rango de frecuencia, por este motivo no se muestra en la interfaz una opción para modificar dicho nivel, pero de ser necesario se puede incluir esta opción.

En el módulo 4 que corresponde al paso 5 (clasificación de características) se cuenta con dos opciones de etiquetado correspondiente a las clases propuestas: estrés alto y estrés bajo (Figura 4.11).






Figura 4.11: Interfaz que permite seleccionar el etiquetado de las señales EEG.

En este paso se genera un archivo arff que sigue las especificaciones del software weka para que sea compatible con dicha aplicación. Dicho archivo contendrá solo señales de los canales seleccionados al presionar el botón "Procesar y generar archivo arff por sujeto". En el apéndice B puede encontrarse un ejemplo del archivo arff generado.

Es importante mencionar que se crea un archivo arff por cada participante, esto podría parecer un problema pues weka no permite cargar múltiples archivos para analizarlos, pero se realiza de esta manera pues nos da mayor flexibilidad a la hora de realizar los experimentos, pues nos permite quitar o seleccionar determinados archivos para clasificar. Debido a lo expuesto anteriormente se creó un módulo que permite unificar los archivos generados por cada usuario en uno solo para ser cargado en weka, este quinto módulo desarrollado (Figura 4.12) cuenta con una opción para ingresar la cantidad de canales que contienen los archivos que se unificarán, un botón para seleccionar la carpeta con los archivos .arff que se desean unir, un cuadro de texto para indicar el nombre del archivo final y el botón Unir y guardar .arff para análisis en weka, que como su nombre lo indica se usa para seleccionar la ubicación donde será almacenado el archivo que tendrá todos los archivos arff. Se verifica previamente a la unión, que los archivos tengan los mismos encabezados para poder unirlos.

En el apéndice C se muestra parte del código desarrollado en matlab, así como las funciones que se utilizaron para procesar las señales EEG.

The image shows a software window titled "Unificar Archivos ARFF". It contains the following elements:

- A label "Ingresa Número de Canales en Archivo .arff" above a text input field containing the number "14".
- A button labeled "Folder con .arff Individuales".
- A label "Num. Archivos .arff :" followed by the number "0".
- A label "Ingresa el Nombre del Archivo .arff" above a text input field containing the word "Análisis".
- A button labeled "Unir y Guardar .arff para Analisis en Weka".

Figura 4.12: Interfaz que une los archivos arff con los que se trabaja en un solo archivo.

# Capítulo 5

## Experimentos y Resultados

En este capítulo se muestran los resultados de los experimentos realizados luego de haber procesado la señal EEG de cada participante con el método que se propuso en el capítulo 4, resultados que posteriormente se clasificaron con algoritmos de aprendizaje automático.

### 5.1. Experimentos con todos los canales EEG

El primer experimento para clasificar los coeficientes wavelet que representan las ondas beta se realizó utilizando las 14 señales del EEG, se decidió utilizar todas las señales porque hasta la fecha no existen investigaciones que determinen de forma definitiva la zona específica del cerebro asociada al estrés, por este motivo se planteó utilizar en un experimento todas las señales, posteriormente utilizar solo las señales del hemisferio izquierdo y finalmente las del hemisferio derecho, la finalidad de realizar los experimentos de esta manera es poder comparar los resultados y determinar si existen determinadas señales que ayuden en la detección del estrés o si todas son necesarias, pues en algunos trabajos como el realizado por [Seo and Lee, 2010] encontraron que la actividad beta alta en sitios temporales anteriores (FC5, FC6) en personas con ojos cerrados están asociadas al estrés.

Una vez que se determinó trabajar con todas las señales EEG se pasó a determinar el número de muestras a utilizar, como se mencionó anteriormente en la sección 4.2 la duración estándar de un EEG es de 20 a 30 minutos pero al no contar con los recursos suficientes para procesar las señales se determinó utilizar 2 minutos, no se utilizó algún criterio en especial que justifique la selección de este tiempo de grabación utilizada pero en trabajos como el de

[Hou et al., 2015] se utilizaron 3 minutos de grabación EEG. Con base en este trabajo, se utilizaron 2 minutos de cada señal EEG. A continuación se indica la configuración seleccionada en la interfaz, se inicio en la muestra 15360 esto porque eliminamos los primeros 2 minutos ya que existe una mayor probabilidad de tener mayor ruido al inicio en la señal por diversos factores y se finaliza en la muestra 30720 que corresponde al minuto 4 tomando al minuto 3 y 4 para el experimento.

Seleccionadas las señales y sabiendo el número de muestras a utilizar, estas se descompusieron en sus diferentes frecuencias usando las tres wavelet seleccionadas en el capítulo 4 de la sección 4.4, se uso la wavelet coiflet de orden 1 (coif1), daubichies (db2) y biorthogonal (bior1.1) obteniendo los coeficientes wavelet de aproximación y detalle, se determino no utilizar la reducción de ruido en la señal a pesar de estar implementada porque se podría eliminar información valiosa. La señal puede tener artefactos (ruido) de diversa índole que deben estudiarse con mayor profundidad antes de eliminarse. La eliminación de ruido se considerará como trabajo futuro.

Los coeficientes de detalle obtenidos al utilizar las distintas wavelet se etiquetaron para ser clasificados usando el software weka.

Posteriormente se unieron los resultados de cada participante en un solo archivo con la ayuda de la aplicación implementada. Este contenía las muestras de las 14 señales etiquetadas como estrés alto o bajo para ser clasificadas en el software weka.

Para finalizar se clasificaron los resultados con tres algoritmos de aprendizaje automático utilizando validación cruzada con 10 pliegues usando el software weka, el primer algoritmo usado fue random forest, el segundo naive bayes y el tercero fue SVM. Los resultados obtenidos se presentan en la Tabla 5.1, la gráfica de barras, Figura 5.2 y en la Figura 5.1 podemos observar el diagrama del proceso que se siguió al procesar la señal, este proceso se realizó en todos los experimentos variando únicamente las señales utilizadas (señales del hemisferio derecho e izquierdo del cerebro).

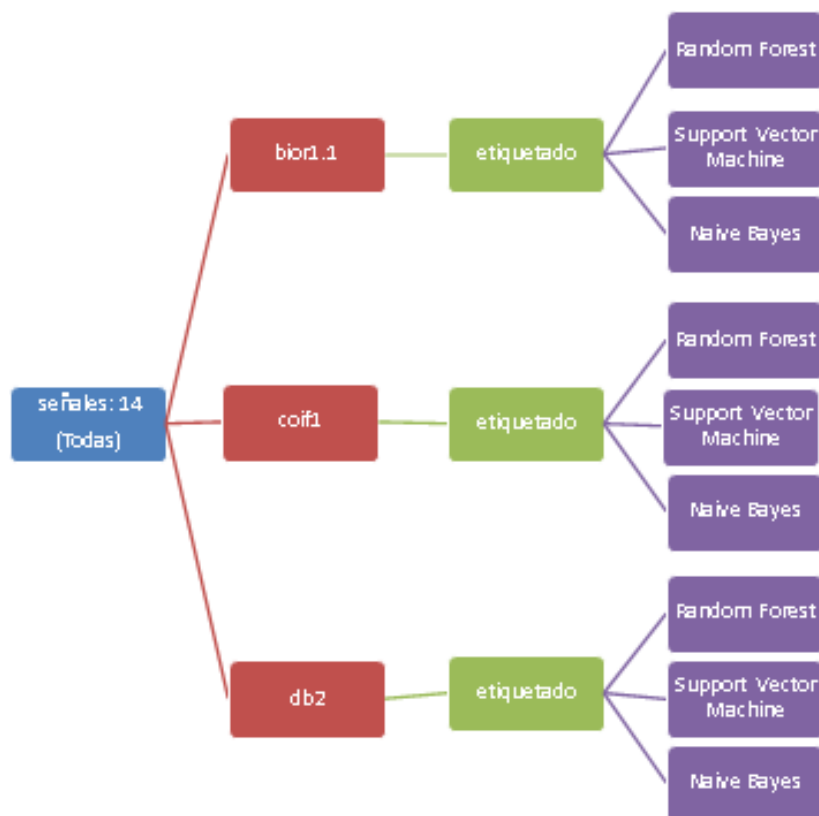


Figura 5.1: Proceso de análisis de las señal usando todas las señales del cerebro usando distintos parámetros.

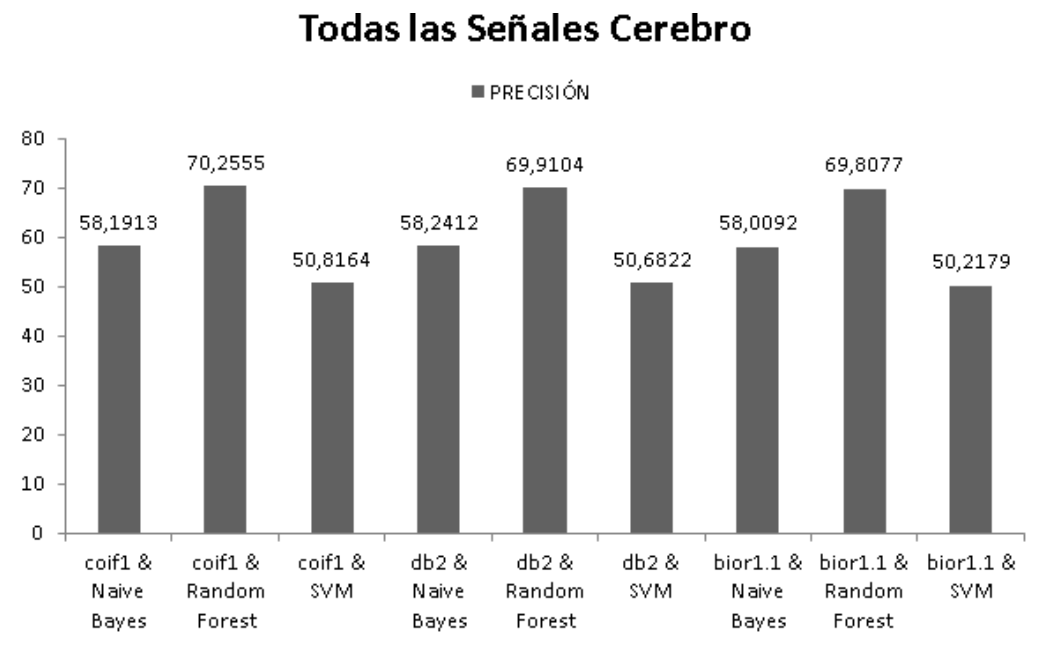


Figura 5.2: Resultados de la clasificación tomando en cuenta todas las señales EEG con diferentes algoritmos de aprendizaje automático.

WAVELET	ALGORITMO	PRECISIÓN	SEÑALES
coif1	Naive Bayes	58,1913 %	todos
coif1	Random Forest	70,2555 %	todos
coif1	SVM	50,8164 %	todos
db2	Naive Bayes	58,2412 %	todos
db2	Random Forest	69,9104 %	todos
db2	SVM	50,6822 %	todos
bior1.1	Naive Bayes	58,0092 %	todos
bior1.1	Random Forest	69,8077 %	todos
bior1.1	SVM	50,2179 %	todos

Tabla 5.1: Resultados de la clasificación tomando todas las señales, usando las tres wavelet seleccionadas y los 3 algoritmos de aprendizaje utilizados.

## 5.2. Experimentos con canales EEG izquierdos

En la sección anterior: 5.1 se han descrito los pasos seguidos para procesar y clasificar las señales, los cuales serán seguidos en este experimento, la diferencia es que en este, solo se usaron 7 señales correspondientes al hemisferio izquierdo del cerebro, estas son: AF3, F7, F3, FC5, T7, P7, O1.

El numero de muestras también fue de 2 minutos, eliminando las muestras de los 2 primeros minutos, las wavelet madre usadas fueron coiflet de orden 1 (coif1), daubichies (db2) y biorthogonal (bior1.1), tampoco se utiliza la reducción de ruido por las causas mencionadas anteriormente, para posteriormente etiquetar los resultados en las dos clases propuestas: estrés alto (0-29 puntos) o estrés bajo (30-56 puntos). Para finalizar se genero el archivo de weka (.arff, Attribute-Relation File Format) con los resultados de las 7 señales por cada participante y clasificar con los algoritmos elegidos: Random fores, Naive Bayes y SVM obtenido los resultados de la Tabla 5.2. Además es importante mencionar que inicialmente se adquirieron 25 EEG, pero se determino eliminar uno que corresponde a estrés bajo esto pues se contaban con 13 EEG de esta clase, se realizo con el fin de tener clases balanceadas para clasificar en weka para obtener resultados mas exactos.

WAVELET	ALGORITMO	PRECISIÓN	SEÑALES
coif1	Naive Bayes	52,485 %	izquierda
coif1	Random Forest	61,9785 %	izquierda
coif1	SVM	49,884 %	izquierda
db2	Naive Bayes	51,5758 %	izquierda
db2	Random Forest	62,1269 %	izquierda
db2	SVM	50,8676 %	izquierda
bior1.1	Naive Bayes	52,0004 %	izquierda
bior1.1	Random Forest	61,8614 %	izquierda
bior1.1	SVM	50,3209 %	izquierda

Tabla 5.2: Resultados de la clasificación usando las 7 señales del lado izquierdo del cerebro, usando las tres wavelet seleccionadas y los 3 algoritmos de aprendizaje utilizados.




Figura 5.3: Resultados de la clasificación tomando en cuenta las señales EEG del hemisferio izquierdo usando diferentes algoritmos de aprendizaje automático.

### 5.3. Experimentos con canales EEG derechos

El ultimo experimento que se realizo también sigue los pasos de la sección anterior: 5.1 para procesar y clasificar las señales, En este las señales fueron las del hemisferio derecho del cerebro, estas son: O2, P8, T8, FC6, F4, F8, AF4.

El numero de muestras también fue el descrito con anterioridad que corresponde a 2 minutos, se eliminaron las muestras de los 2 primeros minutos, las wavelets madre usadas fueron las mismas que en los experimentos anteriores, posteriormente se etiquetaron los resultados con las dos clases propuestas: estrés alto o estrés bajo. Para finalizar se genero el archivo de weka (.arff, Attribute-Relation File Format) con los resultados de las 7 señales por cada participante y se clasifico con los algoritmos elegidos: Random fores, Naive Bayes y SVM obteniendo los resultados de la tabla: 5.3 y la Figura 5.4.



WAVELET	ALGORITMO	PRECISIÓN	SEÑALES
coif1	Naive Bayes	57,8433 %	derecha
coif1	Random Forest	65,1737 %	derecha
coif1	SVM	49,4676 %	derecha
db2	Naive Bayes	57,9245 %	derecha
db2	Random Forest	64,8913 %	derecha
db2	SVM	50,2429 %	derecha
bior1.1	Naive Bayes	58,0807 %	derecha
bior1.1	Random Forest	64,7216 %	derecha
bior1.1	SVM	50,2027 %	derecha

Tabla 5.3: Resultados de la clasificación usando las 7 señales de la derecha del cerebro, usando las tres wavelet seleccionadas y los 3 algoritmos de aprendizaje utilizados.

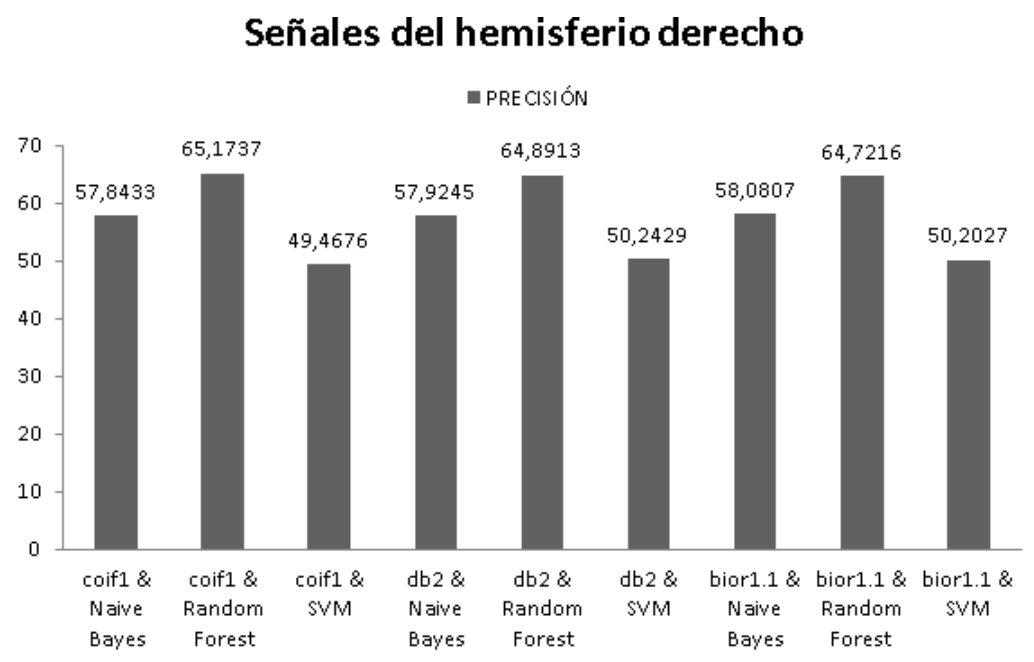


Figura 5.4: Resultados de la clasificación tomando en cuenta las señales EEG del hemisferio derecho usando diferentes algoritmos de aprendizaje automático.

# Capítulo 6

## Conclusiones y Trabajo Futuro

Los resultados de los experimentos realizados siguiendo el método del capítulo 4 para detectar el estrés en las 2 clases propuestas: estrés alto y estrés bajo, a partir de las señales EEG que se adquirieron en 25 participantes arrojando los siguientes resultados (figura: 6.1).




Figura 6.1: Precisión de cada experimento usando diferentes wavelet y algoritmos de aprendizaje automático.

En la gráfica anterior podemos apreciar la precisión de los resultados clasificados, primero todos los resultados que corresponden al hemisferio derecho usando 7 señales, luego se utilizaron las señales del hemisferio izquierdo que

también son 7 y por último se utilizaron todas las señales del cerebro, estas son 14 pues involucra los dos hemisferios cerebrales. Observando la gráfica se aprecia que los mejores resultados se obtuvieron al utilizar las 14 señales y las tuplas formadas por random forest con las diferentes wavelet, de hecho el mejor resultado se obtuvo con coiflet de orden 1 y random forest con una precisión del 70,2555 %, si recordamos en la subsección 4.4 cuando surgió la interrogante sobre que wavelet utilizar, se mencionó que coif1 era la mejor para descomponer señales EEG, esto de acuerdo al trabajo de [Gandhi et al., 2011], por este motivo este resultado ya se esperaba y con esto queda confirmado.

De acuerdo a los resultados obtenidos random forest se puede considerar como una opción bastante confiable a la hora de clasificar señales EEG de estrés, pues fue el algoritmo con mayor precisión al momento de clasificar los resultados en el presente trabajo. Además podemos observar que dentro de los resultados con mayor precisión sin importar si son del hemisferio derecho, izquierdo o ambos, random forest como clasificador tuvo la mayor precisión sin importar la wavelet usada. De todos los experimentos realizados el mejor resultado se obtuvo con la wavelet coiflet de orden 1 y el algoritmo de aprendizaje random forest obteniendo un 70.26 % de precisión, con esto podemos apreciar que el método para clasificar estrés usando EEGs puede ser utilizado como una herramienta para detección de estrés confiable, pues los resultados de estos experimentos están por arriba del azar.

En trabajos futuros se realizarán experimentos para reducir el ruido en la señal con diferentes filtros para identificar cual es el que nos brinda mayor precisión sin eliminar información importante, así como experimentos para determinar si todas las señales empleadas son importantes para detectar el estrés o pueden eliminarse determinadas señales, esto se pretende validar con experimentos donde se utilicen señales de cada lóbulo del cerebro, pues recordamos que de acuerdo al capítulo 2 en la sección 2.2 existen áreas del cerebro asociadas a funciones cognitivas, mejorando así el tiempo para procesar las señales, esto porque de acuerdo a los resultados obtenidos, usando todas las señales, en comparación con las del lado izquierdo y las del lado derecho hubo diferencias. Por ejemplo utilizando las del lado izquierdo se obtuvo una precisión del 62.1269 % y las del lado derecho una precisión del 65.1737 % resultados no muy lejanos de la precisión del 70.2555 % obtenida al utilizar todas las señales. Se esperaba que la diferencia fuera mayor pues el número de señales empleadas fue el doble.

A continuación se presentan todos los resultados ordenados de mayor a

menor precision (Tabla 6.1).

coif1 y Random Forest	70,2555	Hemisferio Der e Izq
db2 y Random Forest	69,9104	Hemisferio Der e Izq
bior1.1 y Random Forest	69,8077	Hemisferio Der e Izq
coif1 y Random Forest	65,1737	Hemisferio Derecho
db2 y Random Forest	64,8913	Hemisferio Derecho
bior1.1 y Random Forest	64,7216	Hemisferio Derecho
db2 y Random Forest	62,1269	Hemisferio Izquierdo
coif1 y Random Forest	61,9785	Hemisferio Izquierdo
bior1.1 y Random Forest	61,8614	Hemisferio Izquierdo
db2 y Naive Bayes	58,2412	Hemisferio Der e Izq
coif1 y Naive Bayes	58,1913	Hemisferio Der e Izq
bior1.1 y Naive Bayes	58,0807	Hemisferio Derecho
bior1.1 y Naive Bayes	58,0092	Hemisferio Der e Izq
db2 y Naive Bayes	57,9245	Hemisferio Derecho
coif1 y Naive Bayes	57,8433	Hemisferio Derecho
coif1 y Naive Bayes	52,485	Hemisferio Izquierdo
bior1.1 y Naive Bayes	52,0004	Hemisferio Izquierdo
db2 y Naive Bayes	51,5758	Hemisferio Izquierdo
db2 y SVM	50,8676	Hemisferio Izquierdo
coif1 y SVM	50,8164	Hemisferio Der e Izq
db2 y SVM	50,6822	Hemisferio Der e Izq
bior1.1 y SVM	50,3209	Hemisferio Izquierdo
db2 y SVM	50,2429	Hemisferio Derecho
bior1.1 y SVM	50,2179	Hemisferio Der e Izq
bior1.1 y SVM	50,2027	Hemisferio Derecho
coif1 y SVM	49,884	Hemisferio Izquierdo
coif1 y SVM	49,4676	Hemisferio Derecho

Tabla 6.1: Precisión de la clasificación en ordenados descendente.

# Bibliografía

- [A. R. Crossman, 2007] A. R. Crossman, D. N. (2007). *Neuroanatomía : texto y atlas, 3ª ed.* Elsevier Masson.
- [Barros and Guardiola, 2006] Barros, M. I. M. and Guardiola, G. T. (2006). Conceptos básicos de electroencefalografía. *Duazary*, 3(1):18–23.
- [Betancourt, 2005] Betancourt, G. A. (2005). Las máquinas de soporte vectorial (SVMs). *Scientia et Technica*, XI(27):67–72.
- [Breiman, 2001] Breiman, L. (2001). Random forests. *Machine Learning*, (45):5–32.
- [Britton et al., 2016] Britton, J. W., Frey, L. C., Hopp, J. L., Korb, P., Koubeissi, M. Z., Lievens, W. E., Pestana-Knight, E. M., and Louis, E. K. S. (2016). *Electroencephalography (EEG): An introductory text and atlas of normal and abnormal findings in adults, children, and infants*. American Epilepsy Society, 135 S. LaSalle St., Suite 2850, Chicago, IL 60603.
- [Cannon, 1929] Cannon, W. B. (1929). Organization for physiological homeostasis. *Physiological Reviews*, IX(3):399–431.
- [Cohen et al., 1983] Cohen, S., Kamarck, T., and Mermelstein, R. (1983). A global measure of perceived stress. *Journal of Health and Social Behavior*, 24(4):385–396.
- [Corchuelo et al., 2011] Corchuelo, A. D., Pozo, E. C., and Herrera, R. R. (2011). Percepción de estrés en personal universitario. 11(2):207–215.
- [Daube and Rubin, 2009] Daube, J. R. and Rubin, D. I. (2009). *Clinical neurophysiology*. Oxford University Press, Inc, 3 edition.

- [de Castro Fernández, 2002] de Castro Fernández, R. M. (2002). *Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Fundamentos*. Escuela Técnica Superior de Ingenieros Industriales.
- [Gandhi et al., 2011] Gandhi, T., Panigrahib, B. K., and Ananda, S. (2011). A comparative study of wavelet families for EEG signal classification. *Neurocomputing*, 74:3051–3057.
- [Haak et al., 2014] Haak, M., Bos, S., Panic, S., and Rothkrantz, L. M. (2014). Detecting stress using eye blinks and brain activity from EEG signals.
- [Hou et al., 2015] Hou, X., Liu, Y., Sourina, O., Tan, Y. R. E., Wang, L., and Mueller-Wittig, W. (2015). EEG Based Stress Monitoring. In *2015 IEEE International Conference on Systems, Man, and Cybernetics*. IEEE.
- [Kandel et al., 2001] Kandel, Schwartz, and Jessell (2001). *Principios de neurociencia*. McGraw-Hill, 4 edition.
- [Klem et al., 1999] Klem, G. H., Lüders, H. O., Jasper, and Elger, C. (1999). The ten-twenty electrode system of the international federation. *Elsevier Science B.V.*, pages 3–6.
- [Lemus, 2008] Lemus, C. G. (2008). Análisis de reducción de ruido en señales EEG orientado al reconocimiento de patrones. *Tecnológicas*, 21.
- [Moreno et al., 1994] Moreno, A., Armengol, E., Béjar, J., Belanche, L., Cortés, U., Gavalda, R., Gimeno, J. M., López, B., Martín, M., and Sánchez, M. (1994). *Aprendizaje automático*. Edicions UPC.
- [Nava and del Pilar Paz-Román, 2014] Nava, M. E. P. and del Pilar Paz-Román, M. (2014). Condiciones de trabajo, estrés y manifestaciones psicósomáticas en médicos de hospitales de la ciudad de México. *Medicina y Seguridad del trabajo*, pages 322–334.
- [Navarro et al., 2012] Navarro, M. P., de los Ángeles Garduño Andrade, M., Estrella, S. L. M., and Flores, N. L. L. (2012). Trabajo, estrés y salud: la costura a domicilio en ciudad de México. *Salud de los Trabajadores*, 20(1):33–47.
- [Odegard and Selesnick, 1998] Odegard, J. E. and Selesnick, I. W. (1998). *Introduction to wavelets and wavelet transforms*. Prentice-Hall.

- [Orozco and Nieto, 2008] Orozco, D. M. and Nieto, N. (2008). El uso de la transformada wavelet discreta en la reconstrucción de señales senosoidales. *Scientia Et Technica*, XIV(38):381–386.
- [Pereira, 2009] Pereira, M. L. N. (2009). Una revisión teórica sobre el estrés y algunos aspectos relevantes de éste en el ámbito educativo. *Revista Educación*, pages 171–190.
- [Pivik et al., 1993] Pivik, R. T., Broughton, R. J., Coppola, R., Davidson, R. J., Fox, N., and Nuwer, M. R. (1993). Guidelines for the recording and quantitative analysis of electroencephalographic activity in research contexts. *Psychophysiology*, (30):547–558.
- [Ramírez and Hernández, 2007] Ramírez, M. T. G. and Hernández, R. L. (2007). Escala de cansancio emocional (ECE) para estudiantes universitarios: Propiedades psicométricas en una muestra de México. *Anales de psicología*, 23(2):33–37.
- [Rodríguez and Peiró, 2008] Rodríguez, I. and Peiró, J. M. (2008). Estrés laboral, liderazgo y salud organizacional. *Papeles del Psicólogo*, 29(1):68–82.
- [Selye, 1936] Selye, H. (1936). A syndrome produced by diverse nocuous agents. *Nature*, page 32.
- [selye et al., 1952] selye, H., M.D., D.Sc., and F.R.S. (1952). *The story of the adaptation syndrome*. Number 100-184. ACTA, INC.
- [Selye et al., 1950] Selye, H., M.D., Ph.D., D.Sc., and F.R.S.C. (1950). Stress and the general adaptation syndrome. *British Medical Journal*, pages 1383–1392.
- [Seo and Lee, 2010] Seo, S. H. and Lee, J. T. (2010). Stress and EEG. *Convergence and Hybrid Information Technologies*, pages 413–427.
- [Sánchez et al., 2011] Sánchez, J. G., Terrats, J. R. A., and Rosas, A. C. (2011). Guía técnica para la construcción de escalas de actitud. *Odiseo revista electrónica de pedagogía*, (16).
- [Tatum et al., 2008] Tatum, W. O., Husain, A. M., Benbadis, S. R., and Kaplan, P. W. (2008). *Hanbook of EEG interpretation*. Demos Medical Publishing.
- [Zhang, 2004] Zhang, H. (2004). The optimality of naive bayes. *American Association for Artificial Intelligence*.

# Apéndice A

## Escala de Estrés Percibido (PSS) y División del Estrés en Dos Clases

La Escala de Estrés Percibido (PSS) es un instrumento psicológico que permite medir la percepción de estrés. Es una medida del grado en que las situaciones en la vida se consideran estresantes, esta medida se realiza a través de un test con 14 preguntas cada pregunta puede tener un puntaje de 0 a 4 puntos, donde el nivel de estrés percibido es la suma de los puntajes de cada ítem, a mayor puntaje mayor estrés, a continuación se describe el trabajo realizado por [Cohen et al., 1983] donde se demuestra la validez y confiabilidad de este test.

Los puntajes del PSS se obtienen invirtiendo los puntajes en los siete ítems positivos, por ejemplo, 0 = 4, 1 = 3, 2 = 2, etc., y luego sumando los 14 ítems. Los ítems 4, 5, 6, 7, 9, 10 y 13 son los ítems positivos.

El PSS fue diseñado para personas con al menos una educación secundaria. Los ítems son fáciles de entender y las alternativas de respuesta son simples de entender. Además, como se señaló anteriormente, las preguntas son de naturaleza bastante general y, por lo tanto, relativamente libres de contenido específico para cualquier grupo.

El trabajo se realizó en dos grupos de estudiantes universitarios y uno de participantes de un programa comunitario para dejar de fumar, de estas tres



## *APÉNDICE A. ESCALA DE ESTRÉS PERCIBIDO (PSS) Y DIVISIÓN DEL ESTRÉS EN DOS*

muestras se recopilaron los datos de validación.

Los ítems de PSS fueron diseñados para aprovechar el grado en que los encuestados encontraron sus vidas impredecibles, incontrolables y sobrecargadas. Estos tres temas se han encontrado repetidamente como componentes centrales de la experiencia del estrés. Además la escala incluye una serie de consultas directas sobre los niveles actuales de estrés experimentado.

Los encuestados de la primera muestra fueron 332 (121 hombres, 209 mujeres, dos con sexo no especificado) estudiantes universitarios de primer año que viven en dormitorios en la universidad de Oregón. La edad media fue de 19 con una desviación estándar de 2.75. Los encuestados en la segunda muestra fueron 114 miembros de una clase en psicología introductoria de la personalidad (53 mujeres, 60 hombres y una persona con sexo no especificado). La edad media de la muestra fue 20 con una desviación estándar de 4.41. y la tercer muestra estuvo conformada por 27 hombres y 37 mujeres que participaron en un programa para dejar de fumar dirigido por el programa de control de fumar de la universidad de Oregón.

La fiabilidad del coeficiente alfa para el PSS fue de .83, .85 y .86 en cada una de las tres muestras.

El PSS puede usarse para determinar si el estrés evaluado es un factor de riesgo en los trastornos de conducta o enfermedad. El PSS es una medida breve y fácil de administrar sobre el grado en que las situaciones en la vida se consideran estresantes. Se ha demostrado que posee una fiabilidad y validez sustancial por lo tanto, proporciona una herramienta potencial para examinar cuestiones relacionadas con los niveles de estrés.

Debido a que este trabajo necesitaba tener dos clases para diferenciar el estrés en los participantes y el test PSS solo indicaba que a mayor puntaje mayor estrés, se generaron las clases, estrés bajo y estrés alto, esto fue posible pues acuerdo a [Corchuelo et al., 2011] cada ítem se valora en una escala tipo Likert de cinco puntos. Donde la escala total tiene un puntaje de 0 a 56, puntaje que se dividió en las dos clases mencionadas. De acuerdo a [Sánchez et al., 2011] la escala de Likert está destinada a medir actitudes, predisposiciones individuales a actuar de cierta manera en contextos sociales específicos o bien a actuar a favor o en contra de personas, organizaciones, objetos, etc. Con base a lo anterior se utilizó el software estadístico IBM SPSS statistics v25, que permitió crear las dos clases mediante un sólo punto de corte en los datos que se le proporcionaron, las clases se generaron automáticamente a

## APÉNDICE A. ESCALA DE ESTRÉS PERCIBIDO (PSS) Y DIVISIÓN DEL ESTRÉS EN DOS

partir de la variable puntuacion como puede observarse en la figura: A.1, de esta manera se generaron las clases utilizadas .

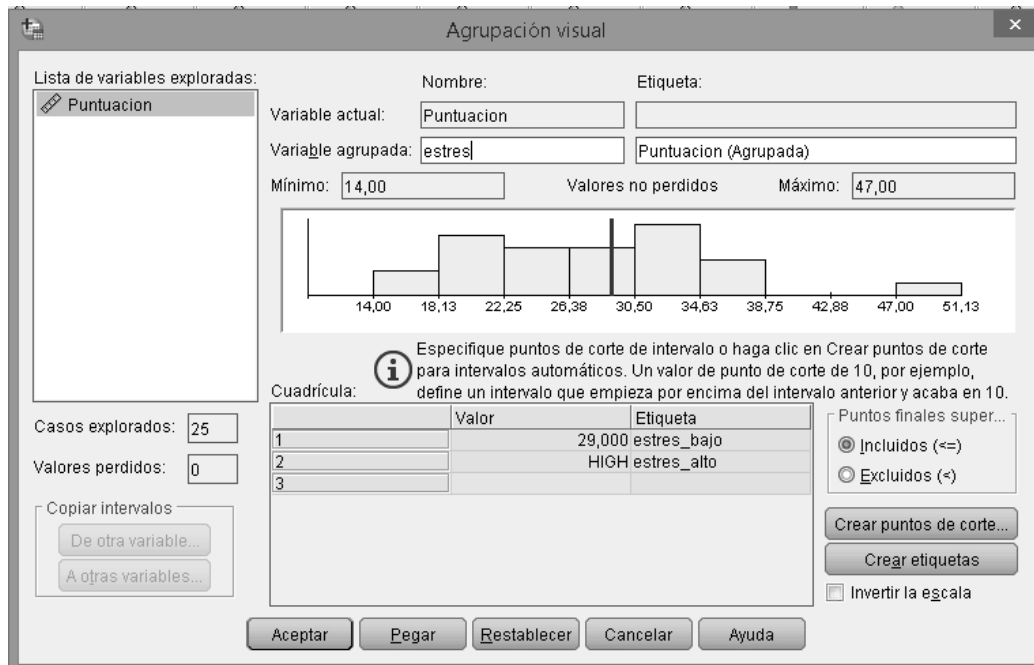


Figura A.1: Puntos de corte generados automáticamente en el software IBM SPSS para crear las clases: estrés bajo y estrés alto.

# Apéndice B

## Ejemplo del archivo arff generado

---

```
@RELATION coeficientes onda
@ATTRIBUTE AF3 REAL
@ATTRIBUTE F7 REAL
@ATTRIBUTE F3 REAL
@ATTRIBUTE FC5 REAL
@ATTRIBUTE T7 REAL
@ATTRIBUTE P7 REAL
@ATTRIBUTE O1 REAL
@ATTRIBUTE class {estres bajo , estres alto }
@DATA
4.621251,3.222787,2.862993,2.256606,1.534220,-0.085898,1.069754,
  estres_alto
-12.882963,-6.877446, 8.475276, 1.073220, 0.827725,4.469818, 0.629965,
  estres_alto
12.278757,0.924013,8.460999,3.148751,-0.568751, 0.024568,1.773519,
  estres_alto
2.304779,3.253615,-0.892696,9.248627,9.601713,3.355935,4.187433,
  estres_alto
-12.694992,+1.507451, 9.892872, 0.489880,6.605858,0.008359, 3.145615,
  estres_alto
14.551609,9.422241,9.390819,13.670337,1.981653,1.250318,5.452218,
  estres_alto
```

4.676549,2.933780,4.821405,-3.832687,8.414212,10.093560,11.834634,  
estres\_alto  
4.746086,-2.852888,4.096740,3.294349,5.250155,11.121241,5.422166,  
estres\_alto  
1.765878,-5.390550,2.580592,5.041122,6.241297,6.002566,3.980560,  
estres\_alto  
0.279156,6.496772,-4.815686,5.427165,1.724763,6.009853,0.905951,  
estres\_alto  
3.049161,-3.046547,0.025371,6.644059, 2-918837, 0-369955,2.788631,  
estres\_alto  
2.099160,8.111360,0.876436,8.525891,3.220675,4.299655,3.947210,  
estres\_alto  
3.740213,4.295387,3.538844,2.135105,3.446526,-1.547245,0.725680,  
estres\_alto  
5.751016,2.317499,-2.693567,0.700662,2.891099,4.426590,2.307114,  
estres\_alto  
5.830953,-3.224612, 6-737031,1.635541, 1.288951, 3.904668,9.041538,  
estres\_alto  
4.625742,4.388271,4.899151,8.365213,0.985726, 1-545140, 2-138545,  
estres\_alto

---

# Apéndice C

## Código para analizar señales EEG

---

```
arrfChannels= 'AF3' 'F7' 'F3' 'FC5' 'T7' 'P7' 'O1' 'O2' 'P8' 'T8' 'FC6' '
    F4' 'F8' 'AF4' }
path = uigetdir('C: \Users \personal Documents \MATLAB ', 'Selecciona
    carpeta para guardar EEG');
hold on;
axes(handles.axes1);
if path == 0
    errordlg(' Selecciona la carpeta donde almacenar los .arrf ', 'Error');
else
    for k = 1 :length(handles. allfiles )
        handles.sujeto = char(handles. allfiles (k));
        disp(handles.sujeto);
        dirfile =strcat(strcat(handles.selpath, ' '),handles.sujeto); input
        eeg =_csvread(dirfile,handles.startSample+2,2,[handles.
            startSample+2,2,handles.numSamples,15]);
        handles.eeg.raw = input_eeg (:,:) ;
        for pos = 1 :14
            if handles.selectedChannel(pos) == 1
                channel=pos;
                handles.channelSignal = handles.eeg.raw(:,channel);
                %levMax = wmaxlev(handles.channelSignal,handles.
                    usedWavelet); % maximo nivel de descomposicion
```

```

[c, l] = wavedec(handles.channelSignal, handles.level,
    handles.usedWavelet);
if (get(handles.checkbox16, 'value') == 0)
    %eliminacion de ruido
    start = l(1)+1;
    for i = 1 : handles.level ;
        endthr = start + l(i+1) - 1;
        c1 = c(start:endthr, 1);
        handles.threshold(i) = thselect(c1, handles.
            usedThreshold);
        c1_denoise = wthresh(c1, handles.applyThreshold,
            handles.threshold(i));
        c(start:endthr, 1) = c1_denoise;
        if ((i+handles.level) - (i+1)) == handles.
            analyzeCoef
            handles.eeg.indicted(:, channel) = c1_denoise;
            guidata(hObject, handles);
        end
        start = endthr+1;
    end
disp('ejecuta codigo con reduccion de ruido');
else
    start = l(1)+1;
    for i = 1 : handles.level ;
        endthr = start + l(i+1) - 1;
        if ((i+handles.level) - (i+1)) == handles.
            analyzeCoef
            handles.eeg.indicted(:, channel) = c(start:
                endthr, 1);
            guidata(hObject, handles);
        end
        start = endthr+1;
    end
end
clear c1;
end
    %plot(handles.channelSignal);
end
    %plot(handles.channelSignal);
    %crea archivo . arff

```

```

fileName=strrep(strcat(' \ strcat(handles.sujeto , ' . arff ' )), ' .csv
    ', ''');
fileID = fopen(strcat(path,fileName) , 'w');
fprintf( fileID , '@RELATION %s r n\ , \coeficientes onda');
for y = 1 : 14
    if (handles.selectedChannel(y) == 1)
        fprintf(fileID , '@ATTRIBUTE %s REAL r \n',
            arrfChannels{1,y});
    end
end
fprintf( fileID , '@ATTRIBUTE class {estres bajo , estres alto}
    \r \n');
fprintf( fileID , '@DATA r \n');

activeChannels = sum(handles.selectedChannel);
handles.format = '';
handles. field = '';
if activeChannels >= 1
    for x = 1 : 14
        if x <= sum(handles.selectedChannel)
            handles.format=strcat(handles.format, '%f, ');
        end
        if handles.selectedChannel(x) == 1
            handles. field = strcat( handles. field , strcat(' ,
                handles.eeg. indicted(date,' , strcat(int2str(x), '
                ) ' ) ) ) );
        end
    end
else
    disp('Selecciona al menos un canal');
end

create arrf=strcat(' fprintf ( fileID , ' ' ' , strcat(handles.format,
    strcat( handles. label, ' \r \n ' ' ' , strcat(handles. field , ' ) ; ')))
    );
disp( create arrf ) ;
for date = 1 : length(handles.eeg.indicted)
    eval( create arrf ) ;
end
fclose( fileID ) ;
%fin archivo arrf

```

```
end %fin for de archivos csv
helpdlg('Archivo Generado correctamente','Análisis EEG');
%channelSignalDenoise = waverec(c,l,usedWavelet); %reconstruccion
    de la senal con coeficientes umbralizados
disp('hecho pre-procesado');
end
```

---