

Trabajo Fin de Grado
Grado en Ingeniería de las Tecnologías de
Telecomunicación

Extracción de características de señales EEG para el
reconocimiento de emociones

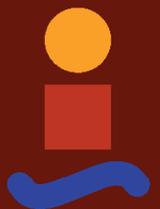
Autor: Santiago Rojas Camacho

Tutoras: María Auxiliadora Sarmiento Vega

Irene Fondón García

Dpto. Teoría de la Señal y Comunicaciones
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2020



Trabajo Fin de Grado
Grado en Ingeniería de las Tecnologías de Telecomunicación

Extracción de características de señales EEG para el reconocimiento de emociones

Autor:

Santiago Rojas Camacho

Tutoras:

María Auxiliadora Sarmiento Vega

Profesora Contratada Doctora.

Irene Fondón García

Profesora Titular.

Dpto. de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2020

Trabajo Fin de Grado: Extracción de características de señales EEG para el reconocimiento de emociones

Autor: Santiago Rojas Camacho

Tutor: María Auxiliadora Sarmiento Vega
Irene Fondón García

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2020

El Secretario del Tribunal

A mi familia

A mis amigos

A mis maestros

Agradecimientos

Y como cualquier cosa en la vida, todo acaba.

A punto de subir el último peldaño de esta escalera... y volviendo la vista atrás no queda más que agradecer a todos los que de alguna forma u otra me han ayudado e impulsado para que hoy pueda estar aquí.

En primer lugar, dar las gracias a mis padres, sin los cuales esto no podría haber sido posible. Por el esfuerzo realizado para que hoy pueda estar donde quiero, por los ánimos e impulsos para que no abandonara cuando ni yo mismo creía que fuera posible y por haber plasmado en mí unos valores que hacen que hoy pueda ser la persona que quiero. Eternamente agradecido.

Sin olvidar a mi hermana, la persona que constantemente me saca de mis casillas, pero sin ti... yo no. Gracias por los ánimos constantes y los empujoncitos necesarios sin los cuales seguro que no hubiese llegado a este último escalón.

Dar las gracias a mi pareja, mi compañera de vida, mi amiga y mi complemento ideal. Por aguantar mi carácter, las malas caras, los días malos, por los tús que necesitas cuando más se necesitan, por llenarme de vida y seguir al pie del cañón. Que el ritmo no pare.

A mis abuelos, por haberles hecho cumplir un sueño, por creer en mí aunque me enfrentara a lo imposible... “Pronto te reirás de los peces de colores”, dice ella mientras me mira desde su mecedora.

A compañeros y amigos que han llenado de historias todos estos años y que de alguna forma u otra han hecho esto más llevadero.

A los de siempre y para siempre.

A todos aquellos profesores que desde pequeño se han volcado en que creciera tanto personal como profesionalmente. A los que verdaderamente les apasiona enseñar, que aunque son pocos, se dejan notar.

A Auxi, por su implicación en el proyecto y hacer que todo este trabajo merezca la pena.

En definitiva, a todos y cada uno de los que han puesto su granito de arena en el camino para hacérmelo más fácil.

Y aunque esta etapa va tocando su fin... Lo mejor está aún por llegar, no tengo pruebas, pero tampoco dudas.

Santiago Rojas Camacho

Estudiante de Grado en Ingeniería de las Tecnologías de Telecomunicación

Sevilla, 2020

Resumen

En el estudio realizado analizamos la importancia de caracterizar las emociones del ser humano de forma automática y haciendo uso de registros EEG (Electroencefalografía) con el fin de realizar una exploración neurofisiológica basada en el registro de la actividad bioeléctrica cerebral. Lo hacemos con el objetivo de ayudar a diagnosticar y tratar enfermedades que impiden que se desarrolle la capacidad de expresar las emociones al mundo exterior y para buscar estados emocionales neutros que nos permitan ser más conscientes de los problemas y nos facilitan poder encontrar soluciones.

Muchos estudios han analizado imágenes físicas de los individuos cuando experimentan algún tipo de emoción, pero sacar conclusiones válidas de esto es sumo complicado, ya que incluso cualquiera de nosotros, sin tener ningún tipo de enfermedad asociada, somos capaces de mostrar felicidad cuando la tristeza nos invade.

Por este motivo, el estudio de señales fisiológicas se ha vuelto esencial para intentar combatir el problema anteriormente mencionado. Sin embargo, como queda demostrado en el desarrollo de este trabajo, la mayoría de las señales fisiológicas; como puede ser la presión arterial, el estudio de la respiración o la temperatura corporal, cambian con factores ambientales y no solamente emocionales. Es por eso por lo que el estudio de señales encefalográficas (EEG) ha sufrido un auge en los últimos tiempos debido a la enorme relación que tienen los procesos que se dan en el cerebro, sobretodo en el sistema límbico, con la generación de las emociones.

Durante el desarrollo de este estudio hemos replicado un algoritmo ya existente. Hemos construido una máquina de decisión que en base a unas características basadas en el procesamiento de señales EEG clasifica automáticamente el estado emocional en cuatro clases. La máquina se ha construido usando una base de datos etiquetada denominada 'DEAP'.

Aunque como veremos posteriormente, todavía queda margen de mejora y será necesario estudiar más características para encontrar una solución al problema sin que exista cabida a la duda.

Abstract

In the study carried out, we analyzed the importance of characterizing human emotions automatically and using EEG (Electroencephalography) records in order to carry out a neurophysiological examination based on the recording of brain bioelectric activity. We do this with the aim of helping to diagnose and treat diseases that prevent the ability to express emotions to the outside world from developing and to seek neutral emotional states that allow us to be more aware of problems and facilitate us to find solutions. Many studies have analyzed physical images of individuals when they experience some kind of emotion, but drawing valid conclusions from this is extremely complicated, since even any of us, without having any type of associated disease, are able to show happiness when sadness invades.

For this reason, the study of physiological signals has become essential to try to combat the aforementioned problem. However, as demonstrated in the development of this work, most of the physiological signals; such as blood pressure, the study of breathing or body temperature, change with environmental factors and not only emotional ones. That is why the study of encephalographic signals (EEG) has boomed in recent times due to the enormous relationship that the processes that occur in the brain, especially in the limbic system, have with the generation of emotions. . .

During the development of this study we have replicated an existing algorithm. We have built a decision machine that based on features based on EEG signal processing automatically classifies the emotional state into four classes. The machine has been built using a labeled database called 'DEAP'.

Although, as we will see later, there is still room for improvement and it will be necessary to study more characteristics to find a solution to the problem without room for doubt.

Índice

Agradecimientos	ix
Resumen	xi
Abstract	xiii
Índice	xiv
Índice de Tablas	xvi
Índice de ilustraciones	xvii
1 Objetivo	11
2 Las emociones	13
3.1- <i>CLASIFICACIÓN DE LAS EMOCIONES</i>	13
3.2- <i>EMOCIONES VS SENTIMIENTOS</i>	16
3.3- <i>¿CÓMO SE GENERAN LAS EMOCIONES?</i>	17
3.4- <i>¿CÓMO PODEMOS DETECTAR LAS EMOCIONES?</i>	20
3 Estado del arte	23
2.1- <i>REVISIÓN DEL ESTADO DEL ARTE</i>	24
4 Señales EEG	29
4.1- <i>¿CÓMO SE OBTIENEN?</i>	30
4.2- <i>SISTEMA DE POSICIONAMIENTO DE LOS ELECTRODOS</i>	31
4.3- <i>ONDAS CEREBRALES</i>	35
4.4- <i>PREPROCESAMIENTO DE SEÑALES EEG</i>	37
5 Base de datos ‘DEAP’	39
6 Algoritmo y Metodología	41
6.1- <i>TRATAMIENTO INICIAL CON LAS SEÑALES EEG</i>	42
6.2- <i>TRANSFORMADA EMD (DESCOMPOSICIÓN EMPÍRICA DE MODOS)</i>	43
6.3- <i>PSEUDOCÓDIGO PARA EL CÁLCULO DE LA TRANSFORMADA EMD</i>	43
6.3.1- <i>DIAGRAMA DE FLUJO DEL ALGORITMO</i>	45
6.3.2- <i>EJEMPLO</i>	46
6.3.3- <i>TRANSFORMADA EMD CON MATLAB</i>	48
6.4- <i>EXTRACCIÓN DE CARACTERÍSTICAS</i>	49
6.4.1- <i>PRIMERA DIFERENCIA DE FASE DE LAS FUNCIONES IMF</i>	49
6.4.2- <i>PRIMERA DIFERENCIA DE TIEMPO DE LAS FUNCIONES IMF</i>	51
6.4.3- <i>ENERGÍA NORMALIZADA DE LAS FUNCIONES IMF</i>	52
6.5- <i>CLASIFICACIÓN</i>	53
6.5.1- <i>HERRAMIENTA ‘CLASSIFICATION LEARNER’</i>	55
7- Resultados	59

7.1-	<i>ANÁLISIS REALIZADOS</i>	59
7.1.1-	CASO 1: 40 VÍDEOS/PRUEBAS, 32 CANALES, 12 FRAMES Y 5 IMF'S	60
7.1.2-	CASO 2: 40 VÍDEOS/PRUEBAS, 8 CANALES, 12 FRAMES Y 1 IMF	62
7.2-	<i>MEDIDA DE LA DESVIACIÓN ESTÁNDAR DE LOS CLASIFICADORES</i>	65
7.2.1-	DESVIACIÓN ESTÁNDAR CASO 1, AROUSAL	65
7.2.2-	DESVIACIÓN ESTÁNDAR CASO 1, VALENCIA	67
7.2.3-	DESVIACIÓN ESTÁNDAR CASO 2, AROUSAL	69
7.2.4-	DESVIACIÓN ESTÁNDAR CASO 2, VALENCIA	71
7.3-	<i>RESUMEN FINAL DE LOS RESULTADOS</i>	73
8-	Conclusiones	75
9-	Futuras líneas de investigación	77
	Referencias	79
	Anexo	83
	CASO 1: 40 VÍDEOS/PRUEBAS, 32 CANALES, 12 FRAMES, 5 IMF'S	83
	CASO 2: 40 VÍDEOS/PRUEBAS, 8 CANALES, 12 FRAMES, 1 IMF	86

ÍNDICE DE TABLAS

Tabla 1: Descripción de los distintos tipos de ondas cerebrales existentes con su frecuencia característica.	35
Tabla 2: Resultados del primer caso para la medida de arousal.	61
Tabla 3: Resultados del primer caso para la medida de valencia.	62
Tabla 4: Resultados del segundo caso para la medida de arousal	63
Tabla 5: Resultados del segundo caso para la medida de valencia.	64
Tabla 6: Resultados obtenidos para el caso 1 en la medida de arousal.	66
Tabla 7: Resultados obtenidos para el caso 1 en la medida de valencia.	68
Tabla 8: Resultados obtenidos para el caso 2 en la medida de arousal.	70
Tabla 9: Resultados obtenidos para el caso 2 en la medida de valencia.	72
Tabla 10: Resumen de los resultados de todos los casos por clasificador, junto con la desviación típica obtenida en cada uno de ellos y el resultado conseguido en [2] mediante LIBSVM.	73

ÍNDICE DE ILUSTRACIONES

Ilustración 1: Descripción gráfica de todos los problemas físicos derivados de trastornos emocionales [3].	12
Ilustración 2: Representación gráfica de la rueda de las emociones descrita por el psicólogo estadounidense Plutchik. [5]	14
Ilustración 3: Adaptación del modelo circumplejo de Rusell. [7]	16
Ilustración 4: Las cuatro principales emociones representadas por medio de emoticonos en la película de ‘Del revés’, de izquierda a derecha aparecen: el miedo, la alegría, la tristeza y el enfado. Representación de nuestro universo emocional [9].	17
Ilustración 5: Representación gráfica de las distintas partes de las que consta el sistema límbico, destacando aquellas de las que hablaremos en el siguiente punto [12].	18
Ilustración 6: Representación gráfica lateral y ventral del hipocampo, la vía de unión con el hipotálamo denominada fórnix y la amígdala [12].	19
Ilustración 7: Representación gráfica de los efectos que producen el sistema nervioso parasimpático y el sistema nervioso simpático cuando actúan [15].	20
Ilustración 8: Representación gráfica de los pasos seguidos en nuestro estudio.	24
Ilustración 9: (a) Un RBM contiene las neuronas de la capa oculta conectadas a las neuronas de la capa visible con pesos W . (b) Un DBN que usa el ajuste fino supervisado de todas las capas con propagación hacia atrás. (c) La representación gráfica de DBN desenrollada utilizando sintonización fina no supervisada de todas las capas con retropropagación [23].	27
Ilustración 10: Descripción gráfica del electrodo de contacto, en la figura A podemos apreciar su estructura mientras que en la figura B vemos como se colocan sobre la cabeza del paciente [25].	31
Ilustración 11: Representación gráfica de los electrodos en casco de malla [25].	31
Ilustración 12: Representación gráfica de los puntos craneométricos, resaltando con un rectángulo los explicados con anterioridad [27].	32
Ilustración 13: En A podemos observar una representación gráfica a vista de perfil sobre el trazado entre el nasión y el inion. Mientras que en B visualizamos una vista superior. En ambos casos se muestran los puntos Fp y O [26].	33
Ilustración 14: En A observamos los puntos temporales mediales separados un 10 % del preauricular. Mientras que en B tenemos una vista frontal de los puntos mencionados hasta este momento [26].	33
Ilustración 15: Representación gráfica frontal de los electrodos estudiados hasta este punto [26].	34
Ilustración 16: Estructura final del sistema internacional de colocación de electrodos 10 -20 [26].	35
Ilustración 17: Representación gráfica del tipo de onda cerebral Delta [28].	36
Ilustración 18: Representación gráfica del tipo de onda cerebral Theta [28].	36

Ilustración 19: Representación gráfica del tipo de onda cerebral Alfa [28].	36
Ilustración 20: Representación gráfica del tipo de onda cerebral Beta [28].	37
Ilustración 21: Representación gráfica del tipo de onda cerebral Gamma [28].	37
Ilustración 22: Representación gráfica de uno de los individuos que formaron parte de la recopilación de datos para la base de datos 'DEAP', podemos apreciar la colocación del casco de electrodos en malla [31].	40
Ilustración 23: Descripción gráfica de los pasos desarrollados en la realización del trabajo y que posteriormente pasaremos a explicar uno por uno.	41
Ilustración 24: Recorte de una parte del código, donde podemos apreciar la lectura de la señal, en este caso, correspondiente al segundo individuo del estudio. Al tratarse de un elemento struct nos quedamos solo con los datos. Y finalmente me interesa quedarme con la información correspondiente a todas las pruebas (40), a determinados canales (dependiendo del experimento a tratar) y con los 60 segundos de estudio, eliminando los 3 segundos iniciales.	42
Ilustración 25: Recorte de la parte de código donde se realiza la división de la señal en 12 trozos de 5 segundos de duración. De tal manera que $nframe = 12$ y posteriormente tenemos almacenado en <code>senal_aux</code> , los videos, canales, la duración de cada señal ($5 * 128 = 640$) y los 12 frames.	42
Ilustración 26: Diagrama de flujo donde queda constancia de los pasos explicados en el punto anterior, en este caso, $d(t) = h_{new}(t)$ [33].	45
Ilustración 27: Figuras representativas del ejemplo anterior [32].	47
Ilustración 28: Implementación en Matlab de la función EMD utilizada en nuestro estudio sobre la caracterización de las emociones.	48
Ilustración 29: Cálculo con Matlab de la primera diferencia de fase para el individuo 2.	51
Ilustración 30: Cálculo con Matlab de la primera diferencia de tiempo para el individuo 2.	52
Ilustración 31: Cálculo con Matlab de la energía normalizada para el individuo 2. En este caso, <code>senal_aux</code> almacena la señal EEG original.	53
Ilustración 32: Realización con Matlab del paso explicado en el punto anterior, unificando cada una de las tres características en un vector columna, cuyas dimensiones dependen del experimento que estemos realizando.	53
Ilustración 33: Descripción gráfica de los pasos explicados en el punto anterior.	55
Ilustración 34: Representación gráfica de la ventana que se nos abre cuando insertamos una variable para clasificar.	56
Ilustración 35: Representación gráfica de la pantalla correspondiente a la vista principal de la herramienta utilizada para clasificar.	57
Ilustración 36: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Medium tree'.	65
Ilustración 37: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Linear Discriminant'.	65
Ilustración 38: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Linear SVM'.	66
Ilustración 39: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Subspace discriminant'.	66
Ilustración 40: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador 'Medium tree'.	67
Ilustración 41: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador 'Linear Discriminant'.	67
Ilustración 42: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador 'Linear SVM'.	68

Ilustración 43: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador ‘Subspace discriminant’.	68
Ilustración 44: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador ‘Medium tree’.	69
Ilustración 45: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador ‘Linear Discriminant’.	69
Ilustración 46: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador ‘Linear SVM’.	70
Ilustración 47: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador ‘Subspace discriminant’.	70
Ilustración 48: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador ‘Medium tree’.	71
Ilustración 49: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador ‘Linear Discriminant’.	71
Ilustración 50: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador ‘Linear SVM’.	72
Ilustración 51: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador ‘Subspace discriminant’.	72
Ilustración 52 : Representación gráfica de todos los resultados obtenidos por clasificador y casos, junto con la desviación típica.	74

Notación

arctan	Arcotangente
BPS	Volumen de pulso sanguíneo
SC	Conductividad de la piel
DBN	<i>Deep Belief Network</i>
DCAU	Diferencial de caudalidad
DLAT	Diferencial de lateralidad
ECG	Electrocargiograma
ECoG	Electrocorticograma
E-EEG	Estéreo encefalograma
EEG	Electroencefalografía
E _{max}	Envolvente superior
EMD	Descomposición empírica de modos
E _{min}	Envolvente inferior
E _{norm}	Energía normalizada
FFT	Transformada rápida de Fourier
fNIR	Espectroscopía funcional del infrarrojo cercano
GSR	Respuesta galvánica de la piel
HAHV	Alta excitación, alta valencia
HALV	Alta excitación, baja valencia
HHT	Transformada de Hilbert-Huang
ICA	Análisis de componentes independientes
IIEE	Instituto de ingenieros eléctricos y electrónicos
IMF	Función de modo intrínseco
LAHV	Baja excitación, alta valencia
LALV	Baja excitación, baja valencia
LTO	<i>Live-trial-out</i>
Máx	Máximo
Mín	Mínimo
RAE	Real academia española
RBM	Máquina de Boltzmann restringida
SVM	Máquina de vectores de soporte

1 OBJETIVO

El objetivo principal del proyecto consiste en replicar un algoritmo de extracción de características en señales EEG para clasificar las emociones humanas.

El estudio se ha llevado a cabo puesto que existen múltiples campos donde las emociones del ser humano tienen especial importancia, siendo el más destacado el ámbito de la psicología.

Hoy en día muchas son las enfermedades relacionadas con las emociones, como pueden ser el autismo, la depresión, el trastorno bipolar, trastorno de ansiedad o la esquizofrenia, pero no solamente hablamos de enfermedades mentales. Tal y como relata Patricia Florín en [1] este tipo de enfermedades están altamente relacionadas con enfermedades físicas como pueden ser el dolor de cuello, tensión en la espalda, problemas de estómago, problemas en la piel, sobrepeso... en definitiva, un conjunto de enfermedades degenerativas que en el peor de los casos pueden ocasionar la muerte del individuo. En la Ilustración 1 podemos observar un resumen de como afectan las emociones a las diferentes partes del cuerpo. Quizás sea difícil imaginar que las emociones estén detrás de todo esto, pero para ponernos en situación pensemos en un ejemplo bastante cotidiano, todos alguna vez hemos engañado a la sociedad, aparentando una emoción que realmente no sentíamos, por ejemplo, emulando felicidad cuando realmente por dentro estamos tristes. Este caso, en personas sin ningún tipo de trastorno lo podemos controlar, sabemos diferenciar lo que realmente estamos sintiendo de lo que aparentamos sentir. El problema aparece cuando las personas no son capaces de expresar al mundo exterior lo que sienten, no muestran afecto y esto hace que les cueste relacionarse con el mundo que les rodea. Otro ejemplo sería personas que se centran en un momento determinado en un problema, este les hace sentir mal y no consiguen traspasar esa barrera para poder encontrar soluciones. Con estudios como el mostrado a continuación queremos intentar facilitar el diagnóstico de forma que los problemas emocionales no lleguen a desarrollar enfermedades más complejas y se encuentren soluciones de manera más rápida y eficaz. Al mismo tiempo, que pretendemos ayudar en otros campos de la psicología, donde hacer encontrar un estado emocional neutro permite a las personas ser más conscientes de los problemas y actuar en consecuencia.

Para ello nos hemos centrado en replicar el algoritmo propuesto por Ning Zhuang et al en [2] que mediante la transformada EMD (Descomposición Empírica de Modos) nos permite obtener una serie de características que están estrechamente ligadas a la aparición de emociones, para posteriormente mediante una herramienta de clasificación ser capaces de clasificar automáticamente tanto arousal (alta / baja) como valencia (alta / baja). Como explicaremos en puntos posteriores, se trata de una clasificación dimensional de las emociones, donde arousal hace referencia al nivel de activación cerebral y la valencia al rechazo o agrado que podemos sentir por un estímulo.

Como veremos durante el desarrollo del trabajo, para el estudio hemos utilizado datos recopilados en una base de datos de nominada 'DEAP' que recoge información sobre 32 individuos, a los

cuales se les captan señales EEG mientras que se les excita en mayor o menor medida, con vídeos musicales representativos de emociones.

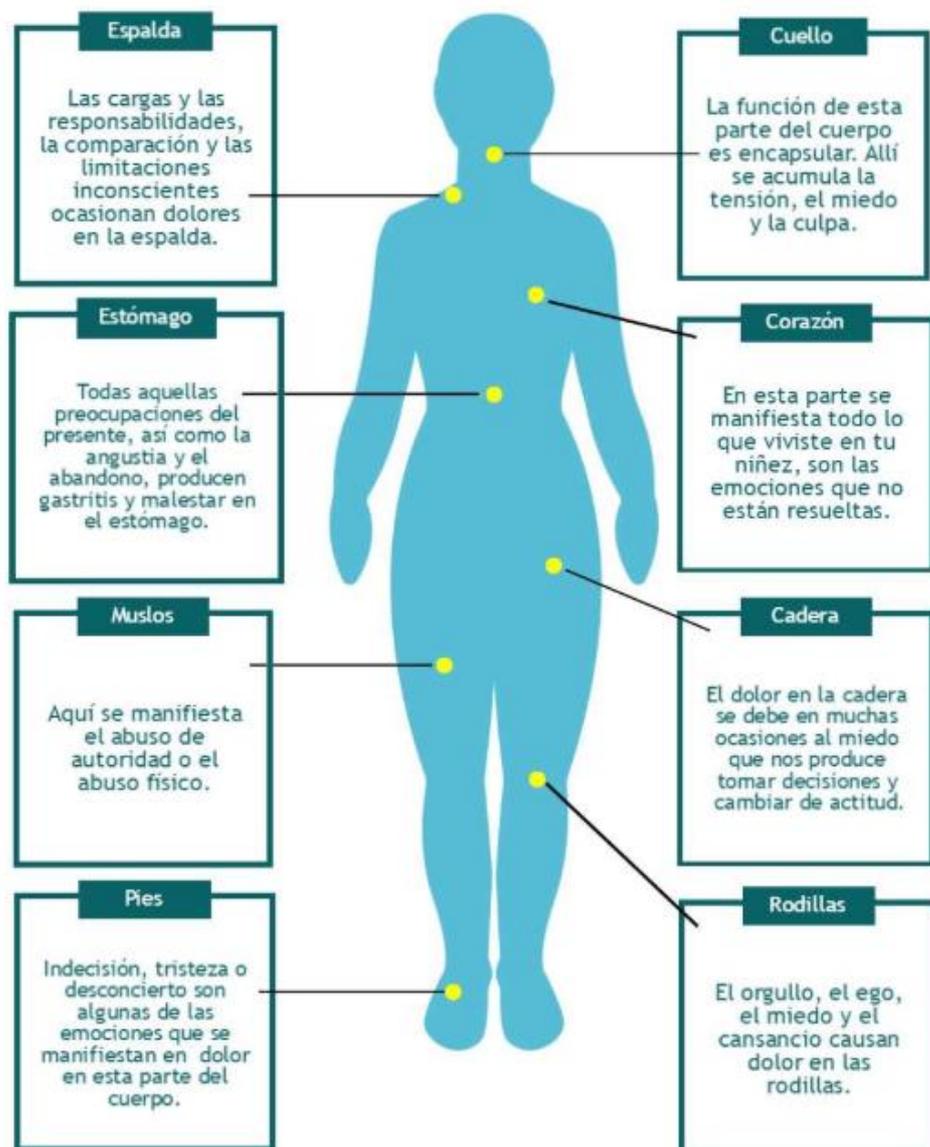


Ilustración 1: Descripción gráfica de todos los problemas físicos derivados de trastornos emocionales [3].

2 LAS EMOCIONES

Para comenzar a introducirnos en este complejo mundo de las emociones, vamos a presentar a éstas con una definición que hacen Francisco Mora et al en [4], “La emoción es ese motor que todos llevamos dentro. Una energía codificada en ciertos circuitos neuronales localizados en zonas profundas de nuestro cerebro (en el sistema límbico) que nos mueve y nos empuja a ‘vivir’, a querer estar vivos en interacción constante con el mundo y con nosotros mismos. Circuitos que, mientras estamos despiertos, se encuentran siempre activos, en alerta, y nos ayudan a distinguir estímulos importantes para nuestra supervivencia”.

Si hacemos reflexión sobre la definición anterior, se define la emoción como una energía que nos empuja a vivir, es decir, ¿qué sería de nosotros sin las emociones? Sin embargo, no son subjetivas del todo ya que tienen un fundamento científico puesto que se desarrollan en una parte del cerebro. El principal problema radica en que somos capaces de camuflar las emociones y esto se convierte en problema cuando las emociones están asociadas a algún tipo de enfermedad. De ahí la importancia de lograr desarrollar un método, una herramienta, que sea capaz de identificar la verdadera emoción que está experimentando una persona en un momento determinado. Esto se realiza con el fin de poder ayudar a personas que no son capaces de expresar sus emociones debido a enfermedades como el autismo, donde el individuo se centra mayoritariamente en su mundo interior y no es capaz de exteriorizar lo que siente. También se emplea para entrenar la neutralidad emocional, es decir, en situaciones donde prima lo blanco o lo negro, los extremos, felicidad o tristeza; hacer llevar al individuo a un estado neutro que permita elevarlo sobre el problema para que sea capaz de pensar sobre el mismo, recabar más información y de esta forma, tomar mejores decisiones.

3.1- CLASIFICACIÓN DE LAS EMOCIONES

Generalmente se destacan cuatro emociones básicas que forman nuestro universo emocional. Éstas son: la alegría, la tristeza, el enfado y el miedo. Sin embargo, tal y como nos cuenta Iván Pico en [5], Robert Plutchik, psicólogo estadounidense, desarrolló una teoría evolucionista sobre las emociones y dividió estas en 8 categorías básicas que son: alegría, confianza, miedo, sorpresa, tristeza, aversión, ira y anticipación. Según esta teoría, el resto de las emociones son combinaciones de las básicas. Además, propuso una forma gráfica de representarlas como es la rueda de las emociones que podemos ver en la Ilustración 2.

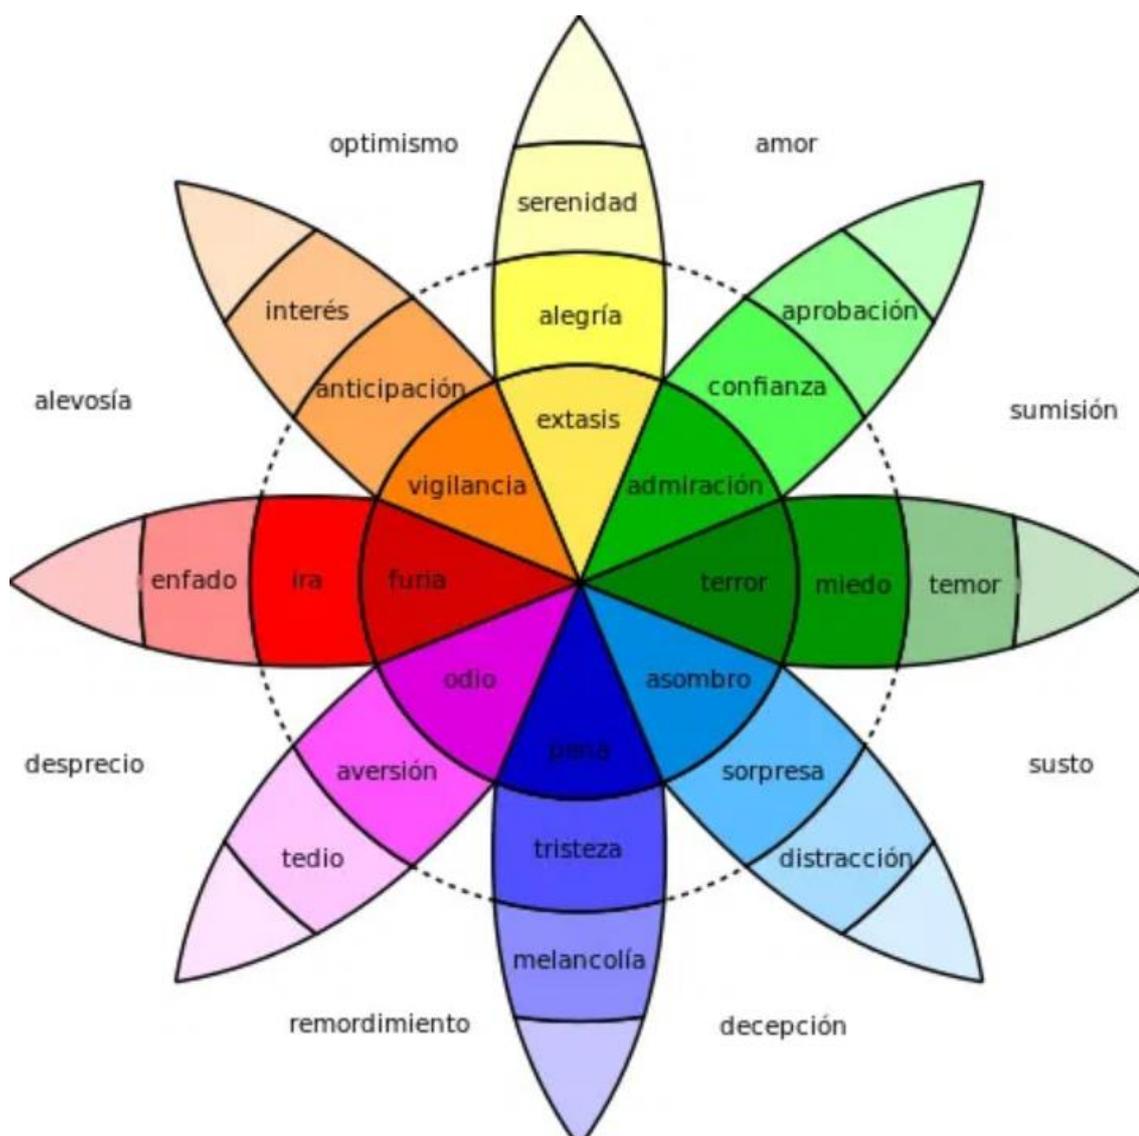


Ilustración 2: Representación gráfica de la rueda de las emociones descrita por el psicólogo estadounidense Plutchik. [5]

Las ocho emociones básicas combinadas dan lugar a ocho emociones avanzadas: amor, sumisión, susto, decepción, remordimiento, desprecio, alevosía y optimismo. Cada una de estas emociones avanzadas está formada por la unión de dos emociones básicas. Por ejemplo, el amor se forma mediante la intersección de la alegría y la confianza. Así formamos todas las emociones que se engloban en la rueda.

Por otro lado, presenta un gran interés el estudio de la dimensionalidad del estado emocional, como nos cuenta María Benigna en [6], a partir del planteamiento dimensional del filósofo y psicólogo Wundt (1886) que señalaba que los sentimientos se podían analizar en base a tres dimensiones: agrado – desagrado, tensión – relajación, excitación – calma; se desarrolló una teoría sobre las emociones que subyacen a la experiencia emocional, la cual nos dice que todas las emociones comparten características que se pueden agrupar en dos o tres dimensiones: valencia (placer – no placer), arousal o intensidad (excitación – tranquilidad) y control (continuidad o interrupción de la secuencia conductual).

- **Valencia.** Relacionada con el agrado y rechazo que produce un estímulo. Podríamos describirla como un hilo continuo con dos extremos bien definidos, por un lado, la tristeza ocuparía el extremo más negativo y la felicidad el extremo más positivo. Toda emoción se dice que se puede clasificar mediante este hilo conductor, donde en un extremo se encuentra aquello que produce placer y en el otro extremo lo que produce rechazo. Para ser capaces de medir la valencia, necesitamos la opinión del individuo, que nos informe de lo que ha sentido en un instante determinado.
- **Arousal.** Fácilmente relacionable con la activación e intensidad. Se trata de una dimensión que subyace a todas las conductas. La activación es una función directa que tiene lugar en nuestro organismo como consecuencia de una determinada emoción. Las respuestas de máxima activación, generalmente, se producen en situaciones de ira o miedo (con valencia negativa) y alegría (con valencia positiva); las de menor activación en situaciones de tristeza (con valencia negativa) y en casos de serenidad (con valencia positiva).
- **Control.** Si pensamos, es cierto que la mayoría de las emociones básicas las podemos clasificar directamente de acuerdo a la valencia y a la activación o arousal. Sin embargo, si ya incluimos el conjunto de todas las emociones, las dos características anteriores se nos quedan cortas, por este motivo, se define el control. Se trata de diferenciar aquellas emociones que el sujeto es capaz de dominar, es decir, de tener bajo control, de las que no.

En nuestro estudio analizaremos las emociones desde el punto de vista dimensional, haciendo hincapié en la valencia y activación o arousal.

Destacar el modelo circunplejo de James Rusell y Lisa Fieldman donde se sugiere que las emociones están distribuidas en un espacio circular de dos dimensiones, donde en el eje vertical se representa la excitación o arousal y en el eje horizontal la valencia tal y como podemos apreciar en la Ilustración 3. De este modo, alrededor de los dos ejes se forma un círculo con el conjunto de emociones de acuerdo al grado de arousal y valencia en el que nos encontremos. Tal y como nos dicen José Miguel Mestre y Rocío Guil Bozal en [7] la idea fundamental que debemos entender sobre dicho modelo consiste en que los estados emocionales están mejor representados en un círculo con dimensiones bipolares que en dimensiones independientes. Fundamentalmente, porque dependiendo del nivel de arousal y de valencia los estados afectivos cambian de una situación desadaptativa a otra adaptativa o viceversa.

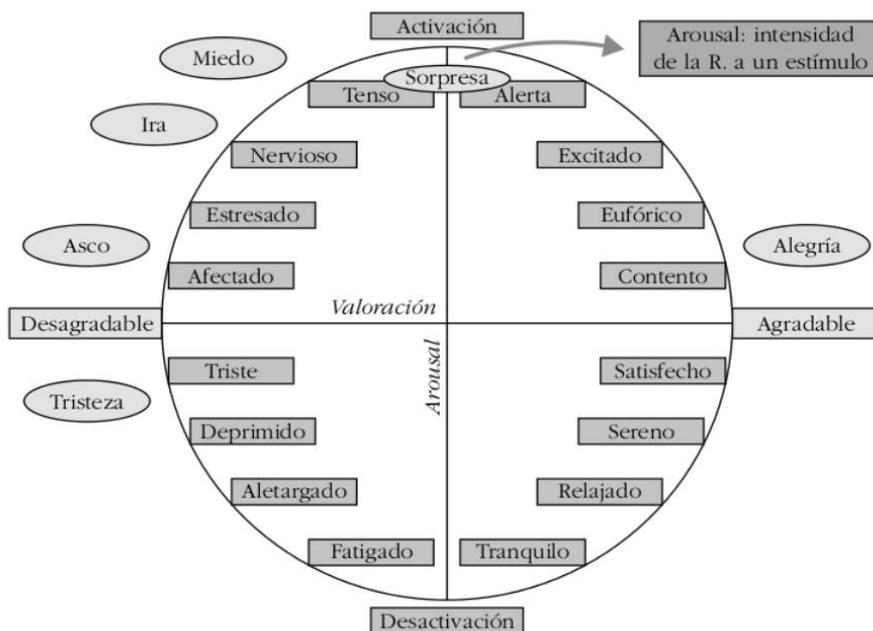


Ilustración 3: Adaptación del modelo circunplejo de Russell. [7]

3.2- EMOCIONES VS SENTIMIENTOS

Aunque aparentemente los dos términos hacen referencia a lo mismo, lo cierto es que tienen significados diferentes.

La emoción como explicamos al principio es una reacción del cerebro ante un estímulo externo o interno [8]. Es algo transitorio, no permanente que nos empuja a la acción. Para entenderlo mejor vamos a explicarlo con un ejemplo, imaginemos que hemos planeado un viaje, lo tenemos todo pagado, el avión, el hotel, las visitas... y de pronto, a causa de una pandemia mundial, el viaje queda suspendido. Lo primero que sentimos es enfado y eso sería lo que se definiría como emoción.

Parece que cuanto más sabemos de las emociones, más las confundimos con los sentimientos. Pero, ¿qué son realmente los sentimientos?

Un sentimiento se puede definir como la suma de una emoción y un pensamiento, es decir, en el sentimiento interviene además de la reacción fisiológica un componente subjetivo y cognitivo. Al contrario de las emociones, la duración de los sentimientos suele ser mayor, éstos van a durar el tiempo que pensemos en ellos. No hay sentimiento sin emoción. Si seguimos con el ejemplo anterior, el del viaje cancelado, seguramente una vez ya seamos conscientes de lo ocurrido pensemos en todo aquello que podríamos haber hecho si el viaje se hubiese podido llevar a cabo, esto nos generaría añoranza, pena... pues esa sensación es lo que se conoce como sentimiento.

Por lo tanto, podemos concluir que lo que distingue principalmente a la emoción del sentimiento es la duración, la intensidad y que la emoción es una reacción automática de nuestro cuerpo.

En la Ilustración 4 podemos observar las cuatro emociones básicas, representadas mediante personajes de la película 'Del revés', que componen nuestro universo emocional y que en muchas ocasiones confundimos con los sentimientos.



Ilustración 4: Las cuatro principales emociones representadas por medio de emoticonos en la película de ‘Del revés’, de izquierda a derecha aparecen: el miedo, la alegría, la tristeza y el enfado. Representación de nuestro universo emocional [9].

3.3- ¿CÓMO SE GENERAN LAS EMOCIONES?

Tal y como nos explica Adrián Triglia en [10] el sistema límbico es una de las redes neuronales más importantes cuando hablamos del comportamiento de los seres humanos, es tal la importancia que en muchos casos se denomina ‘cerebro emocional’.

Dicho sistema como podemos ver en [11] no constituye una región encefálica separada, sino que está integrado por un conjunto de estructuras ubicadas en diferentes áreas que se hallan dispuestas, principalmente, a ambos lados del tálamo, es decir, por debajo del cerebro, y que establecen múltiples conexiones neuronales entre ellas. A este sistema pertenecen áreas tales como la corteza cerebral, los núcleos basales, el tálamo y el hipotálamo.

Como vemos, el sistema límbico parece ser el principal responsable de nuestra vida emocional, es decir, la emoción se genera en una parte del cerebro que podemos estudiar, de ahí la importancia de desarrollar técnicas que faciliten el estudio de las emociones desde un punto de vista objetivo, ya que el gesto aparente es muy fácil de trazar y da lugar a un desconcierto que la ciencia debe eliminar para poder ayudar en la investigación y prevención y cura principalmente de enfermedades psíquicas.

A continuación, vamos a describir las partes más importantes del sistema límbico que se ven involucradas en la generación de las emociones, como son:

- Hipotálamo
- Hipocampo
- Amígdala

Además hablaremos de otros sistemas que se ven involucrados en la generación de las emociones y que no se conocen tanto como son:

- Sistema nervioso parasimpático
- Sistema nervioso simpático
- Sistema nervioso entérico

SISTEMA LÍMBICO

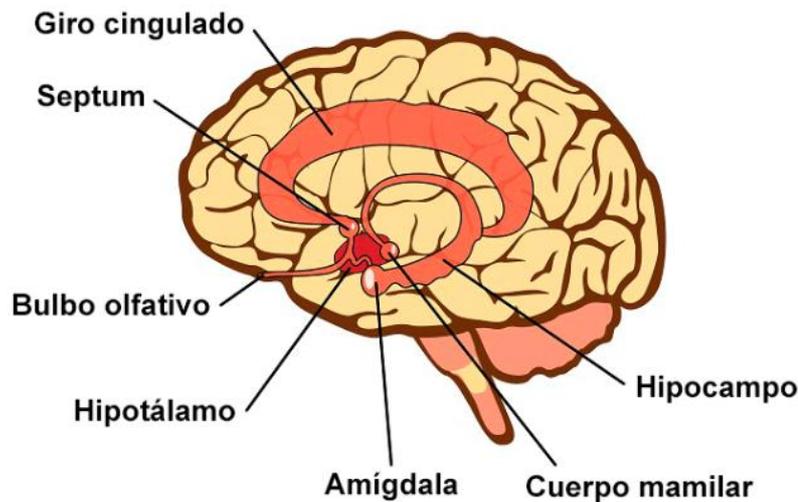


Ilustración 5: Representación gráfica de las distintas partes de las que consta el sistema límbico, destacando aquellas de las que hablaremos en el siguiente punto [12].

- **Hipotálamo** [13]: Se trata de una pequeña estructura que forma parte del encéfalo, situada bajo el tálamo, sin la cual no podríamos ni pensar ni adaptarnos al entorno. Como podemos ver en la Ilustración 5 su tamaño es pequeño y se encuentra escondido con el objetivo de protegerse de agentes externos. Juega un papel fundamental puesto que trata de coordinar y comunicar dos mundos independientes, por un lado las neuronas y por otro lado las hormonas. Este hecho hace que sea una de las estructuras cerebrales con un papel más importante en la regulación de las emociones y los estados fisiológicos. Además de actuar como puente entre el cerebro y el sistema endocrino, coordina todo lo que se realiza a través del sistema nervioso autónomo, es decir, el que le envía órdenes a partes del cuerpo para que estas se adapten a cada situación.

Dentro del hipotálamo se lleva a cabo un proceso denominado homeostasis consistente en que una vez que el hipotálamo recibe la información acorde a algún determinado estímulo, tiene que tramitar las órdenes a todas las partes del cuerpo con el fin de que nada de lo que ocurra en el interior del organismo rompa el equilibrio de cómo debe funcionar la globalidad del cuerpo. Destacar que uno de los aspectos claves de esta parte del sistema límbico es su ubicación, esto hace que la conexión con el sistema nervioso sea sencilla mientras que además conecta con el sistema endocrino por medio de una pequeña estructura llamada hipófisis o glándula pituitaria encargada de generar hormonas.

- **Hipocampo** [12]: Como vemos en la Ilustración 6, el hipocampo es una lámina de corteza curva ubicada en la superficie media del lóbulo temporal. La actividad más importante relacionada con esta parte del sistema límbico es el aprendizaje y la consolidación de la memoria, permite que la memoria a corto plazo se consolide y se transforme en memoria a largo plazo. Si dicha estructura se daña, una persona será incapaz de reconstruir recuerdos. La formación hipocampal tiene acceso a casi todos los tipos de información sensorial. Recibe información del hipotálamo por medio de una vía denominada fórnix.

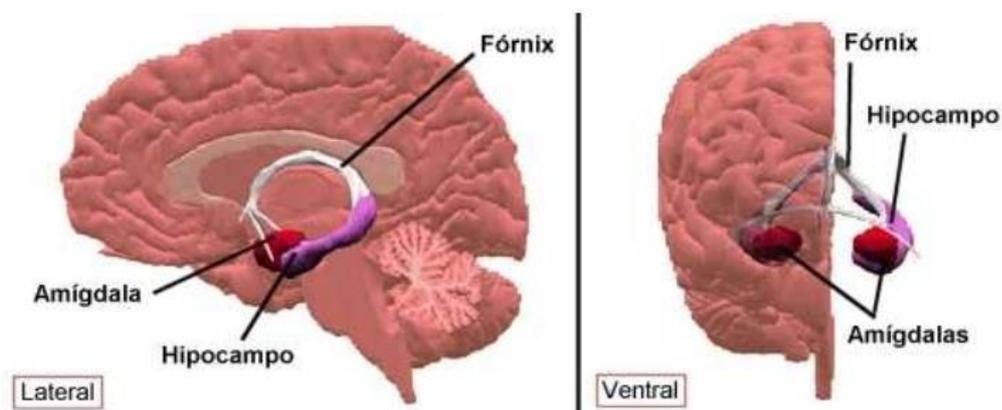


Ilustración 6: Representación gráfica lateral y ventral del hipocampo, la vía de unión con el hipotálamo denominada fórnix y la amígdala [12].

- **Amígdala** [12]: Se trata de dos masas de neuronas en forma de almendra a cada lado del tálamo tal y como podemos ver la en Ilustración 6, en el extremo inferior del hipocampo. Los núcleos de las amígdalas se pueden dividir en tres grupos, formando parte del sistema límbico los núcleos basolaterales y los centrales. Se constituye como un elemento clave para las experiencias emocionales, ya que de éstas dependen los estímulos a los que respondemos, el modo en que se organizan las respuestas que manifestemos a estos estímulos, así como las respuestas internas de nuestros órganos. Por ejemplo, cuando nos estamos bañando en la playa y algo nos toca la pierna, la amígdala es la que interpreta ese estímulo como una amenaza, que se sienta miedo y se actúe en consecuencia. En conclusión, la amígdala da significado emocional a la experiencia y hace que se produzca una respuesta emocional subjetiva y una respuesta endocrina, autonómica y conductual adecuada a la situación.

Como acabamos de explicar, el sistema límbico tiene máxima importancia en la generación de las emociones. Sin embargo, no solamente esta parte del sistema nervioso interactúa en la generación de las mismas. De esta forma, destacar también la función del sistema nervioso autónomo. Tal y como explica George Boeree en [14], dicho sistema consta de dos partes, las cuales funcionan en oposición la una de la otra. Por un lado tenemos el **sistema nervioso simpático**, que tiene origen en la médula espinal y se encarga de preparar al cuerpo para situaciones relacionadas con el peligro, como puede ser la huida de un determinado lugar o la violencia. Entre los efectos capaces de generar el sistema nervioso simpático se encuentran: dilatación de las pupilas, estimulación de las glándulas sudoríparas, dilatación de los vasos sanguíneos de los músculos más grandes, aumento de la presión cardíaca, abertura de los tubos bronquiales de los pulmones, liberación de epinefrina en la sangre (la epinefrina es una hormona que provoca que varias partes del cuerpo actúen de la misma forma que el sistema nervioso simpático), etc. Por otro lado, la otra parte del sistema nervioso autónomo se conoce como **sistema nervioso parasimpático**, comienza en el tronco cerebral y en la médula espinal de la espalda baja. Su función principal consiste en recuperar el estado del cuerpo anterior a que se activara el sistema nervioso simpático. Entre las respuestas de este sistema se encuentran: activación de las glándulas salivares, estimulación de las secreciones en el estómago, estimulación de la actividad de los intestinos, estimulación de las secreciones de los pulmones, decremento de la tasa cardíaca, etc. En la Ilustración 7 podemos observar los efectos de ambos sistemas en el organismo. Finalmente, mencionar que existe otra parte del sistema nervioso autónomo que no se suele tener en cuenta, consiste en el **sistema nervioso entérico**, íntimamente relacionado con la actividad del estómago y culpable de que por ejemplo, cuando nos encontramos nerviosos, sintamos ‘mariposas’ en el estómago.

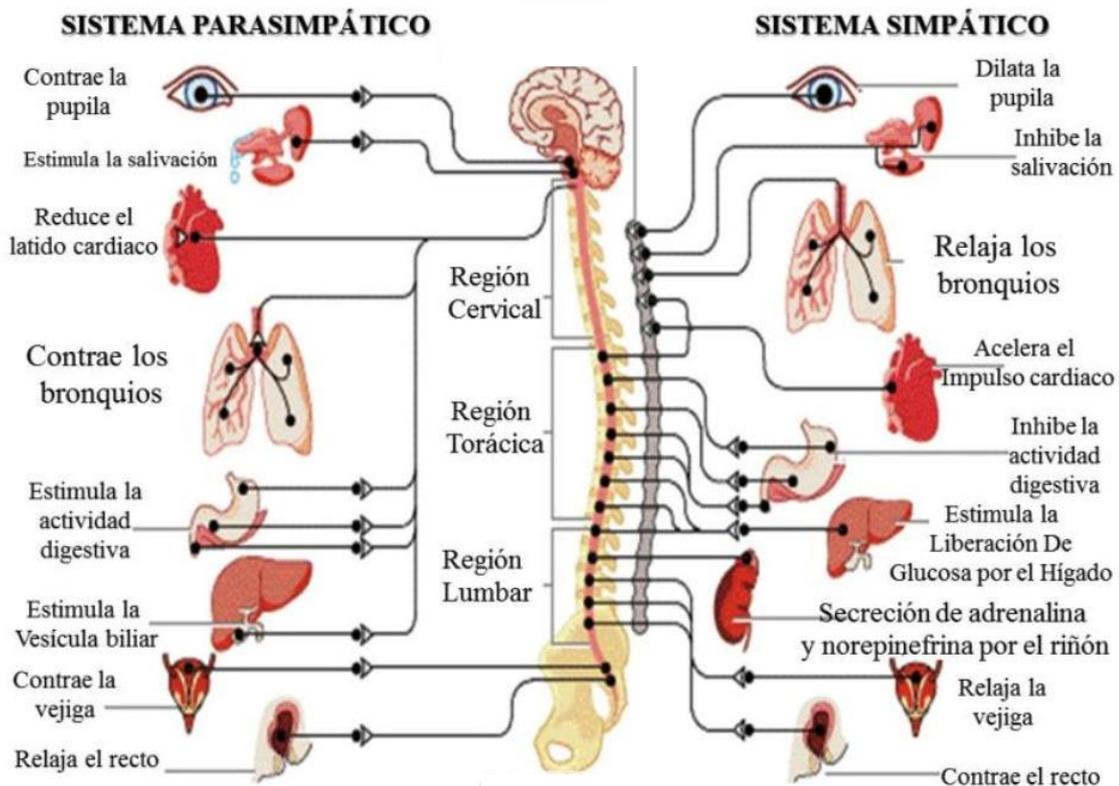


Ilustración 7: Representación gráfica de los efectos que producen el sistema nervioso parasimpático y el sistema nervioso simpático cuando actúan [15].

3.4- ¿CÓMO PODEMOS DETECTAR LAS EMOCIONES?

Tal y como describe Julián Barranca [16], existen diferentes técnicas que se han ido utilizando con el objetivo de intentar detectar emociones en los seres humanos, siendo las que hacen uso de biosensores las que mejores resultados suelen dar. Vamos a proceder a describir las principales técnicas que hacen uso de biosensores utilizadas con el fin de intentar localizar la que a nuestro criterio nos parece mejor o más interesante. Entre ellas, destacar: electrocardiograma, volumen de pulso sanguíneo, medida de la respiración, conductividad de la piel y actividad encefalográfica.

Como ya hemos comentado con anterioridad, las emociones producen cambios fisiológicos notables, como puede ser el aumento de la respiración o del flujo sanguíneo. El uso de biosensores presenta ciertas ventajas frente al uso de detecciones de expresiones faciales, voz o posturas corporales. Debido al pequeño tamaño de estos sensores, la monitorización de datos constantes puede ser una realidad haciendo que se puedan medir emociones naturales y no impuestas por algún tipo de medio externo (vídeos, imágenes, música). Sin embargo, el principal inconveniente es que no solamente las emociones alteran los marcadores fisiológicos y no todas las personas responden de la misma manera ante igual estímulo, de ahí la complejidad. Entre los biosensores que se pueden utilizar cabe destacar los siguientes:

- **Electrocardiograma (ECG):** Con el ECG se mide la actividad eléctrica del corazón registrada con electrodos ubicados en la superficie del cuerpo. Los sensores en este caso se colocan sobre la superficie del pecho. Con este tipo de biosensor podemos medir distintas señales fisiológicas, como pueden ser la frecuencia cardiaca, los intervalos entre latidos del corazón, la variabilidad de la frecuencia cardiaca y la arritmia respiratoria. De tal manera, que se pueden asociar eventos como un decremento de la frecuencia cardiaca a un estado de relajación o un

aumento de los intervalos entre latidos a una situación de estrés. Sin embargo, también se pueden alterar estos marcadores sin tenerse que presentar un estado determinado.

- **Volumen de pulso sanguíneo (BPS):** Este biosensor se encarga de medir de forma no invasiva los cambios relativos de volumen sanguíneo en las venas del dedo índice, indicando la cantidad de sangre que circula en un instante determinado por las venas, lo que permite calcular la vasoconstricción, la dilatación vascular, frecuencia cardíaca y la hipovolemia. De la misma manera, si los niveles de pulso sanguíneo o vasoconstrucción son altos podemos estar hablando de una situación de furia o estrés y si estos niveles se reducen demasiado podemos estar hablando de una situación de tristeza o relajación.
- **Respiración (RSP):** Este biosensor mide los cambios de respiración por medio de una banda sujeta al pecho del usuario. Podemos medir parámetros como la frecuencia respiratoria y la profundidad de respiración. Proporcionándonos estos parámetros información sobre situación de relajación, depresión, estrés... dependiendo de si los niveles de respiración son demasiado rápidos o lentos.
- **Conductividad de la piel (SC):** Conocido también como biosensor de la actividad eléctrica de la dermis, sirve para medir la capacidad de la piel para la transmisión de corrientes eléctricas, la cual varía si hay sudoración y cambios en el organismo. Por esto puede ser un buen indicador del estrés, furia o miedo. Sin embargo, este tipo de señal se ve claramente afectada por factores ambientales.
- **Actividad electroencefalográfica (EEG):** En este caso los sensores se colocan sobre la cabeza con el fin de medir la actividad eléctrica en la corteza cerebral. Al igual que muchos estudios destacan la relación de los estímulos fisiológicos con las emociones, la existencia de una estrecha ligación entre la actividad cerebral y la producción de emociones es clara. Ya que como hemos relatado con anterioridad es el sistema límbico donde se generan las emociones.

Por lo tanto, tal y como veremos posteriormente cuando nos adentremos en la descripción de nuestro estudio. Hemos elegido estos sensores EEG como pieza fundamental en nuestro análisis sobre las emociones.

Destacar también una tecnología muy actual en temas que engloban al cerebro como es la espectroscopia funcional del infrarrojo cercano (fNIR). Dicha tecnología mide los cambios del nivel de oxígeno en el córtex pre-frontal de los sujetos humanos, ofreciendo a los científicos monitorizaciones en tiempo real de la oxigenación de los tejidos del cerebro mientras el sujeto realiza una determinada tarea. Al recoger información sobre la actividad funcional del cerebro, presenta un gran interés en el ámbito de las emociones.

3 ESTADO DEL ARTE

En la actualidad la caracterización de emociones con tratamiento digital es invaluable.

Son numerosos los estudios que se están llevando a cabo con el objetivo de lograr encontrar una tecnología que permita identificar la emoción asociada a un individuo a partir del diagnóstico y estudio realizado sobre el sujeto.

A pesar de que se trata de un ámbito muy subjetivo, ya que tal y como define la RAE [17], la emoción es una “alteración del ánimo intensa y pasajera, agradable o penosa, que va acompañada de cierta conmoción somática”, es decir, tiene asociada una enorme representación física y depende mayoritariamente de cada individuo; cada vez son más los estudios que intentan buscar una correlación entre la emoción y el proceso interno que se genera en el interior de la persona.

Un aspecto clave en este sentido ha sido el desarrollo tecnológico y la aparición de herramientas computacionales con las cuales se ha facilitado, en gran medida, el análisis y procesamiento de la información.

Aunque muchos métodos para la caracterización de emociones se basan en el estudio de la expresión facial del sujeto o análisis del habla mientras experimenta algún tipo de emoción, hoy en día, está resultando mucho más significativo el estudio de señales fisiológicas, como son las señales EEG (Electroencefalografía). Tal y como nos dicen en [18], el estudio de señales EEG representa una técnica de monitoreo electrofisiológico que permite registrar la actividad eléctrica del cerebro, que a su vez es producida por la actividad neuronal en el interior del mismo. Como veremos en puntos posteriores, el análisis de estas señales proporciona resultados aceptables para la caracterización de emociones, aunque los métodos para llevar a cabo la caracterización son muy variados y dependen de la aplicación específica.

Es cierto que actualmente no existe un método que nos proporcione resultados totalmente certeros, debido a esto, la selección de uno u otro para la caracterización puede ser complejo. A continuación, mostraremos algunos estudios que se han llevado a cabo y se están analizando sobre la caracterización de emociones, centrándonos principalmente en el análisis de señales EEG.

2.1- REVISIÓN DEL ESTADO DEL ARTE

Cuando nos adentramos en el mundo del reconocimiento de emociones por medio de métodos computacionales es clave hacer una distinción entre dos métodos basados en técnicas de *Machine Learning*. Por un lado, tenemos los métodos que utilizan *Deep Learning* y por otro tenemos los métodos que no hacen uso del aprendizaje profundo. En nuestro caso, el estudio llevado a cabo no hace uso del *Deep Learning*, sino que la secuencia de pasos a seguir es la que podemos apreciar en la Ilustración 8.



Ilustración 8: Representación gráfica de los pasos seguidos en nuestro estudio.

A continuación, procedemos a mostrar una serie de estudios basados en técnicas que siguen el esquema descrito anteriormente.

Hyun Joong Yoon y Seong Youb Chung [19] estudian la caracterización de las emociones por medio del análisis de las señales EEG, en este caso, en su estudio analizan la valencia (relacionada con la alegría y tristeza) y la excitación (relacionada con el mayor o menor aprecio de emoción). Los experimentos son realizados sobre un individuo adulto, al que se le colocan 12 sensores, de acuerdo al sistema internacional 10 – 20, para la captación de señales EEG y se completa estas señales con 20 señales creadas vía software, de manera que en total se tienen 32 señales. Durante el experimento, al individuo se le excita con una serie de imágenes con el fin de causarle distintos niveles de valencia y excitación, para posteriormente realizar un preprocesamiento de las señales y analizarlas mediante la transformada de rápida de Fourier (FFT) con una ventana Hamming de 1,000 ms con una superposición del 50%. Finalmente, se calculan los potenciales espectrales en las bandas theta, alfa, beta y gamma que son utilizados para clasificar. En la clasificación se utiliza el análisis de varianza ANOVA con HSD de Tukey. Los resultados se obtienen por categoría, definiéndose la categoría 1 (alta valencia, alta excitación), categoría 2 (valencia media, baja excitación) y categoría 3 (baja valencia, alta excitación). Los resultados obtenidos hacen que se puedan clasificar a los individuos en 5 clases. Para la clase A se distinguen las categorías 1, 2 y 3; en la clase B se pueden distinguir las categorías 1-2 y 2-3 pero no las categorías 1-3. En la clase C solamente se pueden distinguir las categorías 1-3, en la clase D sólo las categorías 1-2 son distinguibles y finalmente, en la clase E sólo se distinguen las categorías 2-3. Los casos de Clase A y Clase C implican que la valencia se puede reconocer en tres niveles (valencia alta-media-baja) y dos niveles (valencia alta-baja) respectivamente, y los casos de Clase A y Clase B implican que la excitación puede ser reconocido en dos niveles (excitación alta-baja).

Siguiendo el hilo de la transformada de Fourier, Yuan-Pin Lin y Tzzy-Ping Jung [20] en su estudio también utilizan dicho método para la caracterización de emociones. Sin embargo, en este caso el experimento se realiza sobre tres sujetos y el estímulo se logra alcanzar por medio de la música y no con imágenes. Para ello, les proporcionan a los sujetos unos auriculares y realizan el análisis sobre los individuos proporcionándoles 12 extractos musicales diferentes divididos en cuatro bloques donde cada bloque comprende extractos felices y tristes en orden aleatorio, el experimento se realiza durante varios días seguidos. Posteriormente, se preprocesan las señales mediante un análisis de componentes independientes (ICA) para finalmente realizar la extracción de características que en este caso son dos, el diferencial de lateralidad (DLAT) que consiste en el cálculo de la asimetría diferencial de potencia de banda sobre izquierda – derecha de los sensores

colocados en la cabeza y el diferencial de caudalidad (DCAU) que estudia la asimetría de potencial diferencial de pares fronto – posteriores. Se ha demostrado que ambas características son aplicables en la caracterización y clasificación de emociones, al mismo tiempo que el preprocesamiento ICA resulta muy favorable. El método utilizado para clasificar fue el ‘*leave-trial-out*’ (LTO) arrojando un resultado confiable al repetir la clasificación 24 veces. Cada vez se usaban 23 de 24 ensayos como datos de entrenamiento para evaluar el ensayo restante. Los resultados comprenden 3 clases (feliz, triste y neutro), sin embargo, el porcentaje de acierto teniendo en cuenta las dos características estudiadas, en ningún caso superó el 50 %. Lo más destacable del estudio fue el buen comportamiento que presentó el preprocesamiento ICA.

También se ha demostrado que la medición de otros tipos señales junto con las EEG, pueden mejorar el resultado de la clasificación, en este aspecto cabe destacar el estudio llevado a cabo por Guillaume Chanel et al [21] donde además de realizar medidas de señales EEG, se llevan a cabo medidas de presión arterial, medidas de resistencia de la piel (GSR) y medidas de respiración. El aumento o disminución tanto de la presión arterial como de la respiración durante la realización del ensayo da lugar a una clasificación con mejores resultados. Los experimentos se realizaron sobre 30 individuos diferentes colocándoles 64 electrodos según el sistema de posicionamiento 10-20, haciéndoles recordar momentos del pasado y posteriormente, se llevó a cabo un preprocesamiento de la señal mediante un filtro paso de banda y se utilizó la transformada de Fourier a corto plazo para cada electrodo con una ventana deslizante de 512 muestras y una superposición del 50% entre dos ventanas consecutivas. Para cada uno de los 64 espectrogramas (uno por electrodo), se seleccionaron 9 bandas de frecuencia en función de las banda alfa, theta...para la obtención de características. Finalmente, destacar también en este estudio la comparación que se realiza entre un clasificador lineal y un clasificador SVM, demostrándose que los resultados obtenidos con el clasificador SVM son un 10% mejor que los obtenidos mediante el clasificador lineal. Los resultados obtenidos en el estudio se dividieron en tres clases; excitado-positivo, excitado-negativo y calma-neutral. Los valores logrados oscilan entre el 67 % de los patrones bien clasificados para el conjunto de tres clases, hasta casi el 79 % para el conjunto de dos clases, excepto para el conjunto de positivo frente a negativo donde el mejor resultado fue del 76 % de acierto.

Haniel Zamanian y Hassan Farsi [22] realizaron un estudio científico sobre la caracterización de las emociones donde cabe destacar los buenos resultados obtenidos en torno a un 95% de acierto. Para ello, se hace uso de una base de datos existente denominada ‘DEAP’ (la misma que nosotros utilizamos) que contiene datos de 32 individuos a los cuales se les van mostrando pequeños fragmentos de vídeos. Se recogen las señales EEG mediante 40 electrodos y posteriormente se elimina el ruido y los artefactos por medio de los filtros de Garbor, filtros de banda limitada con una localización óptima en el espacio y dominios de la frecuencia. Cada filtro representa una función de núcleo gaussiana modulada por una onda plana compleja caracterizada por la frecuencia central y orientación. Con los resultados obtenidos del preprocesamiento, se seleccionan una serie de características (energía, funciones IMF, frecuencia máxima, frecuencia mínima, entropía y potencia promedio), tanto en el dominio del tiempo como en el dominio de la frecuencia para posteriormente clasificar en cuatro clases distintas haciendo uso de un clasificador SVM, la idea principal de un clasificador de este tipo se basa en encontrar hiperplanos optimizados con un margen de separación máximo. En este estudio, también se hace uso de los términos conocidos como valencia y excitación y la clasificación en cuatro clases hace referencia a baja excitación – baja valencia (LALV), alta excitación – baja valencia (HALV), baja excitación – alta valencia (LAHV) y alta excitación – alta valencia (HAHV). Los resultados obtenidos, en torno al 90% de acierto hacen referencia a la utilización máxima de 7 canales y con un tamaño máximo de filtro Gabor de 5 x 8. Elegir más canales y filtros de mayor tamaño causan un vector de características más grande y por lo tanto, más difícil de tratar desde el punto de vista computacional.

Finalmente, destacar el desarrollo científico llevado a cabo por Ning Zhuang et al [2] donde se utiliza la transformada EMD para el reconocimiento de emociones y además en dicho estudio hemos basado nuestro trabajo para intentar emular el comportamiento con el fin de verificar y demostrar la veracidad de los datos. Para este análisis científico también se utiliza la base de datos 'DEAP' (la cual explicaremos con más detalles en puntos posteriores) constituida por 32 individuos, a los cuales se les colocan 40 sensores captadores de señales EEG sobre la cabeza y se entrenan con 40 vídeos de 1 minuto de duración. En dicho estudio las señales EEG que se utilizan ya vienen preprocesadas con anterioridad, por lo tanto, el preprocesamiento no es objeto del análisis. Al igual que ocurre con otros métodos con el fin de obtener características como puede ser la transformada de Fourier, en este caso se realiza una descomposición empírica EMD (Descomposición de Modo Empírico) donde se obtienen como resultado una serie de IMFs (Funciones de Modo Intrínseco) donde cada una de estas funciones se define en un determinado rango de frecuencias. Haciendo uso de ellas se extraen las características a utilizar para el análisis, como será la primera diferencia en tiempo, la primera diferencia en fase y la energía. Con dichas características y utilizando un clasificador SVM se obtienen los resultados. En este caso se mide tanto la valencia como arousal y destacar que los mejores resultados obtenidos se alcanzan haciendo uso de 8 canales y de un solo IMF. Para la valencia se obtiene un 69 % de acierto, mientras que para arousal un 72 % de acierto.

De la misma forma, como mencionamos al principio, no solamente se utilizan estas técnicas para el estudio y la caracterización de emociones. Por este motivo vamos a presentar un estudio bastante significativo donde se caracterizan las emociones por medio del *Deep Learning*.

Wei-Long Zheng y Bao-Liang Lu [23] utilizan las técnicas de *Deep Learning* para el reconocimiento de emociones según las bandas de frecuencia. Para ello realizan estudios con 15 sujetos de los cuales recopilan señales EEG por medio de un casco de 62 electrodos con posicionamiento 10 – 20. A los individuos se les excita con clips de películas de 45 segundos de duración. Con el objetivo de eliminar el ruido y los artefactos de las señales EEG, estas se filtran con un filtro paso de banda entre 0,3 y 50 Hz. Una vez filtradas las señales, se procede a la extracción de características, en este caso se utilizan la entropía diferencial, la asimetría diferencial, la asimetría racional y la densidad espectral de potencia. Finalmente, con el objetivo de clasificar las emociones en positivas, negativas y neutras, se utiliza un modelo de clasificación con *Deep Belief Networks (DBN)*, el cual consiste en un modelo generativo probabilístico con arquitectura profunda compuesto por múltiples capas de variables ocultas con conexiones entre las capas, pero no entre unidades dentro de cada capa. Cuando se está entrenando un algoritmo DBN con un conjunto de ejemplos como entrada de forma no supervisada, una DBN puede aprender a reconstruir probabilísticamente estas entradas. Así, las capas actúan como detectores de características en dicha entrada. Después de este paso de aprendizaje, una DBN puede ser entrenada de nuevo de forma supervisada para mejorar la etapa de clasificación. Una DBN puede ser vista como una composición de redes simples y no supervisadas tales como las máquinas de Boltzmann restringidas (RBM) donde cada capa oculta de una subred sirve como la capa visible para la siguiente. Esto también permite que la etapa de entrenamiento no supervisado sea realmente eficiente.

A continuación, en la Ilustración 9 mostramos con una imagen la representación gráfica de lo descrito en el párrafo anterior.

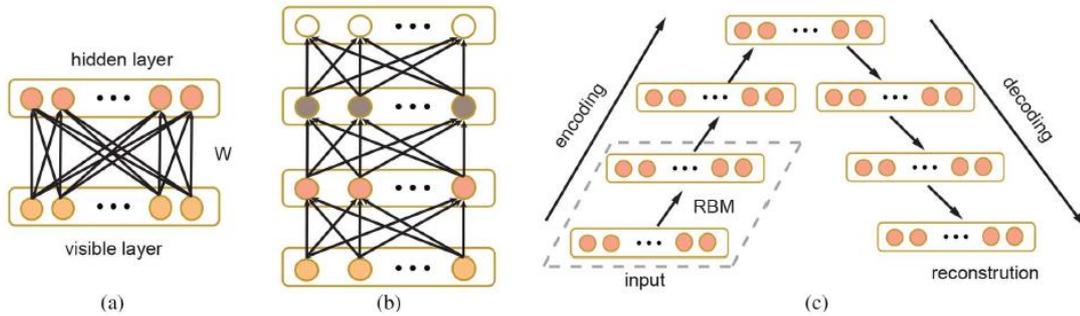


Ilustración 9: (a) Un RBM contiene las neuronas de la capa oculta conectadas a las neuronas de la capa visible con pesos W . (b) Un DBN que usa el ajuste fino supervisado de todas las capas con propagación hacia atrás. (c) La representación gráfica de DBN desenrollada utilizando sintonización fina no supervisada de todas las capas con retropropagación [23].

Finalmente, destacar que como resultado de la clasificación se obtuvo alrededor del 86 % de acierto disminuyendo a 8 el número de canales a utilizar, mientras que haciendo lo mismo con el clasificador SVM se obtuvo un 83,9 % de acierto. Por lo tanto, concluir con que ambas técnicas presentan resultados muy parecidos y que se tienen que seguir desarrollando para encontrar resultados más prometedores.

Como podemos ver, el estudio de las emociones no es una novedad científica, sino que se ha intentado comprender el funcionamiento de éstas mediante el uso de tecnología desde principios de siglo XX, tanto desde una perspectiva psicológica como científica. En las últimas décadas se han intensificado los estudios gracias al desarrollo tecnológico. Además, estos análisis han ido apareciendo por la importancia que han cobrado las emociones en el mundo actual, donde cada vez son más los trastornos mentales que se justifican emocionalmente. Si es cierto que como hemos dicho con anterioridad dichas emociones tienen un porcentaje subjetivista importante, al tratarse de impulsos estimulados mayoritariamente por el cerebro, tienen que tener una justificación científica demostrable, ya que fácilmente el sujeto puede aparentar un estado totalmente contrario al emocional y esto puede llegar a ser un problema para la sociedad. De ahí la importancia que tiene el estudio de las emociones desde una perspectiva científica.

4 SEÑALES EEG

Puesto que centraremos nuestro estudio sobre las emociones en este tipo de señales, nos conviene profundizar en dicho campo, definiendo con detalles aspectos importantes sobre la captación electroencefalográfica.

Tal y como nos explican Miguel Ángel Pérez y Maricela González en [24] el registro encefalográfico (EEG) es un método que nos permite estudiar la relación existente entre la conducta y el sistema nervioso de forma no invasiva. Dichas señales son variaciones de voltaje originadas por las corrientes iónicas intra y extraneuronales en una gran población de células. El análisis de estas señales ha sido objeto de estudio durante mucho tiempo, contando principalmente con dos vertientes, el análisis de las señales en el dominio de la frecuencia, utilizando para ello diversos métodos como la transformada rápida de Fourier (TRF) y el análisis en el dominio del tiempo, haciendo uso entre otros métodos, de la correlación.

En el dominio de la frecuencia, mediante la transformada rápida de Fourier,

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi kn/N} \quad \text{Con } k=0, \dots, N-1, \quad (1)$$

se puede descomponer una forma de onda compleja en una suma lineal de componentes de ondas más elementales, en este caso, las ondas elementales son senos y cosenos. Donde $X(k)$ representa un conjunto de números complejos y $x(n)$ una señal no periódica discreta en el tiempo. De tal forma, que trabajando en este dominio se puede llegar a separar una señal EEG en los componentes de frecuencia que la constituyen y calcular la amplitud de cada uno de ellos, para posteriormente agruparlos en bandas de frecuencias particulares y a partir de aquí poder caracterizar las señales. Estas amplitudes constituyen el espectro de amplitudes de la señal de estudio.

De la misma manera, en el dominio del tiempo se suele hacer uso de la correlación puesto que en este caso, el coeficiente de correlación de Pearson, que es uno de los índices matemáticos con mayor potencia estadística, permite encontrar posibles relaciones entre las variables de interés en el estudio al determinar el grado de semejanza entre dos señales. Así una correlación de 1 indica la máxima correlación positiva, de 0 la mínima y de -1 la máxima correlación negativa.

Dicho coeficiente se calcula de la siguiente manera:

$$\rho_{X,Y} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} = \frac{E[(X-\mu_X)(Y-\mu_Y)]}{\sigma_X \sigma_Y}, \quad (2)$$

Donde σ_{XY} es la covarianza de (X, Y) y σ_X, σ_Y son las desviaciones estándar de X e Y respectivamente, siendo X e Y dos variables aleatorias reales.

Debido a la complejidad matemática que aborda el estudio de este tipo de señales, no ha sido hasta el siglo XX cuando se empezó a trabajar a fondo con ellas desde una perspectiva ‘tecnológica’, este auge vino motivado por el desarrollo tecnológico y sobretodo computacional, facilitándonos, en gran parte, el trabajo.

4.1- ¿CÓMO SE OBTIENEN?

La captación de señales EEG como explica Rafael Barea en [25] se hace por medio de electrodos, estos se colocan mayoritariamente sobre el cuero cabelludo, aunque existen casos en los que los electrodos se sitúan en localizaciones cerebrales profundas.

Teniendo en cuenta lo comentado anteriormente, podemos hablar de dos tipos principales de electrodos, los **superficiales** que se aplican directamente sobre el cuero cabelludo y los **quirúrgicos** que se colocan en zonas profundas del cerebro mediante cirugía.

De la misma manera, el registro de la actividad bioeléctrica recibe distintos nombres de acuerdo al tipo de electrodo utilizado. Hablamos de **electroencefalograma** (EEG) cuando se utiliza el electrodo superficial, de **electrocorticograma** (ECoG) si se utilizan electrodos quirúrgicos en la superficie de la corteza y **estéreo electroencefalograma** (E-EEG) cuando se usan electrodos quirúrgicos profundos.

Los electrodos superficiales a su vez los podemos encontrar con diferentes formas y sujeciones que pasaremos a explicar a continuación.

- **Adheridos.** Son pequeños discos metálicos de 5 mm de diámetro, se adhieren con pasta conductora y se fijan con colodión que es un aislante. Aplicados correctamente proporcionan resistencias de contacto muy bajas.
- **De contacto.** Se trata de pequeños tubos de plata clorurada roscados a soportes de plástico. En el extremo se coloca una especie de almohadilla que se humedece con solución conductora. Se sujetan con bandas elásticas y se colocan mediante pinzas de ‘cocodrilo’. Generalmente son muy incómodos y debido a esto no permite registros de larga duración. Podemos observar su estructura en la Ilustración 10.

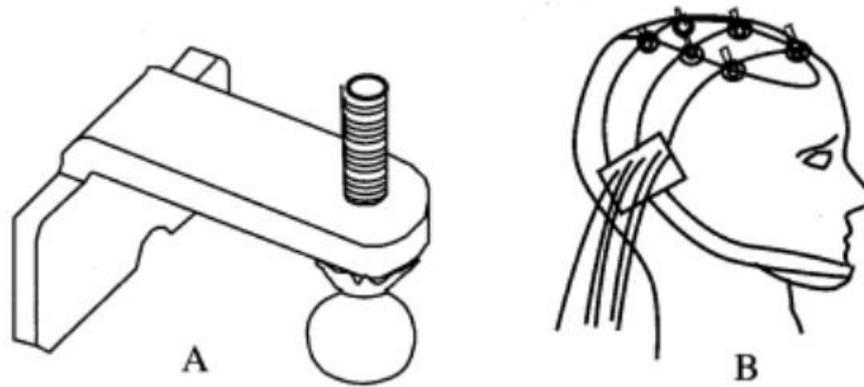


Ilustración 10: Descripción gráfica del electrodo de contacto, en la figura A podemos apreciar su estructura mientras que en la figura B vemos como se colocan sobre la cabeza del paciente [25].

- **En casco de malla:** Los más recientes, los electrodos están incluidos en una especie de casco elástico tal y como podemos apreciar en la Ilustración 11. El tamaño de los cascos es seleccionado de acuerdo a la talla del paciente. De esta manera, se gana sobretodo en ergonomía para el sujeto, además presentan gran inmunidad al ruido y a los artefactos. Los electrodos están correctamente posicionados de manera que los estudios son muy precisos.



Ilustración 11: Representación gráfica de los electrodos en casco de malla [25].

4.2- SISTEMA DE POSICIONAMIENTO DE LOS ELECTRODOS

Tal y como explica Rafael Barea en [26] existen varios sistemas diferentes de posicionamiento de electrodos, sin embargo, el más extendido, que es el que se utiliza en la base de datos seleccionada para nuestro estudio, es el sistema internacional 10-20. Para colocar los electrodos en este sistema se siguen los pasos mostrados a continuación. Aunque antes tenemos que tener en cuenta los puntos craneométricos como son el **nación**, el **inion** y el **vertex**; tal y como nos dicen en [27] se tratan de puntos de referencia para establecer los límites de ciertos diámetros. El **nación** se caracteriza por ser el punto donde confluyen los huesos propios de la nariz con el hueso frontal. Por su parte, el

inion es el punto medial que se encuentra en la protuberancia occipital externa. Finalmente, el **vertex** se caracteriza por ser el punto más superior de la sutura interparietal. Podemos observar dichos puntos craneométricos en la Ilustración 12.

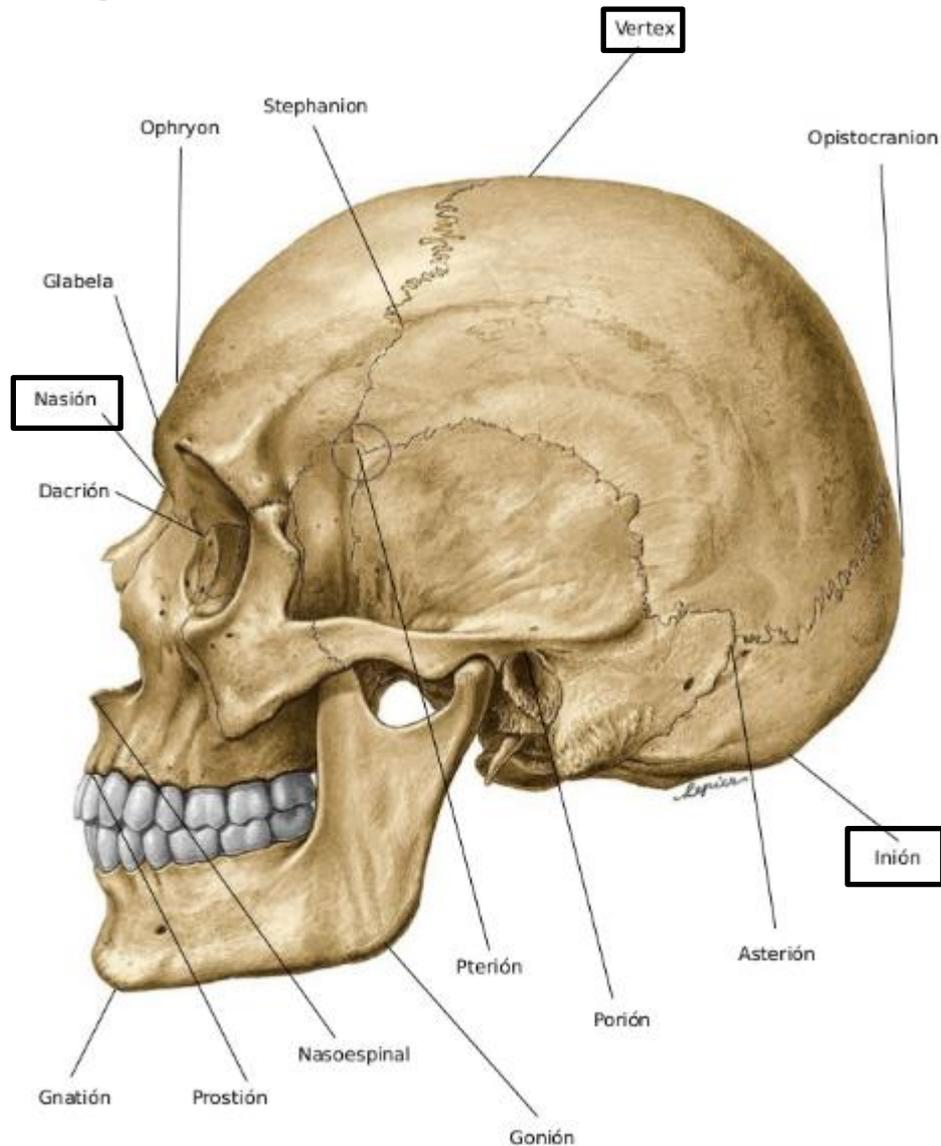


Ilustración 12: Representación gráfica de los puntos craneométricos, resaltando con un rectángulo los explicados con anterioridad [27].

Una vez conocidos los puntos craneométricos que nos sirven como referencia para la explicación del sistema de posicionamiento de electrodos 10 – 20, procedemos a su explicación [26]:

1. Se mide la distancia entre el nasión y el inion pasando por el vertex. El 10 % de esa distancia sobre el nasión señala el punto Fp (Frontal Polar). El 10 % de esa distancia sobre el inion señala el punto O (Occipital). La posición correcta de los puntos la podemos observar en la Ilustración 13.

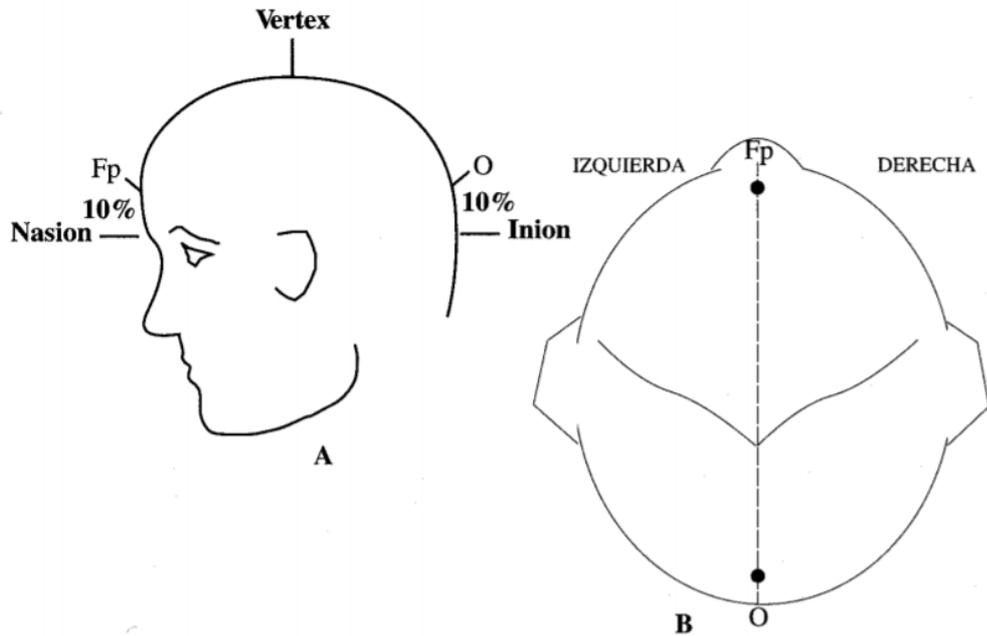


Ilustración 13: En A podemos observar una representación gráfica a vista de perfil sobre el trazado entre el nasión y el inion. Mientras que en B visualizamos una vista superior. En ambos casos se muestran los puntos Fp y O [26].

2. Entre los puntos FP y O se sitúan tres nuevos puntos espaciados a la misma distancia. Estos puntos son, de delante hacia atrás, el Fz (Frontal), el Cz (Central o Vertex) y el Pz (Parietal). De la misma forma, midiendo la distancia entre los puntos preauriculares (situados delante del oído), alejados un 10 % de éste, encontramos los puntos temporales mediales, T3 (izquierdo) y T4 (derecho). Podemos apreciar la representación gráfica de los puntos en la Ilustración 14.

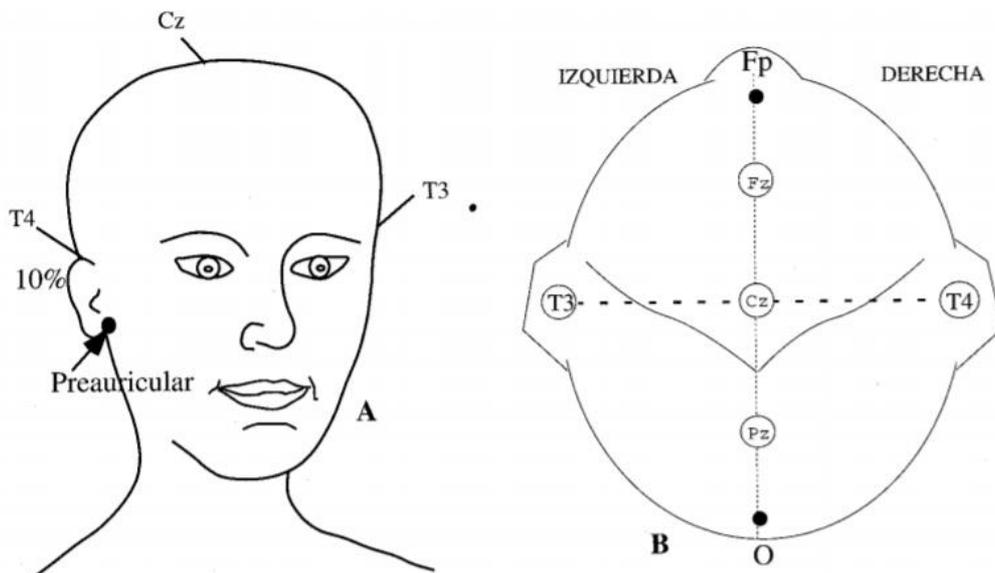


Ilustración 14: En A observamos los puntos temporales mediales separados un 10 % del preauricular. Mientras que en B tenemos una vista frontal de los puntos mencionados hasta este momento [26].

3. Siguiendo con el posicionamiento, tendremos que los electrodos F3 y F4 (Izquierda y derecha respectivamente) están situados de forma equidistante entre el punto frontal medio (Fz) y la línea de electrodos temporales. De la misma manera, los electrodos P3 y P4 (izquierda y derecha respectivamente) equidistan entre el punto P medio y la línea de los electrodos temporales, como podemos apreciar en la Ilustración 15.

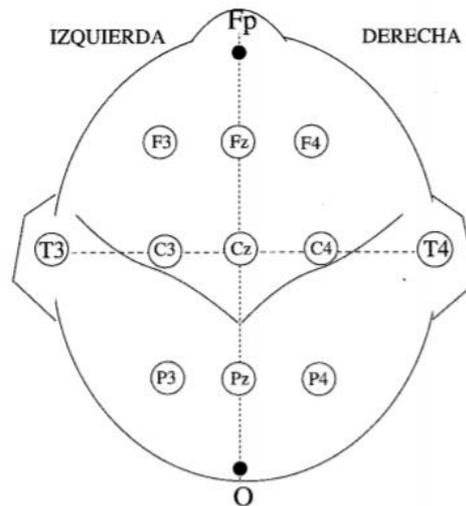


Ilustración 15: Representación gráfica frontal de los electrodos estudiados hasta este punto [26].

4. Llegados a este punto, se mide la distancia entre el punto medio Fp y el punto medio O a través de T3. El 10 % de esta distancia a través de Fp corresponde a los electrodos FP1 y FP2, mientras que el 10 % de esa distancia a través de O corresponde a los electrodos O1 y O2. El electrodo F7 (y el F8) se sitúa equidistante entre los puntos FP1 (ó FP2) y T3 (ó T4). El electrodo T5 (y el T6) se sitúa en la línea media entre T3 (ó T4) y O1 (ó O2). Finalmente, a un 10 % de los temporales T3 y T4 se sitúan los electrodos auriculares A1 y A2 respectivamente. La posición final de todos los electrodos la podemos ver resumida en la Ilustración 16.

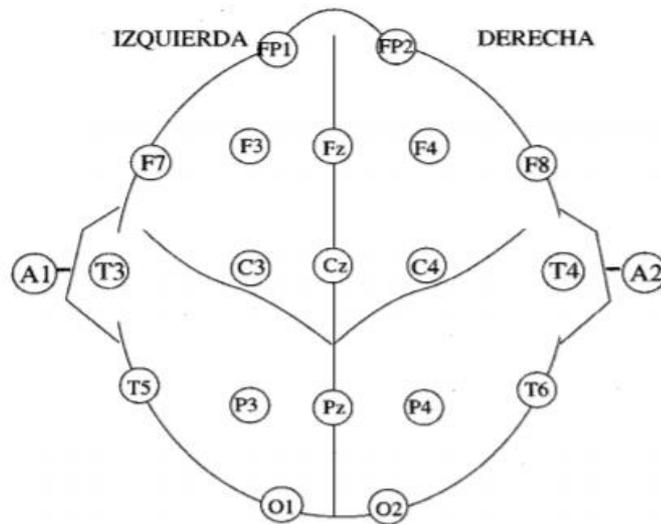


Ilustración 16: Estructura final del sistema internacional de colocación de electrodos 10 -20 [26].

4.3- ONDAS CEREBRALES

Tal y como nos explican en [28] las neuronas se comunican entre ellas por medio de pequeños impulsos eléctricos llamados ondas cerebrales. Al igual que los diferentes tipos de ondas existentes en la naturaleza, estas presentan distintas frecuencias.

Para medir dichas ondas utilizamos lo que ya conocemos como electroencefalograma (EEG). Generalmente, estas ondas se dividen en diferentes grupos según su frecuencia como podemos ver en la Tabla 1.

Tipo de onda	Frecuencia (Hz)
Ondas Delta	0.2 - 4
Ondas Theta	4 - 8
Ondas Alfa	8 - 12
Ondas Beta	12 - 30
Ondas Gamma	30 - 90

Tabla 1: Descripción de los distintos tipos de ondas cerebrales existentes con su frecuencia característica.

- **Ondas Delta.** Ondas muy lentas, como podemos apreciar en la Ilustración 17, pero son también las que tienen mayor amplitud, son características durante el sueño, aunque también aparecen en estados de meditación.

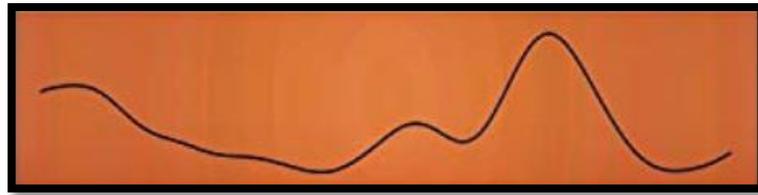


Ilustración 17: Representación gráfica del tipo de onda cerebral Delta [28].

- **Ondas Theta.** Predominan cuando los sentidos están procesando información interna y el individuo se encuentra desconectado del mundo exterior. Se presentan también durante la meditación profunda y en la fase entre la vigilia y el sueño. Están muy relacionadas con el aprendizaje y la memoria. Como observamos en la Ilustración 18 se trata de ondas más rápidas que en el caso anterior.

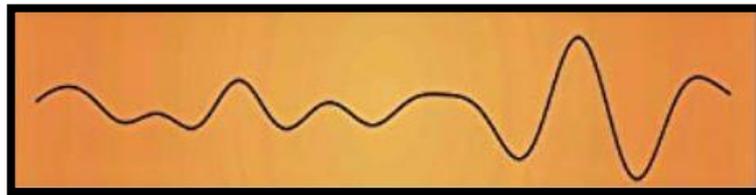


Ilustración 18: Representación gráfica del tipo de onda cerebral Theta [28].

- **Ondas Alfa.** Este tipo de ondas predominan cuando el sistema nervioso central se encuentra relajado, pero despierto y atento. Esta frecuencia ayuda a la coordinación mental, la integración mente / cuerpo, la calma y la alerta. El cerebro también utiliza esta frecuencia como gratificación después de un trabajo bien hecho, como podemos ver en la Ilustración 19 la frecuencia de la onda es mayor.

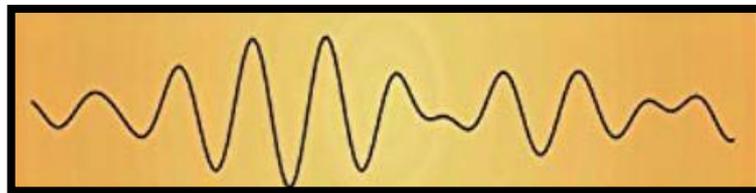


Ilustración 19: Representación gráfica del tipo de onda cerebral Alfa [28].

- **Ondas Beta.** Dichas ondas aparecen durante el periodo de vigilia, en estados donde la atención está dirigida a tareas cognitivas externas, es decir, cuando estamos envueltos y atentos en la resolución de tareas o problemas cotidianos, también durante la toma de decisiones o cuando estamos concentrados. La aparición constante de este tipo de onda implica el desgaste de energía. La Ilustración 20 refleja el comportamiento de dicho tipo de onda.

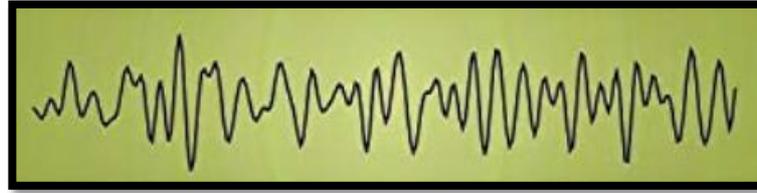


Ilustración 20: Representación gráfica del tipo de onda cerebral Beta [28].

- **Ondas Gamma.** Se trata de las ondas más rápidas, como podemos observar en la Ilustración 21, se producen en ráfagas cortas y se relacionan con el proceso de información simultánea, es decir, cuando el cerebro se encuentra en estado de máxima resolución.



Ilustración 21: Representación gráfica del tipo de onda cerebral Gamma [28].

4.4- PREPROCESAMIENTO DE SEÑALES EEG

Aunque el preprocesamiento no sea objetivo de nuestro estudio, al recibir la señal cruda de los electrodos antes de realizar cualquier tipo de análisis matemático es necesario eliminar el ruido y los artefactos que se añaden a la señal, que, como consecuencia, entorpecen el procesamiento de la información.

Como podemos observar en el estudio llevado a cabo por Priyanka [29] la procedencia del ruido y los artefactos en las señales EEG se debe a las alteraciones eléctricas que efectúan los nervios y los músculos que hay tanto en la cara como en la cabeza. Otras alteraciones, aunque menores, pueden ser producidas por órganos como el corazón.

Uno de los principales casos de artefactos consiste en la señal producida por el parpadeo de la persona sometida al estudio que debido a la proximidad de los sensores suele afectar en la captación de las señales.

Para intentar eliminar los ruidos y artefactos de las señales EEG crudas, éstas son sometidas a un preprocesamiento. Las señales que nosotros utilizamos en nuestro estudio son preprocesadas con el objetivo principal de eliminar el ruido ocasionado por el continuo parpadeo de los individuos objeto de estudio; para ello se utiliza el método de separación ciega de fuentes, como describen Irene Aldecoa et al en [30] ‘la separación ciega de fuentes es un problema que consiste en obtener señales procedentes de n fuentes a partir de las mezclas que llegan a m sensores, disponiendo sólo de estas últimas.’ Dicho método se utiliza para el preprocesamiento de muchas señales, mayoritariamente relacionadas con el audio.

El modelo teórico básico de la separación ciega de fuentes, nos dice que sean x_1, \dots, x_n n variables aleatorias recogidas por n sensores, que proceden de la combinación lineal de n variables aleatorias s_1, \dots, s_n , denominadas fuentes y mutuamente independientes por definición. Los observables x_i vienen dados por:

$$\mathbf{x}_i = \mathbf{a}_{i1}\mathbf{s}_1 + \mathbf{a}_{i2}\mathbf{s}_2 + \dots + \mathbf{a}_{in}\mathbf{s}_n \quad \text{Para todo } i = 1, \dots, n, \quad (3)$$

donde a_{ij} con $i, j = 1, \dots, n$ son coeficientes reales que modelan la atenuación relativa entre las fuentes y se denominan coeficientes de mezcla.

Resulta conveniente utilizar notación matricial para reescribir la ecuación anterior. Sean x y s los vectores columnas cuyos elementos son las mezclas x_1, \dots, x_n , y los componentes independientes s_1, \dots, s_n respectivamente. El modelo de mezcla instantánea se denota por:

$$\mathbf{x} = \mathbf{A}\mathbf{s} \tag{4}$$

donde A es la denominada matriz de mezcla formada por los coeficientes a_{ij} .

Destacar que este modelo básico no contempla la posibilidad de que el número de observables y de componentes independientes sea diferente, pero si así fuese sería importante que el número de sensores fuese superior o igual al número de fuentes para poder aplicar este método.

El objetivo del método es estimar la matriz de mezcla A para poder obtener la matriz de separación W al invertirla y recuperar así los componentes independientes mediante:

$$\mathbf{y} = \mathbf{W}\mathbf{x} \tag{5}$$

donde y contiene los componentes independientes estimados o recuperados.

Como podemos notar, en las ecuaciones anteriores, tanto la matriz A como las señales fuentes en s son desconocidas, por lo tanto, tenemos un sistema de ecuaciones con menos ecuaciones que incógnitas. Para poder encontrar W necesitaríamos recurrir a ecuaciones adicionales que permitan medir qué tan parecidas a s son las señales obtenidas y . Sin embargo, al no conocer tampoco s esto no lo podemos medir, por lo que recurrimos a las hipótesis de sus propiedades. Por ejemplo, se puede suponer que las fuentes eran no correlacionadas y por lo tanto, buscar la matriz W que genere las señales menos correlacionadas entre sí posibles. Para esto, la principal característica a tener en cuenta es la independencia estadística de las fuentes. Para ello tenemos que suponer una función de costes que mida qué tan independiente estadísticamente son las estimaciones de las fuentes obtenidas, y se puede optimizar dicha función buscando la W que maximice dicha independencia, este método se denomina Análisis de Componentes Independientes (ICA) y es muy utilizado en la actualidad.

Por lo tanto, son muchos los métodos y filtros existentes para la eliminación de los artefactos, de tal manera que la utilización de uno u otro dependerá, en mayor medida, de la aplicación a desarrollar.

5 BASE DE DATOS ‘DEAP’

Para la realización de nuestro estudio nos hemos basado en una base de datos ya existente denominada ‘DEAP’ (Database para el Análisis de Emociones Usando Señales Fisiológicas). Dichos datos fueron recopilados por miembros del IEEE (Instituto de Ingenieros Eléctricos y Electrónicos) con el objetivo de la realización de diferentes análisis para conocer el comportamiento de las emociones en los seres humanos.

Tal y como nos explican sus autores Sander Koelstra, Jong-Seok Lee et al en [31] el experimento consistió en recopilar señales EEG y señales fisiológicas periféricas de 32 individuos diferentes, para ello se utilizó un casco de electrodos en malla formado por 40 canales, correspondiéndose cada uno de estos canales con un electrodo en una posición previamente preestablecida. Durante el registro de las señales los sujetos fueron estimulados visualmente mediante vídeos musicales de un minuto de duración, en total se mostraron 40 vídeos por individuo en orden aleatorio. Estos vídeos pretendían introducir en los individuos un determinado tipo de emoción, la cual tenía que ser calificada por los individuos en términos de arousal o nivel de excitación, valencia (relacionado con la felicidad o tristeza que puede ocasionar un evento en un determinado sujeto), atracción o no atracción por lo que se estaba viendo, dominancia y familiaridad. En nuestro caso, solamente arousal y valencia serán objetivo de estudio.

En la Ilustración 22 podemos observar a uno de los individuos durante el estudio, se aprecia el casco de malla con los electrodos y la pantalla de visualización de datos donde se reproducían los vídeos.

Para conocer el efecto que el vídeo había ocasionado en los sujetos, estos tenían que valorar de 1 a 9 los aspectos comentados anteriormente (arousal, valencia...) y los datos eran recopilados como verdad de referencia.

Nosotros para el estudio hemos utilizado las señales ya preprocesadas y en formato ‘.mat’ para poder trabajar con Matlab. Las señales son filtradas a una frecuencia de 4 – 45 Hz a través de un filtro paso de banda y para eliminar los artefactos y el ruido, como ya comentamos en el apartado de preprocesamiento de las señales, se emplea un método de separación ciega de fuentes. Las capturas de información se realizan durante 63 segundos, del total del tiempo 60 segundos se dedican al visionado del vídeo y los 3 segundos iniciales a la captura de datos de referencia. Por cada individuo la base de datos proporciona una matriz de datos y una matriz de etiquetas. La matriz de datos es tridimensional y sus dimensiones son 40 x 40 x 8064 que hacen referencia al número de vídeo, número de canal o electrodo y el registro de los 63 segundos a una tasa de muestreo de 128 Hz. Los primeros 32 canales recopilan información sobre las señales EEG, mientras que los últimos canales se utilizan para recolectar información de señales fisiológicas

externas. La otra matriz es donde se encuentran los datos conocidos como ‘etiquetas’, se trata de una matriz bidimensional de 40 x 4, donde se representan los vídeos y las etiquetas estudiadas (valencia, arousal, dominancia y atracción o no atracción), estos datos corresponden a la verdad de referencia marcada por cada uno de los sujetos y como dijimos anteriormente, se proporcionan en una escala que va de 1 a 9, siendo 1 la mínima puntuación posible, por ejemplo en el caso de valencia una puntuación de 1 indica tristeza y 9 la máxima, siguiendo con el ejemplo, haría referencia a una felicidad máxima.

Muchos son los estudios que han hecho uso de esta base de datos para la realización de sus análisis, ya que resulta muy complicado generar bases de datos de señales EEG propias, no solamente debido al elevado coste del material necesario para poder captar las señales EEG con todos los electrodos correspondientes, sino también por la dificultad de encontrar a personas voluntarias que ofrezcan su tiempo desinteresadamente al estudio, además que realizar el experimento a un elevado número de personas supondría la necesidad de alargar el estudio en el tiempo. Por este motivo, nosotros hemos hecho uso de la base de datos ‘DEAP’ adquiriendo los permisos con anterioridad.



Ilustración 22: Representación gráfica de uno de los individuos que formaron parte de la recopilación de datos para la base de datos 'DEAP', podemos apreciar la colocación del casco de electrodos en malla [31].

6 ALGORITMO Y METODOLOGÍA

Como hemos comentado en apartados anteriores, en nuestro experimento hemos partido de señales recopiladas en una base de datos ‘DEAP’ ya existente. De tal manera que hemos utilizado los datos preprocesados con extensión ‘.mat’ puesto que para el desarrollo del análisis vamos a utilizar el entorno de Matlab. Como la base de datos recoge información de 32 individuos diferentes, tendremos 32 archivos ‘.mat’ a analizar, uno por cada individuo.

Los pasos que durante el desarrollo del trabajo hemos ido realizando son los siguientes, además hemos incorporado en la Ilustración 23 una representación gráfica de los pasos que hemos seguido:

- División de cada una de las señales EEG de 60 segundos de duración en señales más pequeñas de 5 segundos. Con el objetivo de aumentar el número de datos a analizar para posteriormente entrenar al clasificador.
- Realización de la transformada EMD (Descomposición Empírica de Modos) a cada una de las señales obtenidas en el paso previo.
- Como resultado de aplicar la transformada EMD obtenemos funciones IMF (Funciones de Modo Intrínseco). Haremos uso, en el caso máximo, de 5 funciones IMF por cada una de las señales a las que les realizamos la transformada EMD.
- Posteriormente, con las funciones IMF obtenidas pasaremos a realizar una extracción de características tanto en el dominio de la frecuencia como en el dominio del tiempo.
- Finalmente, las características obtenidas nos servirán como entrada al clasificador y de acuerdo a estas conseguiremos unos determinados resultados.

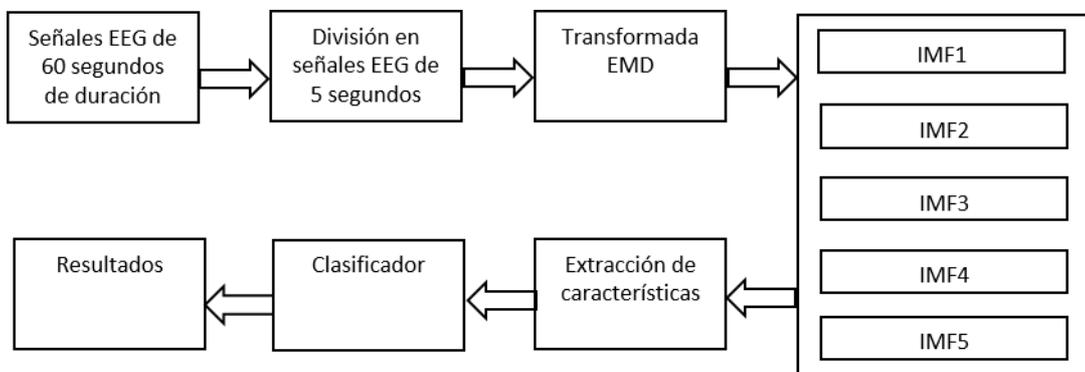


Ilustración 23: Descripción gráfica de los pasos desarrollados en la realización del trabajo y que posteriormente pasaremos a explicar uno por uno.

6.1- TRATAMIENTO INICIAL CON LAS SEÑALES EEG

Las señales ya vienen preprocesadas, por lo tanto, el preprocesamiento no ha sido objetivo de estudio. Sin embargo, antes de meternos en la realización de la transformada EMD para posteriormente poder extraer las características, hemos realizado una serie de pasos previos.

Tal y como explicamos en la descripción de la base de datos, cada prueba realizada a cada individuo tenía un duración de 63 segundos, sin embargo se analizan los últimos 60 segundos, debido a que tras los primeros 3 segundos se presupone que el individuo estará mejor adaptado. De esta forma, uno de los primeros pasos a realizar, ha sido eliminar estos 3 segundos iniciales de las pruebas. Para ello, como mostraremos a continuación en la Ilustración 24, tenemos que tener en cuenta la frecuencia de muestreo, como hemos dicho, se muestrea a 128 Hz, por lo tanto, las primeras 128×3 muestras no las tenemos que tener en cuenta en nuestro estudio y no las analizamos.

```
person2=load('s02.mat');
%Como se trata de un elemento struct me quedo solamente con los datos.
datosPerson2 = person2.data;
%Vamos a muestrear con una frecuencia de 128 Hz
fs = 128;
%Segundo iniciales que no contienen grabacion para estudio
segini=3;
%Quitamos los 3s iniciales a cada prueba
datosEstudio2=datosPerson2(:,canales,segini*fs+1:end);
```

Ilustración 24: Recorte de una parte del código, donde podemos apreciar la lectura de la señal, en este caso, correspondiente al segundo individuo del estudio. Al tratarse de un elemento struct nos quedamos solo con los datos. Y finalmente me interesa quedarme con la información correspondiente a todas la pruebas (40), a determinados canales (dependiendo del experimento a tratar) y con los 60 segundos de estudio, eliminando los 3 segundos iniciales.

Una vez realizado el paso previo, con idea de tener un mayor número de datos para posteriormente entrenar al clasificador, se divide cada vídeo o prueba (60 segundos) en señales más cortas de 5 segundos de duración, ya que el éxito de los métodos de aprendizaje de máquinas depende mucho del tamaño de los datos usados para el entrenamiento del clasificador. De tal manera, que cada vídeo queda dividido en 12 trozos. En resumen, ahora tenemos por cada individuo; 40 vídeos o pruebas, 40 canales (utilizaremos los necesarios para cada análisis) y por cada vídeo tenemos 12 ‘frames’ de 5 segundos de duración, como podemos apreciar en la Ilustración 25.

```
%Numero de trozos en los que vamos a dividir cada video para su posterior
%estudio, calculado eliminando los tres segundos iniciales en los cuales no
%hay grabacion verdadera y dividiendo en pequeñas señales de 5 segundos de
%duracion
nframe = round ((nlen-segini*fs)/(5*fs));
%Obtenemos 12 señales de 5 segundos cada una, para cada uno de los videos,
%en total vamos a tener 480 señales por individuo. El orden de senal_aux
%es: pruebas, canales, tiempo, frames
senal_aux2=reshape(datosEstudio2,nvideos,ncanales,640,[]);
```

Ilustración 25: Recorte de la parte de código donde se realiza la división de la señal en 12 trozos de 5 segundos de duración. De tal manera que $nframe = 12$ y posteriormente tenemos almacenado en `senal_aux`, los videos, canales, la duración de cada señal ($5 \times 128 = 640$) y los 12 frames.

6.2- TRANSFORMADA EMD (DESCOMPOSICIÓN EMPÍRICA DE MODOS)

La descomposición empírica de modos, tal y como se explica en [32] fue propuesta como parte fundamental de la transformada de Hilbert – Huang (HHT), dicha transformada se realiza en dos fases, en la primera se hace uso del algoritmo EMD para la obtención de funciones de modo intrínseco (IMF) y en la segunda fase, se obtiene el espectro de frecuencia instantáneo de la serie inicial aplicando la transformada de Hilbert - Huang a los resultados del paso anterior.

Centrándonos en la transformada EMD, este algoritmo descompone cualquier conjunto de datos en funciones de modo intrínseco (IMF) que no se establecen analíticamente y, en lugar de esto, se determinan mediante una sola serie analizada. Las funciones básicas son obtenidas de forma adaptativa directamente a partir de los datos de entrada. De esta forma, la ecuación que define a la transformada EMD y descompone a la señal de entrada en los IMF's correspondientes a través de un proceso iterativo es la siguiente:

$$x(t) = \sum_{n=1}^L imf_n + r \quad (6)$$

Con $n = 1, 2, 3 \dots, L$ siendo L igual al número máximo de IMF's que queremos calcular menos 1 y r la parte residual de la función que se corresponde con la entrada sin su tratamiento posterior.

Los requisitos que debe satisfacer una IMF obtenida por medio de una transformada EMD son los siguientes:

- El número de puntos extremos, es decir, la suma del máximo y el mínimo y el número de cruces por cero deben ser iguales o distintos en al menos uno.
- En cualquier punto de una IMF, el valor medio de la envolvente definida por el máximo local y la definida por el mínimo local deber ser cero.

Dicha descomposición da como resultado una familia de componentes IMF ordenados según la frecuencia. Cada IMF contiene oscilaciones con una frecuencia inferior a la precedente. Tenemos que tener en cuenta que, aunque una IMF sea de naturaleza oscilatoria, esta puede tener una amplitud y frecuencia variable a lo largo del tiempo.

6.3- PSEUDOCÓDIGO PARA EL CÁLCULO DE LA TRANSFORMADA EMD

Los pasos que tenemos que seguir para poder calcular la transformada EMD son los siguientes:

1. $h \leftarrow$ inicializar
2. $h_{old} \leftarrow$ inicializar
3. Leer señal de entrada x
4. $h \leftarrow x$
5. $h_{old} \leftarrow h$
6. **Para** $i = 1$ hasta el número máximo de IMF's a calcular **hacer**:

7. Hallar el máximo y el mínimo de h_{old}
8. **Si** h_{max} y h_{min} se corresponden con el máximo y mínimo **entonces**
9. Interpolar para calcular la envolvente superior e_{max} y la inferior e_{min}
10. $m \leftarrow (e_{max} + e_{min})/2$
11. $h_{new} \leftarrow h_{old} - m$
12. **Si** el número de puntos extremos de $h_{new} \neq 0$ ó \neq en al menos 1 al número de cruces por cero de h_{new} y el valor medio de la envolvente de $h_{new} = 0$ **entonces**
13. $Imf_i \leftarrow h_{new}$
14. $h_{old} \leftarrow h_{old} - imf_i$
15. **Si no** se cumple (12)
16. $h_{old} \leftarrow h_{new}$
17. **Fin Si**
18. **Fin Si**
19. **Si** $i = n^\circ$ máximo de IMF's a calcular, **Fin para i.**

De esta manera, se puede describir el proceso iterativo como expresamos en $x(t) = n = 1 \dots L \dots i m f n + r$ (6).

Como veremos en un ejemplo a continuación, la transformada EMD funciona como un filtro adaptativo paso de alta. A medida que aumenta el nivel de IMF, la oscilación se vuelve más suave. Cada componente está limitada en banda, reflejando las características de la frecuencia instantánea con la que se está trabajando.

6.3.1- DIAGRAMA DE FLUJO DEL ALGORITMO

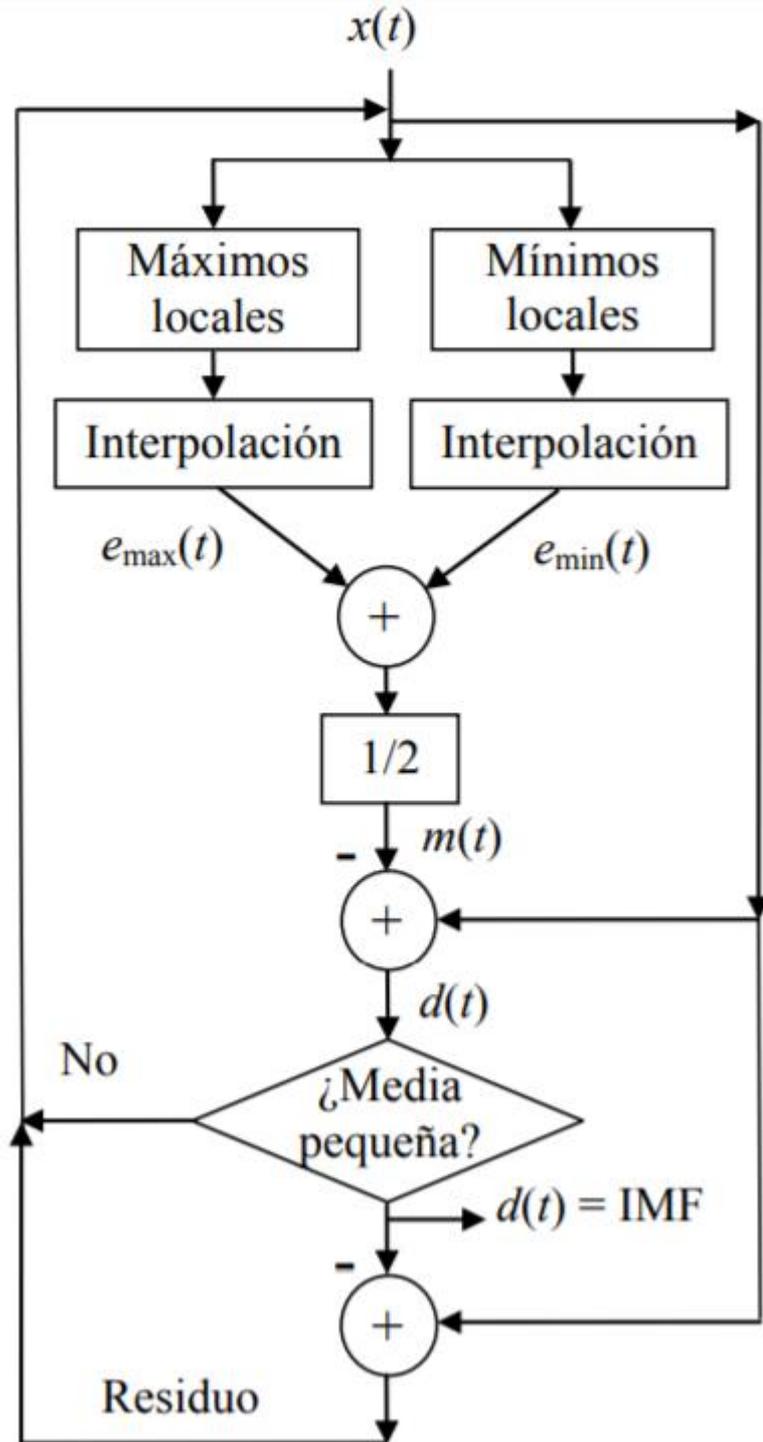


Ilustración 26: Diagrama de flujo donde queda constancia de los pasos explicados en el punto anterior, en este caso, $d(t) = h_{\text{new}}(t)$ [33].

6.3.2- EJEMPLO

Con el objetivo de que se entienda mejor la transformada EMD, vamos a utilizar un ejemplo que aparece también en [32] y que puede resultar muy ilustrativo.

Para dicho ejemplo tenemos que tener en cuenta el panel de imágenes que aparece en la Ilustración 27.

En la figura (a) se muestra la señal de entrada $x(t)$, que consiste en la suma de una senoide de amplitud 0,5 y frecuencia 0,02 y dos señales de barrido espectral parabólicos de amplitud unitaria y frecuencias contenidas en las bandas $[0,05; 0,1]$ y $[0,08; 0,2]$. La figura (b) muestra, para un pequeño intervalo temporal, la entrada junto a las envolventes superior $e_{max}(t)$ (color azul) e inferior $e_{min}(t)$ (color rojo) como resultado de la interpolación entre los máximos y mínimos locales de la entrada, respectivamente. En ese panel también se muestra en color magenta la media local $m(t)$. Esta señal restada a la secuencia de entrada permite obtener el detalle local $d(t)$ mostrado en la figura (c) en color negro. Esta señal no es completamente simétrica alrededor del eje horizontal, pues su media local (en color magenta) es no nula. Por este motivo se realizan iteraciones sobre esta misma serie temporal tantas veces como sea necesario hasta obtener una serie simétrica como la graficada en color negro en la figura (d). En este punto, el detalle es considerado la primera función IMF.

El análisis de señal con EMD continúa de este modo iterando sobre el residuo, que es la entrada sin el detalle anteriormente calculado (consistente en la primera IMF). El próximo detalle extraído es entonces otra IMF de siguiente orden, que contiene información en escalas con frecuencias menores. La extracción de los sucesivos detalles continúa de esta forma hasta que el residuo es despreciable o bien no contiene más extremos locales, es decir, es una función monótona llamada residuo final.

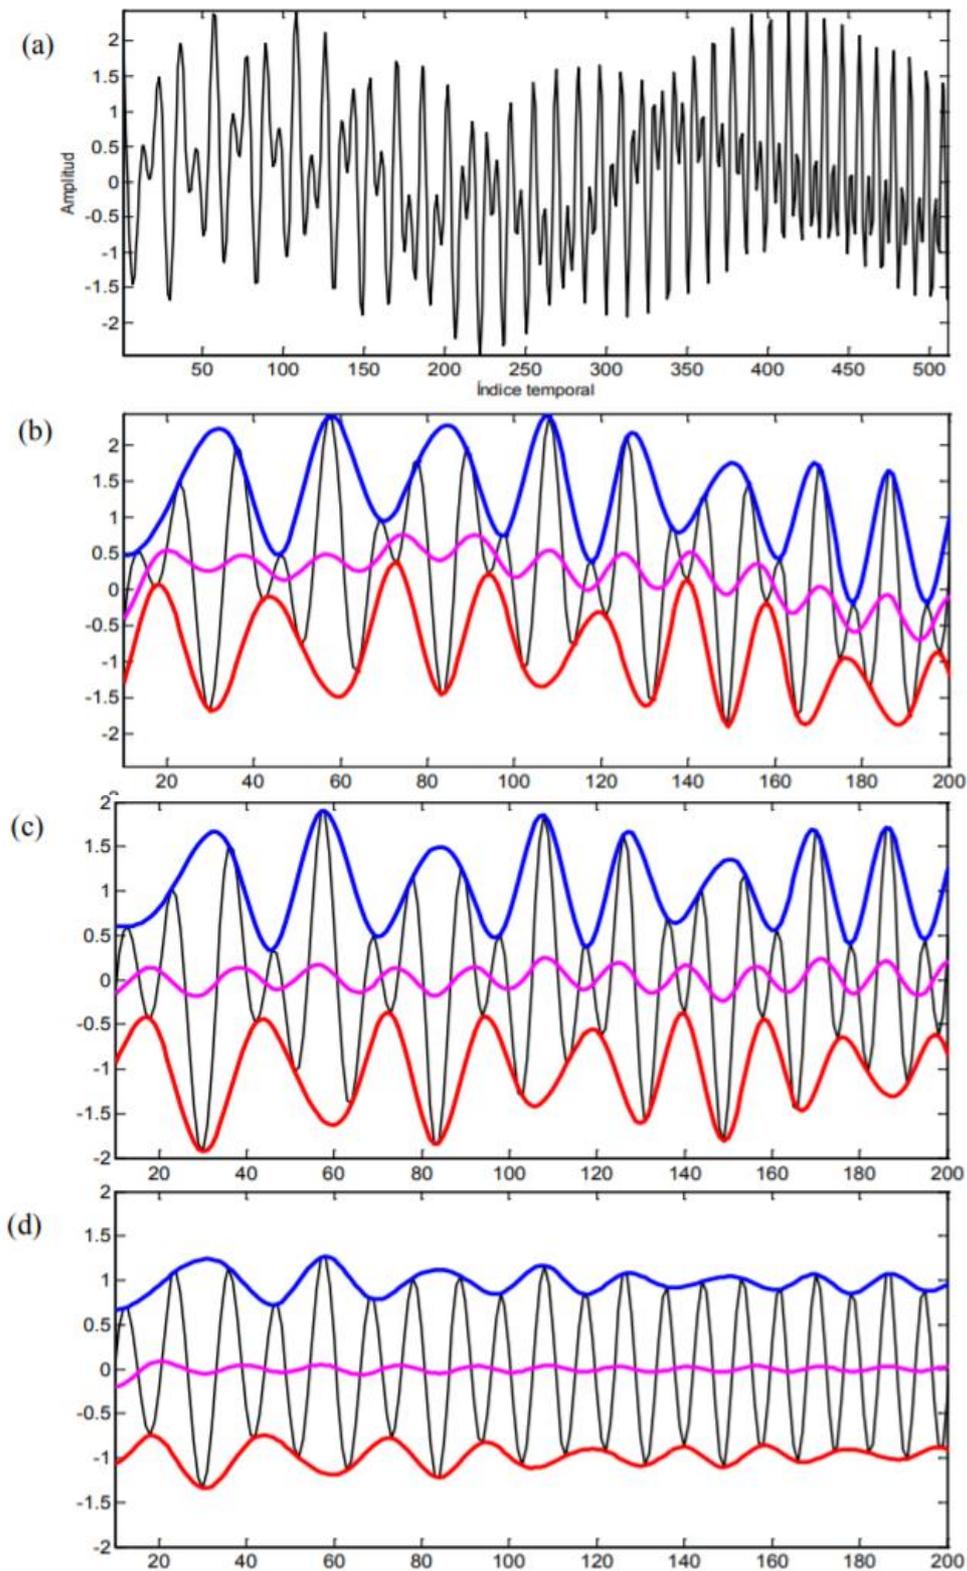


Ilustración 27: Figuras representativas del ejemplo anterior [32].

6.3.3- TRANSFORMADA EMD CON MATLAB

Como ya hemos explicado en puntos anteriores, nuestro estudio lo hemos realizado en el entorno de desarrollo de Matlab. De tal manera que la implementación de la transformada EMD se vuelve más sencilla, puesto que existe una función que directamente nos la realiza.

La sintaxis de la función es la siguiente:

[Imf, residual, info] = emd (X), nos devuelve funciones de modo intrínseco (IMF), la señal residual correspondiente a la descomposición e información adicional. Aunque no es necesario utilizar todos los parámetros de salida, nosotros nos hemos quedado solamente con el valor de la función.

Además a dicha función se le pueden incorporar diversos parámetros, entre todos, nosotros hemos utilizado, '*maxNumIMF*', el cual limita el número de funciones IMF a calcular al valor que le proporcionemos.

A continuación mostramos en la Ilustración 28 la utilización de la función EMD en nuestro análisis.

```
%% Calculo de los IMF%%
%Inicializo la señal IMF, uno para cada individuo, para no tener problemas
%de memoria
numIMF=1;
IMF2=zeros (nvideos,ncanales,nlen2,numIMF,nframe);
%Para cada video, para cada canal, para cada señal, calculo los imf

for i=1:nvideos
    for j=1:ncanales
        for r=1:nframe
            aux2=emd(squeeze(senal_aux2(i,j,:,r)), 'MaxNumIMF', 1);
            IMF2(i,j,:,1:(size(aux2,2)),r)=aux2;

        end
    end
end
```

Ilustración 28: Implementación en Matlab de la función EMD utilizada en nuestro estudio sobre la caracterización de las emociones.

6.4- EXTRACCIÓN DE CARACTERÍSTICAS

Una vez que tenemos las funciones IMF definidas, tenemos que proceder a la selección de características para posteriormente ser capaces de clasificar. En este punto hemos seguido los pasos establecidos por el artículo [2] que hemos seguido, ya que consideramos que la selección de características realizada en dicho artículo aumenta la precisión de la clasificación al trabajar en varios dominios. Además, el hecho de contar con tres características y no más, hace que el proceso computacional y posteriormente el entrenamiento del clasificador sea más rápido.

Por este motivo, las características que vamos analizar son:

- Primera diferencia de fase de las funciones IMF
- Primera diferencia de series de tiempo de las funciones IMF
- Energía normalizada de las funciones IMF

El motivo fundamental de usar estas tres características radica en el hecho de tener información en el dominio del tiempo, en el dominio de la frecuencia e información de energía.

6.4.1- PRIMERA DIFERENCIA DE FASE DE LAS FUNCIONES IMF

Una vez que tenemos las funciones IMF, teniendo en cuenta que dichas funciones están limitadas en banda y representan una componente de oscilación de la señal EEG original, para cada uno de los puntos de estas funciones (si tenemos 5 funciones IMF, pues tendremos que para IMF1 $\{imf_1, imf_2, \dots, imf_{n-1}\}$, IMF2 $\{imf_1, imf_2, \dots, imf_{n-1}\}$... y así sucesivamente. Siendo N el número máximo de puntos que queremos calcular para cada IMF) obtendremos una señal analítica aplicando la transformada de Hilbert a cada IMF. De tal manera, que nos quedará desde el punto de vista teórico tras aplicar la transformada de Hilbert:

$$z(n) = x(n) + jy(n) \quad (7)$$

De la misma manera, dicha fórmula analítica puede ser expresada como:

$$z(n) = A(n) * e^{j\varphi(n)} \quad (8)$$

Donde

$$A(n) = \sqrt{x(n)^2 + y(n)^2} \quad (9)$$

Es la amplitud de $z(n)$ y

$$\varphi(n) = \arctan\left(\frac{y(n)}{x(n)}\right) \quad (10)$$

Define la fase instantánea de $z(n)$. Esta fase será la que utilizaremos posteriormente para calcular la característica.

Haciendo una correspondencia de parámetros con nuestro caso particular, $z(n)$ es el resultado de aplicar la transformada de Hilbert a cada uno de los IMF's correspondientes. Posteriormente, una vez que ya tenemos la señal analítica, calcularemos la fase de cada punto para poder definir la característica concreta.

De esta manera, se define la primera diferencia de fase como:

$$Dp = \frac{1}{N-1} \sum_{n=1}^{N-1} |\varphi(n+1) - \varphi(n)| \quad (11)$$

Sin embargo, aún no hemos explicado qué representa esta diferencia de fase. Dentro del contexto en el que nos encontramos, podemos decir que mide la intensidad del cambio en fase y representa el significado físico de la frecuencia instantánea.

6.4.1.1- IMPLEMENTACIÓN CON MATLAB

A la hora de implementar la extracción de característica con Matlab tenemos que tener en cuenta ciertos aspectos, el primero de ellos es que para obtener la señal analítica $z(n)$ tenemos que utilizar la transformada de Hilbert, existe una función en Matlab denominada *Hilbert* a la cual se le pasa como parámetro de entrada la señal de datos real y nos devuelve la señal analítica de la forma:

$$z(n) = x(n) + jy(n) \quad (7)$$

Posteriormente, necesitamos calcular la fase, para ello también hacemos uso de otra de las funciones de Matlab denominada '*angle*' a la cual le pasamos como parámetro de entrada la señal analítica obtenida en el paso previo y nos devuelve la fase. Finalmente, para calcular la diferencia de fase, hacemos uso de lo calculado en apartados anteriores.

Como podemos ver a continuación en la Ilustración 29, primero inicializamos las variables donde vamos a guardar los resultados y posteriormente aplicamos esa diferencia de fase para cada vídeo (40), cada canal (máximo 32), cada '*frame*' (máximo 12), cada IMF (máximo 5) y para cada punto (640= 5 segundos de cada '*frame*' * 128 Hz). Todo esto se hace para cada uno de los 32 individuos que forman la base de datos.

```

%% First difference of IMF phase %%
% Lo primero que tenemos que hacer en este caso es obtener la transformada
% de Hilbert para poder tener las señales como z(n) = x(n)+jy(n)
Dp2=zeros(nvideos,ncanales,nframe,numIMF,1);
thilbert2=zeros(nvideos,ncanales,nframe,numIMF,nlen2);
phase2=zeros(nvideos,ncanales,nframe,numIMF,nlen2);

for i3=1:nvideos
    for j3=1:ncanales
        for r3=1:nframe
            for s2=1:numIMF
                for t2=1:nlen2-1
                    thilbert2(i3,j3,r3,s2,t2)= hilbert(IMF2(i3,j3,t2,s2,r3));
                    phase2(i3,j3,r3,s2,t2)=angle(thilbert2(i3,j3,r3,s2,t2));
                    Dp2(i3,j3,r3,s2,1)=Dp2(i3,j3,r3,s2,1)+(1/(nlen2-1)*abs((phase2(i3,j3,r3,s2,t2+1))-(phase2(i3,j3,r3,s2,t2))))
                end
            end
        end
    end
end

end

```

Ilustración 29: Cálculo con Matlab de la primera diferencia de fase para el individuo 2.

6.4.2- PRIMERA DIFERENCIA DE TIEMPO DE LAS FUNCIONES IMF

La primera diferencia de tiempo de las funciones IMF hace referencia a la diferencia de intensidad en el dominio del tiempo. Estudios previos como [2] han demostrado la importancia de este tipo de característica en la caracterización de emociones, ya que las diferencias en el dominio del tiempo están íntimamente relacionadas con diferentes estados emocionales. De la misma manera que en el caso anterior, para cada uno de los puntos de las funciones IMF (si tenemos 5 funciones IMF, pues tendremos que para IMF1 {imf₁, imf₂, ..., imf_{n-1}}, IMF2 {imf₁, imf₂, ..., imf_{n-1}} ... y así sucesivamente. Siendo N el número máximo de puntos que queremos calcular para cada IMF), calcularemos la diferencia en tiempo como:

$$Dt = \frac{1}{N-1} \sum_{n=1}^{N-1} |imf(n+1) - imf(n)| \quad (12)$$

6.4.2.1- IMPLEMENTACIÓN CON MATLAB

A la hora de realizar la implementación con Matlab, no tenemos que hacer uso de ninguna función específica, solamente programar la fórmula anteriormente descrita, como apreciamos en la Ilustración 30. Siguiendo los pasos llevados a cabo en el caso anterior, primero inicializamos las variables donde vamos a guardar los resultados y posteriormente aplicamos la diferencia de tiempo para cada vídeo (40), cada canal (máximo 32), cada 'frame' (máximo 12), cada IMF (máximo 5) y para cada punto (640= 5 segundos de cada 'frame' * 128 Hz). Todo esto se hace para cada uno de los 32 individuos que forman la base de datos.

```

%% First difference of IMT time series %%
%Inicializo las 32 matrices, una para cada individuo
Dt2=zeros (nvideos,ncanales,nframe,numIMF,1);

for i2=1:nvideos
    for j2=1:ncanales
        for r2=1:nframe
            for t=1:nlen2-1
                for s=1:numIMF
                    Dt2(i2,j2,r2,s,1)=Dt2(i2,j2,r2,s,1)+(1/(nlen2-1)*abs((IMF2(i2,j2,t+1,s,r2))-(IMF2(i2,j2,t,s,r2))));
                end
            end
        end
    end
end
end

```

Ilustración 30: Cálculo con Matlab de la primera diferencia de tiempo para el individuo 2.

6.4.3- ENERGIA NORMALIZADA DE LAS FUNCIONES IMF

Finalmente, la tercera característica seleccionada se corresponde a la energía normalizada, dicha característica describe el peso del componente de oscilación actual. Se define como:

$$Enorm = \frac{\sum_{n=1}^N imf(n)^2}{\sum_{n=1}^N s(n)^2} \quad (13)$$

Donde $s(n)$ hace referencia a la señal EEG original. De esta forma, nos queda que el numerador hace referencia a la energía de las funciones IMF en cada punto (si tenemos 5 funciones IMF, pues tendremos que para para IMF1 $\{imf_1, imf_2, \dots, imf_{n-1}\}$, IMF2 $\{imf_1, imf_2, \dots, imf_{n-1}\}$... y así sucesivamente. Siendo N el número máximo de puntos que queremos calcular para cada IMF) y el denominador hace referencia a la energía de la señal EEG original.

6.4.3.1- IMPLEMENTACIÓN CON MATLAB

De nuevo como en el caso anterior, no tenemos que utilizar ninguna función específica del entorno de desarrollo de Matlab, basta con ir utilizando lo calculado en apartados previos para programar dicha característica. Como siempre, primero inicializamos las variables donde vamos a guardar los resultados y posteriormente aplicamos la diferencia de tiempo para cada vídeo (40), cada canal (máximo 32), cada 'frame' (máximo 12), cada IMF (máximo 5) y para cada punto ($640 = 5 \text{ segundos de cada 'frame'} * 128 \text{ Hz}$). Todo esto se hace para cada uno de los 32 individuos que forman la base de datos, como vemos en la Ilustración 31.

```

%% Normalized energy of IMF %%
% Tercera característica a calcular, se calcula a partir de los imf^2, y
% los puntos de la señal original al cuadrado.
numerador2=zeros(nvideos,ncanales,nframe,numIMF,1);
denominador2=zeros(nvideos,ncanales,nframe,1);
energia2=zeros(nvideos,ncanales,nframe,numIMF);

for i4=1:nvideos
    for j4=1:ncanales
        for r3=1:nframe
            for s3=1:numIMF
                for t3=1:nlen2

                    numerador2(i4,j4,r3,s3,1)=numerador2(i4,j4,r3,s3)+IMF2(i4,j4,t3,s3,r3)^2;
                    denominador2(i4,j4,r3,1)=denominador2(i4,j4,r3,1)+senal_aux2(i4,j4,t3,r3)^2;
                    energia2(i4,j4,r3,s3)=numerador2(i4,j4,r3,s3,1)/denominador2(i4,j4,r3,1);
                end
            end
        end
    end
end
end
end

```

Ilustración 31: Cálculo con Matlab de la energía normalizada para el individuo 2. En este caso, `senal_aux` almacena la señal EEG original.

6.5- CLASIFICACIÓN

Una vez que hemos extraído las características nuestro principal objetivo radica en clasificar de acuerdo a estas. Inicialmente pensamos construir un clasificador con los 32 individuos que forman la base de datos, sin embargo, debido a la gran cantidad de datos que teníamos, computacionalmente nuestro sistema no soportaba trabajar con tal cantidad de información, así que como solución hemos realizado un clasificador para cada individuo.

El primer paso a realizar ha consistido en cambiar el formato en el que se encontraban almacenadas las características y situarlas en un vector columna. De tal manera que tendremos tres vectores columnas correspondientes cada uno a una característica, todo ello para cada uno de los individuos.

La dimensión de cada uno de estos vectores depende del experimento que estemos tratando, por ejemplo, suponiendo un caso en el que trabajamos con los 40 vídeos o pruebas, 8 canales, 12 'frames' y 1 IMF, la dimensión será $(40 \times 8 \times 12 \times 1) = 3840$ filas y 1 columna.

Dicho procedimiento lo hemos realizado con Matlab tal y como se muestra en la Ilustración 32.

```

%% Unificar características %%
%Una vez que tenemos las tres características, tenemos que unificar estas
%en una matriz, donde cada columna sea una característica

columna1=reshape(Dt2,nvideos*ncanales*nframe*numIMF,[]);
columna2=reshape(Dp2,nvideos*ncanales*nframe*numIMF,[]);
columna3=reshape(energia2,nvideos*ncanales*nframe*numIMF,[]);

```

Ilustración 32: Realización con Matlab del paso explicado en el punto anterior, unificando cada una de las tres características en un vector columna, cuyas dimensiones dependen del experimento que estemos realizando.

Por otro lado, tenemos que tener en cuenta que para clasificar necesitamos una verdad de referencia. Tal y como explicamos en el apartado desarrollado sobre la base de datos que hemos estado utilizando, cada señal correspondiente a cada uno de los individuos estaba almacenada en un elemento estructura, donde uno de los campos contenía los datos y el otro campo contenía unas etiquetas, estas etiquetas contienen la verdad de referencia marcada por los usuarios.

El campo 'etiqueta' dentro del elemento estructura es una matriz de cuatro columnas que hacen referencia a la valencia, al grado de excitación (arousal), a la mayor o menor atracción que puede causarle la prueba y al grado de familiaridad; Sin embargo, tal y como hemos estado explicando durante el desarrollo del análisis, nosotros solamente utilizaremos las etiquetas que hacen referencia a la valencia y al grado de excitación.

La verdad de referencia viene marcada en una escala que va de 0 a 9, nosotros con el objetivo de llevar a cabo una clasificación binaria vamos a dividir estas puntuaciones de tal manera que si la puntuación dada es mayor o igual a 5 le proporcionamos un 1 lógico y si la puntuación es menor de 5, le proporcionamos un 0 lógico, así conseguimos nuestra clasificación binaria.

En este punto se nos presenta un problema, tenemos un valor para cada prueba tanto de arousal como de valencia, es decir, 40 valores para cada una de las dos etiquetas a medir. Sin embargo, nosotros hemos fraccionado las pruebas de tal modo que tenemos 3840 medidas por cada prueba (considerando el caso en el que trabajamos con los 40 vídeos o pruebas, 8 canales, 12 'frames' y 1 IMF).

Entonces miramos el orden en el que se han almacenado las características en las variables columna1, columna2 y columna 3 y nos damos cuenta que se han almacenado en orden secuencial, es decir, el primer valor se corresponde al primer vídeo o prueba, el valor 40 se corresponde al vídeo o prueba 40, el 41 de nuevo a la prueba número 1... y así sucesivamente. De esta forma, el procedimiento que seguimos pues es repetir los valores tanto de arousal como de valencia 96 veces, puesto que 40 vídeos o pruebas por $96 = 3840$ valores que necesitamos.

Finalmente, formamos dos matrices, una para arousal y otra para valencia, incluyendo en cada una de ellas las tres características y la verdad de referencia, tal y como vemos en la Ilustración 33, posteriormente, esto será lo que introduzcamos en el clasificador.

```

%% Verdad de referencia e inserción en características%%
valence=person2.labels(:,1);
arousal=person2.labels(:,2);
tamano=size(arousal,1);
for g=1:tamano

    if (valence(g)>= 5)
        valence(g)=1;
    else
        valence (g)=0;
    end
    if (arousal(g) >=5)
        arousal(g)=1;
    else
        arousal(g)=0;
    end
end
arousalC= repmat(arousal,96,1);
valenceC= repmat(valence,96,1);

% 3 características juntas para valence
caracteristicaVTTotal=[columna1,columna2,columna3,valenceC];
% 3 características juntas para arousal
caracteristicaATotal=[columna1,columna2,columna3,arousalC];

```

Ilustración 33: Descripción gráfica de los pasos explicados en el punto anterior.

6.5.1- HERRAMIENTA ‘CLASSIFICATION LEARNER’

Finalmente, para realizar la clasificación hemos utilizado una aplicación de Matlab denominada ‘Classification Learner’ la cual nos permite llevar a cabo un aprendizaje automático pudiendo utilizar diversos tipos de clasificadores.

Como puntualizamos en el apartado anterior, para cada individuo hemos realizado un clasificador por dimensión a tratar. De tal manera que tenemos dos clasificadores binarios para cada uno de los individuos. Teniendo en cuenta que estamos midiendo valencia y arousal, el clasificador correspondiente a la valencia nos clasifica en alta valencia – baja valencia y seguimos el mismo procedimiento para el caso de arousal.

Como hemos realizado en nuestro caso, podemos realizar el aprendizaje automático supervisado proporcionando un conjunto conocido de datos de entradas y respuestas conocidas a los datos, aunque la falta de datos etiquetados hace que usemos un porcentaje de los datos para el entrenamiento del clasificador y el resto para la validación del mismo. Los pasos a seguir para ponerlo en marcha los explicamos a continuación.

- 1- El primer paso consiste en introducir los datos que queremos clasificar, para ello previamente los datos tienen que estar cargados en el ‘Workspace’ de Matlab. Como veremos a continuación en la Ilustración 34, en el campo ‘variable del workspace’ nos saldrá una lista desplegable con todas las variables almacenadas en nuestro workspace, nosotros tenemos que seleccionar aquella variable donde se encuentren las tres características y la verdad de referencia, que como pudimos ver en la ilustración anterior los nombres de estas variables son: *caracteristicaVTtotal* y *caracteristicaATtotal*, que hacen referencia a valencia y arousal respectivamente.

Una vez que seleccionamos la variable la pantalla que nos aparece es la siguiente.

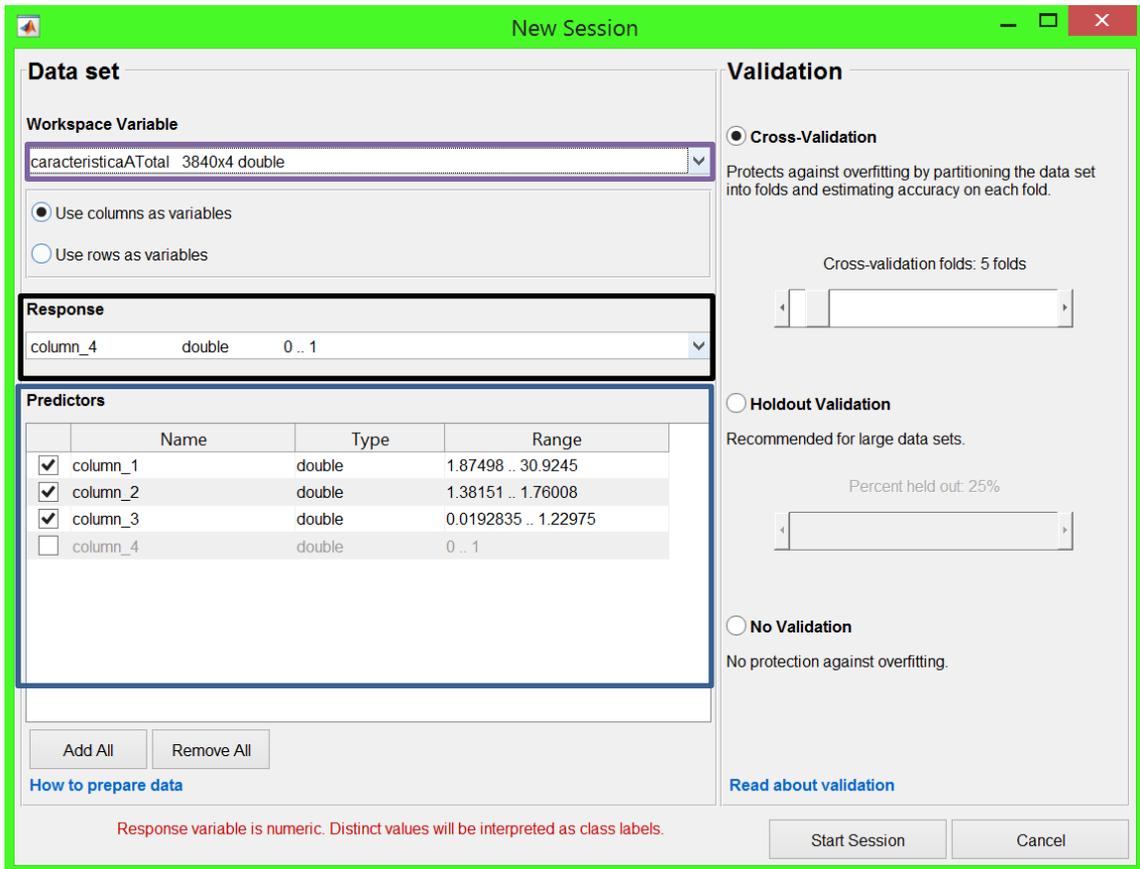


Ilustración 34: Representación gráfica de la ventana que se nos abre cuando insertamos una variable para clasificar.

Como podemos observar en amarillo aparece la lista desplegable de la cual hemos hablado antes. Seleccionamos la característica y automáticamente se nos completan los dos campos marcados en negro y en azul. El campo marcado en negro indica la verdad de referencia, como nosotros teníamos una columna con valores binarios 0 ó 1 por este motivo identifica el programa que esa será nuestra verdad de referencia y en azul nos aparecen las características que se van a utilizar para predecir el resultado de la clasificación.

- 2- Pulsamos sobre 'Star Session' para poder empezar a manejar el clasificador. La aplicación automáticamente establece un conjunto de datos de entrenamiento y un conjunto de datos de prueba. Una vez realizado esto, tenemos que seleccionar el clasificador que queramos probar, en nuestro caso hemos ido probando todos los clasificadores hasta ver cuál de ellos nos proporcionaba mejores resultados. Elegimos el clasificador, pulsamos sobre Train para que empiece a entrenar, esperamos y posteriormente se nos proporcionan los resultados. A continuación en la Ilustración 35 podemos observar el proceso.

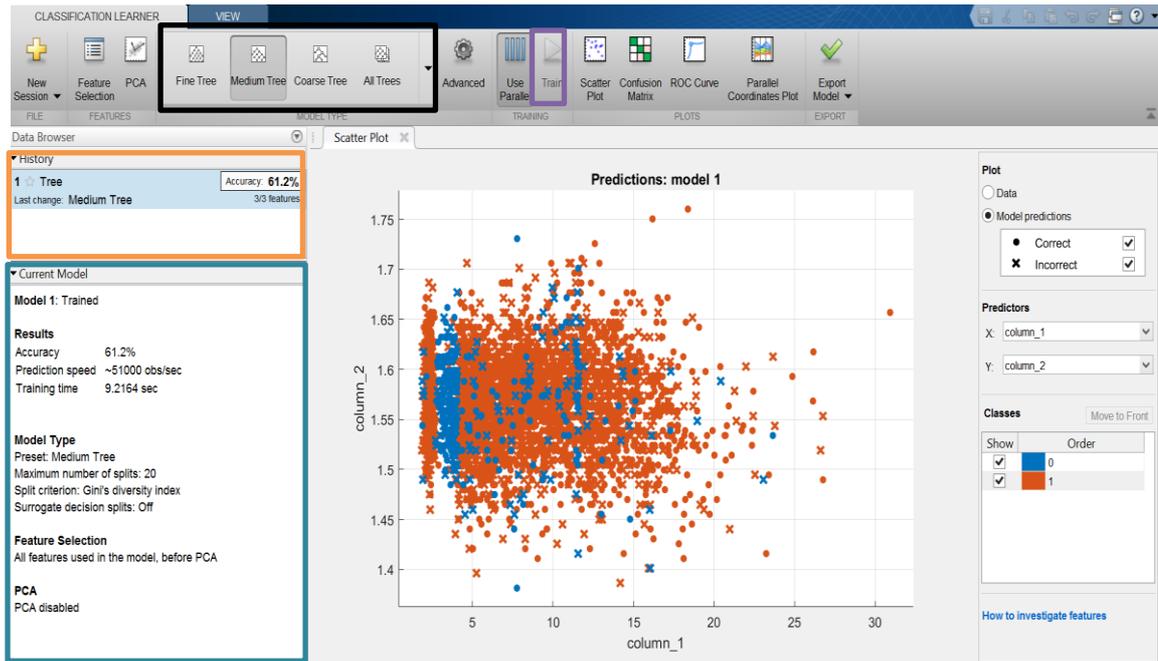


Ilustración 35: Representación gráfica de la pantalla correspondiente a la vista principal de la herramienta utilizada para clasificar.

Como podemos ver en la Ilustración 35, hemos ejecutado un ejemplo para Arousal de un determinado individuo. En negro nos aparece el cuadro para seleccionar el clasificador, podemos elegir entre árboles de decisión, discriminantes lineales, clasificadores SVM (Support Vector Machine), clasificadores que utilizan la información del vecino más cercano, etc. Una vez que elegimos el clasificador pulsamos sobre el botón que aparece bordeado en amarillo. Posteriormente, empieza a entrenar y en el rectángulo verde nos va apareciendo información de todos los clasificadores que hemos ido utilizando y el porcentaje de acierto de cada uno de ellos. En el recuadro azul tenemos información sobre el último clasificador ejecutado y en el centro nos aparece una representación de las muestras que se consiguen acertar y de las que no, los ejes son modificables, pudiendo cambiar cualquiera de ellos e incorporar alguna de las características que nosotros queramos, dentro de las que hayamos cargado en la matriz que le hemos introducido al clasificador.

Los pasos aquí señalados son los que hemos seguido nosotros para llevar a cabo la clasificación, repitiendo el procedimiento para cada uno de los 32 individuos, tanto para medir la valencia como el grado de excitación o arousal. Hemos estado probando con diversos clasificadores para comprobar cuál nos proporcionaba mejores resultados y estos serán presentados en el apartado siguiente.

7- RESULTADOS

Con nuestro estudio buscábamos poder construir un algoritmo que emulara el comportamiento del llevado a cabo por Ning Zhuang et al en [2]. Hasta este apartado los pasos que hemos ido siguiendo han sido prácticamente los mismos que ellos siguen en su estudio, sin embargo en este punto las herramientas que hemos utilizado son diferentes. Como explicamos en el apartado anterior, nosotros hemos utilizado la herramienta de ‘Classification Learner’ que nos proporciona Matlab. Sin embargo, en su estudio ellos hacen uso de una librería denominada ‘LIBSVM’.

7.1- ANÁLISIS REALIZADOS

Para mostrar los resultados y poder realizar una comparativa más exhaustiva, hemos realizado dos experimentos completos. En el primero de ellos, analizamos todos los datos que hemos ido recopilando durante el estudio, es decir, para cada individuo utilizamos los 40 vídeos o pruebas, la información contenida en los 32 canales o electrodos captadores de señales EEG, los 12 ‘frames’ en los que dividimos cada vídeo y 5 funciones IMF. Mientras que en el segundo experimento probamos a estudiar los 40 vídeos o pruebas, la incidencia que tenían 8 de los 32 electrodos en el individuo, los 12 ‘frames’ en los que dividimos cada vídeo y utilizando solamente la primera función IMF que nos proporciona la transformada EMD, que debe ser la que más incidencia tenga en el individuo ya que representa el componente de las señales EEG que cambia más rápido al tener la mayor frecuencia.

Al mismo tiempo, el hecho de utilizar 8 canales o electrodos en vez de los 32 que nos proporcionan señales EEG se debe a que en el artículo que hemos seguido [2] hacen uso de la distancia de Fisher, que es un criterio eficiente de divisibilidad entre clases donde se comparan las distancias medias de todos los niveles, en nuestro caso entre sensores, con el fin de concretar y especificar una hipótesis alternativa para quedarse con los 8 canales más influyentes de los 32.

Basado en este análisis ellos establecen que los 8 canales con mayor influencia en el sujeto son Fp1, Fp2, F7, F8, T7, T8, P7 y P8. Así que en nuestro estudio hemos utilizado dichos canales para probar si realmente su selección mejora los resultados.

En ambos análisis utilizamos cuatro clasificadores con el objetivo de observar el comportamiento de estos, ya que cada uno de ellos pertenece a una categoría distinta. Los clasificadores utilizados

son los siguientes:

- **Medium Tree:** Clasificador basado en árboles de decisión donde el objetivo es predecir el valor de una variable destino en función de diversas variables de entrada. En este caso cada nodo interno denota una prueba en un atributo, cada rama representa el resultado de la prueba y cada hoja tiene una etiqueta de clase.
- **Linear discriminant:** Este clasificador se basa en una generalización del discriminante lineal de Fisher, consiste en intentar encontrar una combinación lineal de rasgos que caracterizan o separan dos o más clases de objetos.
- **Linear SVM (Support Vector Machine):** Se trata de un clasificador de máquina de vectores de soporte, de nuevo dado un conjunto de muestras, se etiquetan y se entrena al clasificador para que sea capaz de predecir la clase de una nueva muestra, en este caso, si hablamos de dos clases, estas se separan en dos espacios lo más amplios posibles mediante un hiperplano que se denomina vector soporte. Posteriormente, dependiendo de la posición en la que se sitúe la nueva muestra se clasificará como perteneciente a una clase u a otra.
- **Subspace discriminant:** Este clasificador se basa en máquinas de vectores de soporte junto con la minimización de la dispersión de datos dentro de la clase. Se trata de un procedimiento iterativo que aplica máquinas de vectores de soporte en subespacios perpendiculares de tal manera que se minimice la varianza dentro de la clase.

Como comentamos al principio de este apartado, en el artículo que seguimos [2] se utiliza una librería denominada LIBSVM, de tal manera que los resultados que mostramos a continuación no son del todo comparables puesto que no se han obtenido de la misma manera, aunque la base de ambos procedimientos sea la misma. En todo caso, dentro de los cuatro clasificadores que hemos establecidos el clasificador *Linear SVM* es el que más se puede asemejar en cuanto a comportamiento a la librería utilizada por ellos. Aunque también resulta de interés la comparación con el clasificador *Subspace discriminant*, ya que también hace uso de una máquina de vectores de soporte.

7.1.1- CASO 1: 40 VÍDEOS/PRUEBAS, 32 CANALES, 12 FRAMES Y 5 IMF'S

A continuación, mostraremos los resultados de este primer caso tanto para arousal como para valencia. Recordemos que teníamos un clasificador por individuo y para cada uno de estos dos aspectos.

Destacar también que los resultados se han obtenido mediante una validación cruzada donde los conjuntos de datos, tanto de entrenamiento como de clasificación son seleccionados por la herramienta de clasificación de Matlab. Esta técnica consiste en que con los datos iniciales se crean dos subconjuntos, el de entrenamiento y el de validación. Posteriormente, el conjunto de datos de entrenamiento se divide en K subconjuntos y en el momento en el que se entrena al clasificador, se toma cada K subconjunto como conjunto de prueba del modelo, mientras que el resto de los datos se toman como conjunto de entrenamiento. Este proceso se repite K veces y en cada iteración se selecciona un conjunto de prueba diferente, mientras que el resto de datos se emplean como conjunto de entrenamiento. Una vez que se finalizan todas las iteraciones, se calcula la precisión del clasificador para el modelo de estudio concreto.

En primer lugar vamos a mostrar en la Tabla 2 los resultados obtenidos para **arousal**.

Individuo ↓	Clasificador ⇒	Medium tree (%)	Linear Discriminant (%)	Linear SVM (%)	Subspace discriminant (%)
1		63,4	63,4	41,7	63,2

2	60	60	43,8	60
3	80	80	80	80
4	60,1	60	60	60
5	52,3	52,5	51,9	52,5
6	57,9	57,6	51,3	57,6
7	62,6	62,5	42,5	62,5
8	59,9	60	42,1	60
9	62,5	62,5	40,6	62,5
10	55	55	45,6	55
11	62,7	62,5	62,5	62,5
12	82,5	82,5	41,8	82,5
13	85	85	43,5	85
14	67,5	67,5	40	67,5
15	52,6	52,5	49,2	52,5
16	53,6	53	49,7	52,4
17	62,5	62,5	44,9	62,5
18	62,6	62,5	39,9	62,5
19	67,5	67,5	39,4	67,5
20	77,5	77,5	31,4	77,5
21	80	80	41,4	77,5
22	62,8	62,5	40,2	62,5
23	67,5	67,5	67,5	67,5
24	82,5	82,5	41,2	82,5
25	75	75	34,9	75
26	57,4	57,5	54,2	57,5
27	67,5	67,5	36,8	67,5
28	50,7	51,1	50,2	51
29	67,4	67,5	37,2	67,5
30	50,8	50,9	50,3	50,9
31	50,7	49,9	50	50
32	69,9	70	32,9	70
Resultado medio (%)	64,68	64,64	46,21	64,53

Tabla 2: Resultados del primer caso para la medida de arousal.

Como podemos apreciar, los resultados obtenidos con 3 de los 4 clasificadores se asemejan bastante, ya que se sitúan en torno al 64,5 % de acierto. Sin embargo, los resultados obtenidos con el clasificador SVM se alejan de esta media, esto se puede deber a que estamos trabajando con una gran cantidad de datos y esto hace que, en ocasiones, el clasificador SVM tenga problemas de sobreajustes al intentar encontrar el hiperplano que se ajuste perfectamente a todas las observaciones. En el caso del artículo que estamos siguiendo [2] los resultados obtenidos haciendo uso de LIBSVM fueron del 67 % de acierto.

En amarillo hemos destacado el límite superior de cada clasificador.

A continuación, mostramos en la Tabla 3 los resultados para la **valencia**.

Individuo ⇩	Clasificador ⇨	Medium tree (%)	Linear Discriminant (%)	Linear SVM (%)	Subspace discriminant (%)
1		61,2	61,1	39,8	61,2
2		62,4	62,5	38,5	62,5

3	55	55	49,4	55
4	60,2	60,1	57,3	60
5	59,9	60	42,2	60
6	75	75	36,8	75
7	70	70	36,5	70
8	55,4	55,2	47,1	55,2
9	52,8	52,8	49,6	52,5
10	54,1	53,8	49,8	53
11	60	60	41,8	60
12	54,7	53,2	48,7	53,2
13	57,8	55,6	52	56,3
14	52,8	52,3	50	52,2
15	52,6	51	50,1	50,2
16	63,2	62,9	62,4	62,9
17	54,9	55	47,4	55
18	65	65	41,4	65
19	57,6	57,5	42,6	57,5
20	57,5	57,6	47,9	57,5
21	52,5	52,4	49,8	52,5
22	52,2	51,1	50,1	50,6
23	67,5	67,5	41,2	67,5
24	53	52,6	52,2	52,5
25	52,9	52,7	48,6	52,6
26	65	65	37,3	65
27	75	75	32,2	75
28	62,5	62,5	41	62,5
29	57,4	57,5	47	57,5
30	67,5	67,5	37,7	67,5
31	64,9	65	37,5	65
32	51,7	50,8	50	50,9
Resultado medio (%)	59,51	59,23	45,50	59,17

Tabla 3: Resultados del primer caso para la medida de valencia.

De nuevo vuelve a ocurrir lo mismo que en la anterior ocasión, todos los clasificadores a excepción del SVM nos proporcionan resultados muy parecidos, en torno, al 59 % de acierto. Sin embargo, el resultado medio obtenido con SVM se aleja de la media, seguramente debido al sobreajuste producido por la gran cantidad de datos con los que estamos trabajando. En el caso del artículo que estamos siguiendo [2] los resultados obtenidos haciendo uso de LIBSVM fueron del 64,6 % de acierto.

De nuevo, los límites superiores de los distintos clasificadores se destacan en amarillo.

7.1.2- CASO 2: 40 VÍDEOS/PRUEBAS, 8 CANALES, 12 FRAMES Y 1 IMF

En esta ocasión tal y como explicamos al principio del apartado, hemos realizado la propuesta que también se realiza en el artículo de Ning Zhuang et al [2] mediante la cual utilizamos 8 canales (los más influyentes) de los 32 que nos proporcionan señales EEG. Y además hacemos uso de una sola función IMF, que debe ser la que mayor influencia tiene que tener al corresponderse con la mayor frecuencia.

De nuevo, la Tabla 4 de resultados que vamos a mostrar hace referencia a la medida de **arousal**.

Individuo ↓	Clasificador →	Medium tree (%)	Linear Discriminant (%)	Linear SVM (%)	Subspace discriminant (%)
1		61,5	61,5	61,2	61
2		61,2	60	60	60
3		79,4	80	80	80
4		59,1	60,1	60	60
5		53,3	52	52,5	52,3
6		58,4	59,3	57,5	58,9
7		62,1	62,5	62,5	62,5
8		59,3	60	60	60
9		62	62,5	62,5	62,5
10		55,1	55,1	55	55
11		63,1	61,6	62,5	62,1
12		82	82,5	82,5	82,5
13		84,5	85	85	85
14		66,5	67,5	67,5	67,5
15		57,2	56,9	57,1	57,1
16		59,3	60,4	60,1	60,3
17		61,9	62,5	62,5	62,5
18		61,9	62,5	62,5	62,5
19		66,9	67,5	67,5	67,5
20		77,2	77,5	77,5	77,5
21		78,9	80	80	80
22		62,7	62,6	62,5	62,5
23		67,1	67,5	67,5	67,5
24		81,6	82,5	82,5	82,5
25		73,7	75	75	75
26		56,6	57,7	57,5	57,8
27		66,8	67,7	67,5	67,6
28		51,5	53,3	52,7	53,3
29		66,4	67,5	67,5	67,5
30		52,8	52,2	50,8	52,4
31		54,4	52	52,2	52,3
32		69	69,9	70	70
Resultado medio (%)		64,79	65,15	65,05	65,16

Tabla 4: Resultados del segundo caso para la medida de arousal

En esta ocasión apreciamos que los cuatro clasificadores nos proporcionan resultados en torno al mismo valor, es decir, a un 65 % de acierto. Es verdad que la mejoría en cuanto al porcentaje de acierto no ha subido en demasía, sin embargo hay algo que llama la atención y es que el clasificador SVM nos proporciona resultados alineados al resto de clasificadores, esto es debido a que los datos han bajado considerablemente en cuanto a cantidad nos referimos y ya no se ocasionan los sobreajustes que hacen que pierda capacidad de acierto. En el caso del artículo que estamos siguiendo [2] los resultados obtenidos haciendo uso de LIBSVM fueron del 72 % de acierto.

En amarillo destacamos los límites superiores de los distintos clasificadores.

Finalmente, mostramos los resultados de este segundo análisis en la Tabla 5 para el caso de **valencia**.

Individuo ↓	Clasificador →	Medium tree (%)	Linear Discriminant (%)	Linear SVM (%)	Subspace discriminant (%)
1		60,2	60,1	60,2	60
2		61,6	62,6	62,5	62,5
3		55,2	54,6	55	54,8
4		59,7	61	60	59,9
5		58,9	59,9	60	60
6		74,1	75	75	75,1
7		69,7	70	70	70
8		55,2	56,3	55,8	56,6
9		56,3	53,4	53,3	52,6
10		62,6	61	61,4	61
11		58,8	59,9	56,9	60
12		57,1	55,7	54,5	55,4
13		65	61,3	60,2	61,1
14		53,8	55,2	54	55,5
15		56,1	54,4	55,1	54,6
16		66,4	66,5	65,7	66,5
17		55,1	55	55	55
18		64,3	65	65	65
19		58,7	57,3	57,5	57,4
20		58,9	55,1	57,5	57,2
21		53,4	52,7	52,5	52
22		55	55,5	54,4	55,3
23		67,4	67,5	67,5	67,5
24		53,2	53,7	52,5	53,2
25		54,4	55,5	55,6	56
26		64,4	65	65	65
27		74,3	74,9	75	75
28		61,9	62,5	62,5	62,5
29		55,8	57,4	57,5	57,5
30		66,5	67,5	67,5	67,5
31		62,7	65	65	65
32		54,8	52,8	53,2	52,7
Resultado medio (%)		60,36	60,29	60,09	60,29

Tabla 5: Resultados del segundo caso para la medida de valencia.

De nuevo observamos la sintonía de resultados en los cuatro clasificadores, que nos proporcionan alrededor de un 60% de acierto. En esta ocasión el porcentaje de acierto con respecto a la misma media en el caso 1 sube una media de un 1%, pero de nuevo destacar el hecho de que la simplificación de datos hace que el clasificador SVM proporcione mejores resultados. En el caso del artículo que estamos siguiendo [2] los resultados obtenidos haciendo uso de LIBSVM fueron del 69 % de acierto.

Como en casos anteriores, en amarillo hemos destacado los límites superiores de los clasificadores.

Con el objetivo de establecer cuál es el mejor clasificador dentro de los cuatro que proponemos, ya que en el segundo caso de estudio los resultados proporcionados por los cuatro clasificadores son muy parecidos, vamos a presentar figuras donde representamos la media y desviación estándar en cada uno de los casos. Puesto que la mejor forma para seleccionar uno de los clasificadores es ver cuál es el más estable.

7.2- MEDIDA DE LA DESVIACIÓN ESTÁNDAR DE LOS CLASIFICADORES

Nota: En todas las figuras que mostraremos a continuación, el eje vertical hace referencia al % de acierto del clasificador y el eje horizontal al número de individuos que hemos estudiado.

7.2.1- DESVIACIÓN ESTÁNDAR CASO 1, AROUSAL

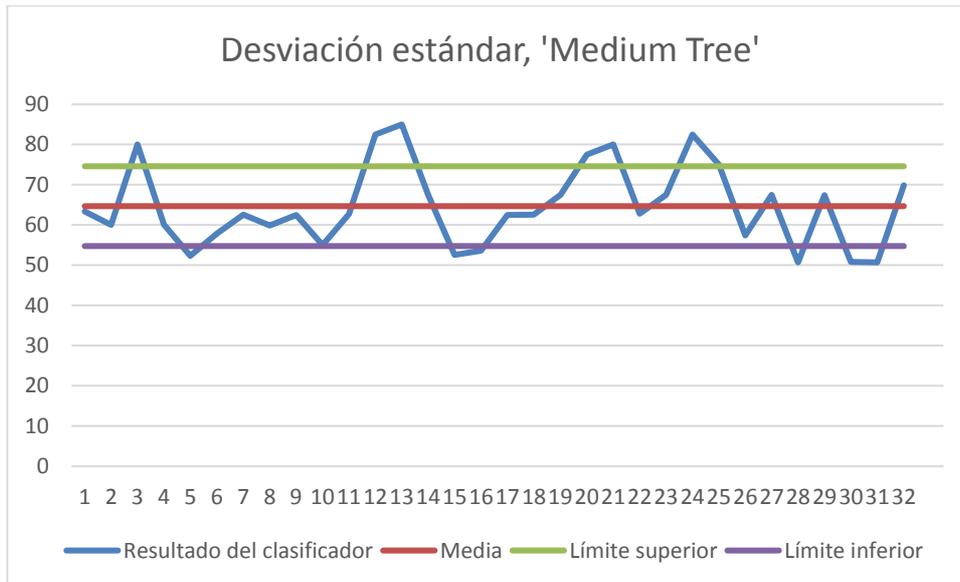


Ilustración 36: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Medium tree'.

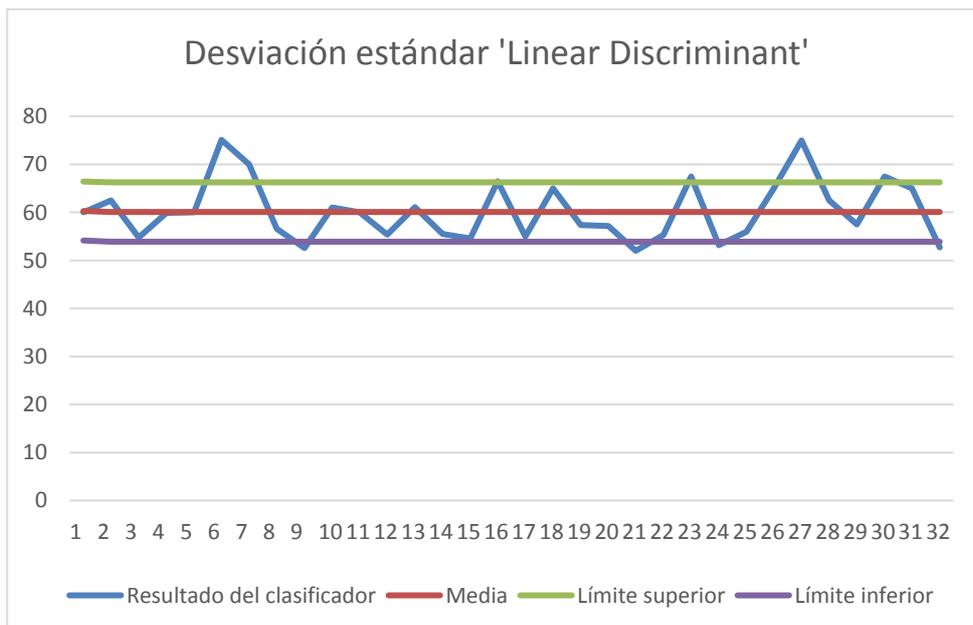


Ilustración 37: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Linear Discriminant'.

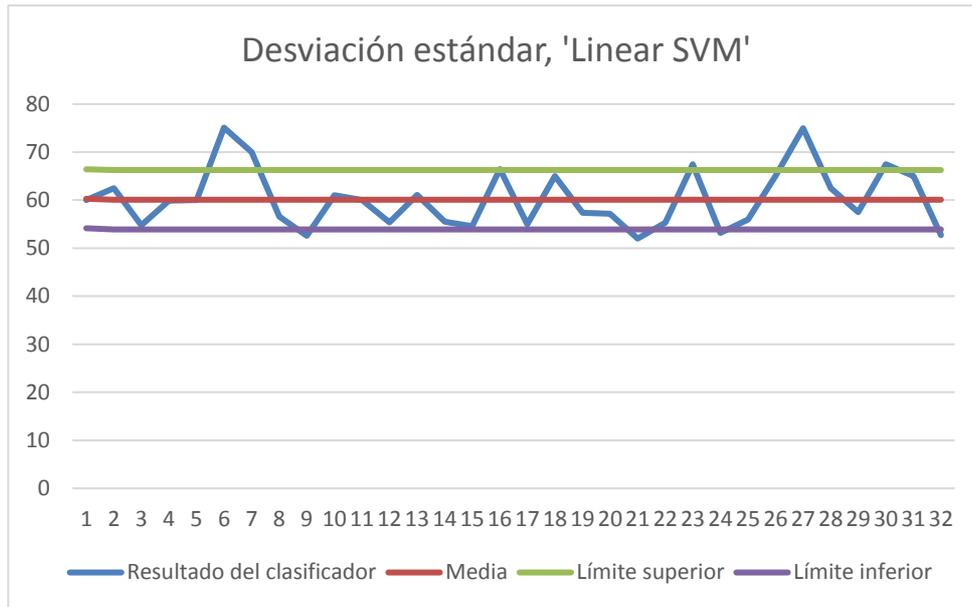


Ilustración 38: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Linear SVM'.

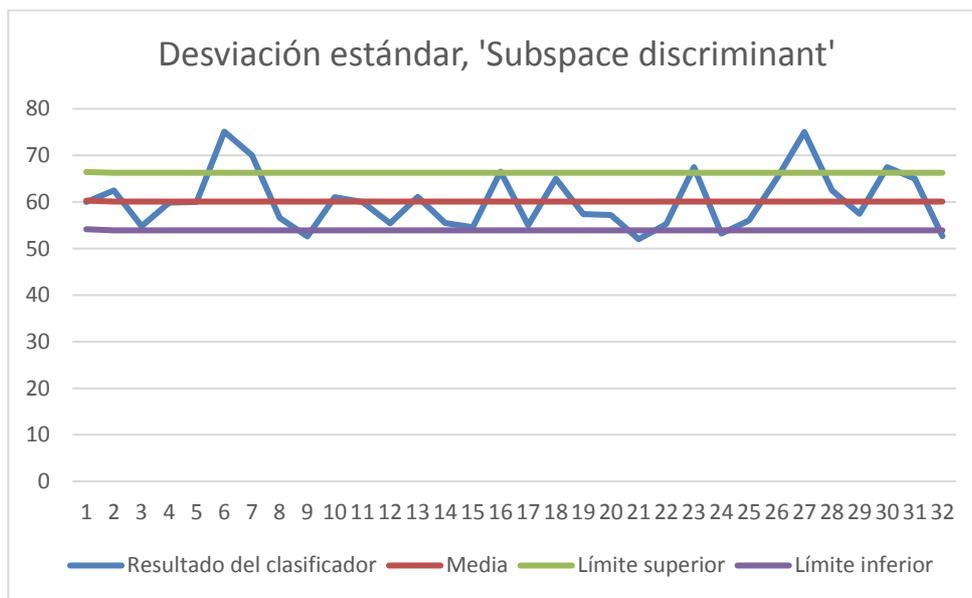


Ilustración 39: Representación de la desviación estándar, en el caso 1, para la medida de Arousal y con el clasificador 'Subspace discriminant'.

Clasificador	Media (%)	Desviación típica (%)
Medium tree	64,68	9,92
Linear discriminant	64,64	9,96
Linear SVM	46,21	10,095
Subspace discriminant	64,53	9,87
LIBSVM [8]	67	-----

Tabla 6: Resultados obtenidos para el caso 1 en la medida de arousal.

Como pudimos intuir con el cálculo de la media, el clasificador *Linear SVM* presenta una desviación típica más alta que el resto. Los otros tres clasificadores presentan desviaciones típicas similares, tal y como apreciamos en la Tabla 6. Estableceríamos como mejor clasificador en este caso, el *Medium Tree*, aunque exceptuando el *Linear SVM*, todos presentan un comportamiento equitativo con respecto a la estabilidad.

7.2.2- DESVIACIÓN ESTÁNDAR CASO 1, VALENCIA

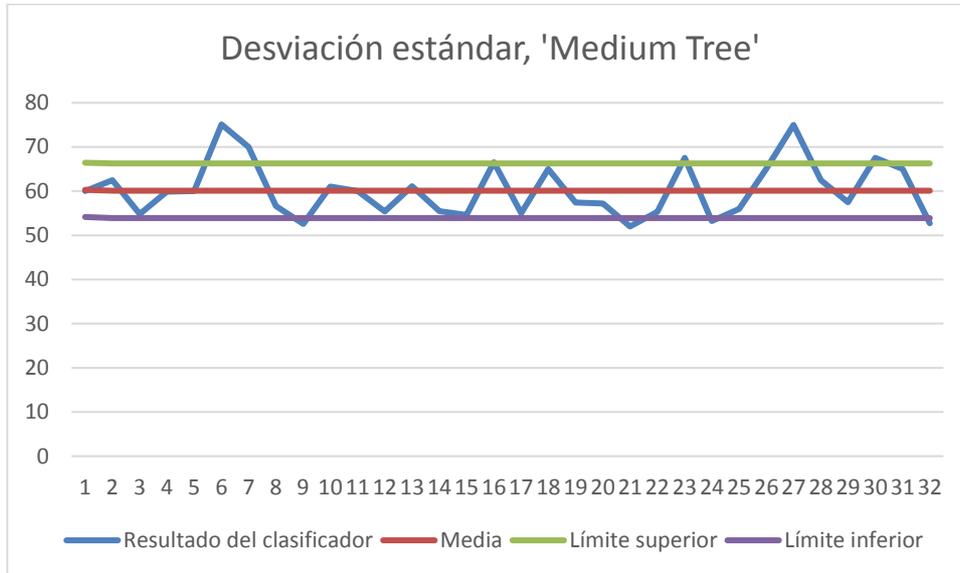


Ilustración 40: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador 'Medium tree'.

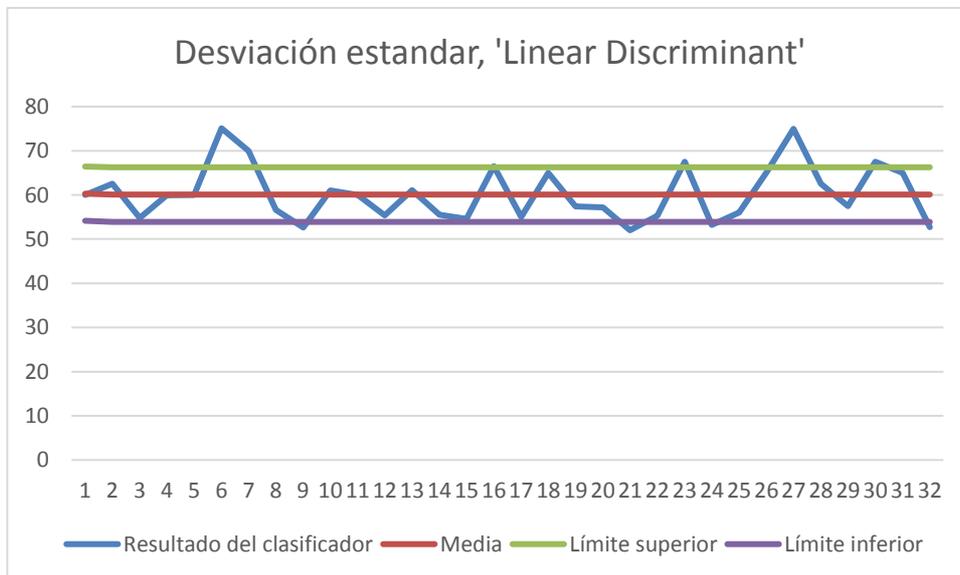


Ilustración 41: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador 'Linear Discriminant'.

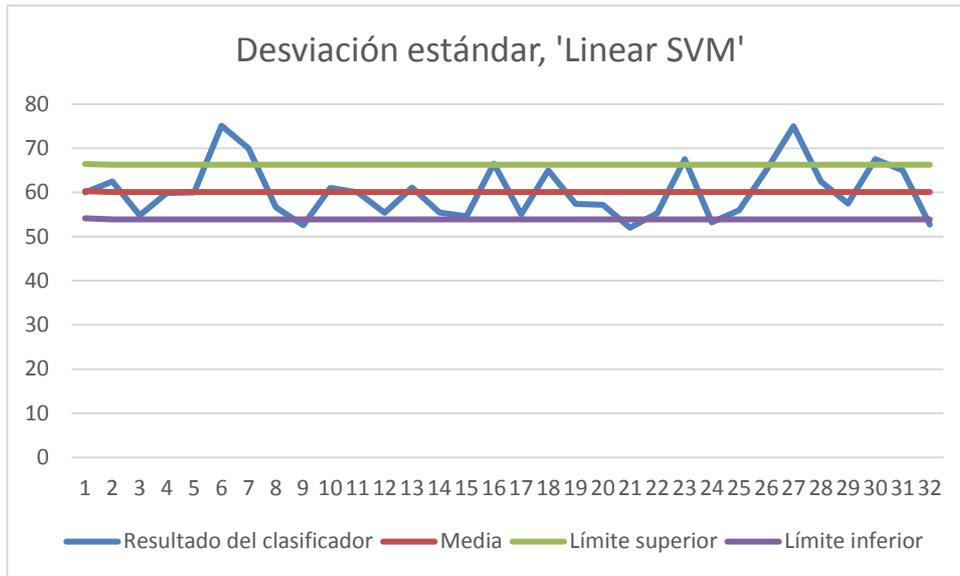


Ilustración 42: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador 'Linear SVM'.

8.

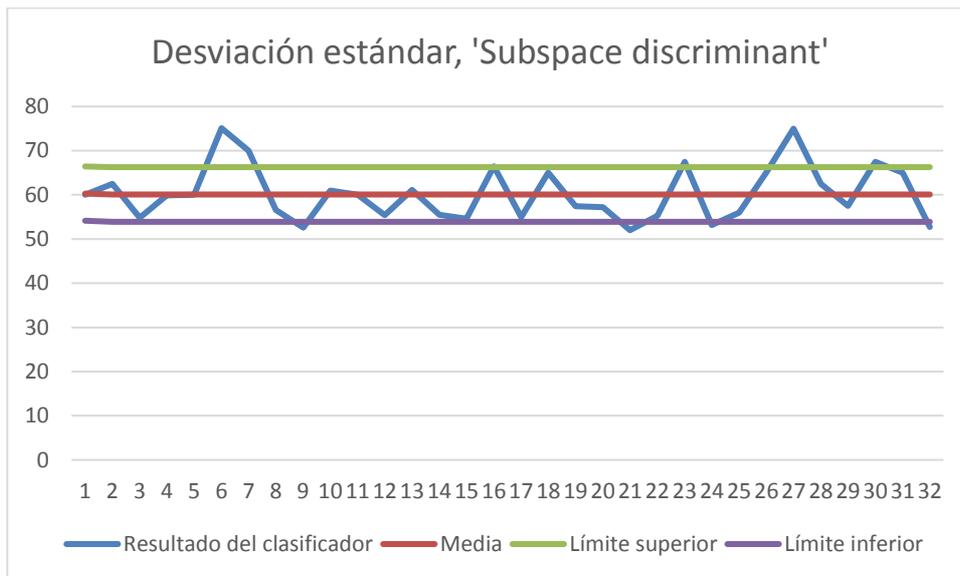


Ilustración 43: Representación de la desviación estándar, en el caso 1, para la medida de Valencia y con el clasificador 'Subspace discriminant'.

Clasificador	Media (%)	Desviación típica (%)
Medium tree	59,51	6,51
Linear discriminant	59,23	6,74
Linear SVM	45,50	6,60
Subspace discriminant	59,17	6,82
LIBSVM [8]	64,60	-----

Tabla 7: Resultados obtenidos para el caso 1 en la medida de valencia.

En este caso, la elección del clasificador más estable es más sencilla, puesto que coincide tanto la mejor media como la desviación típica más pequeña, como apreciamos en la Tabla 7. Es el caso del clasificador *Medium tree*.

7.2.3- DESVIACIÓN ESTÁNDAR CASO 2, AROUSAL

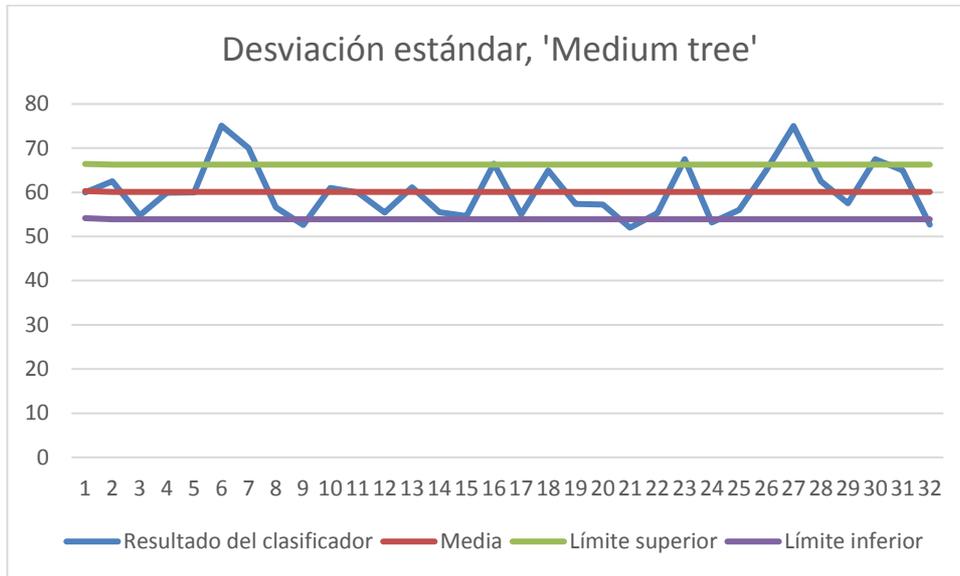


Ilustración 44: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador 'Medium tree'.

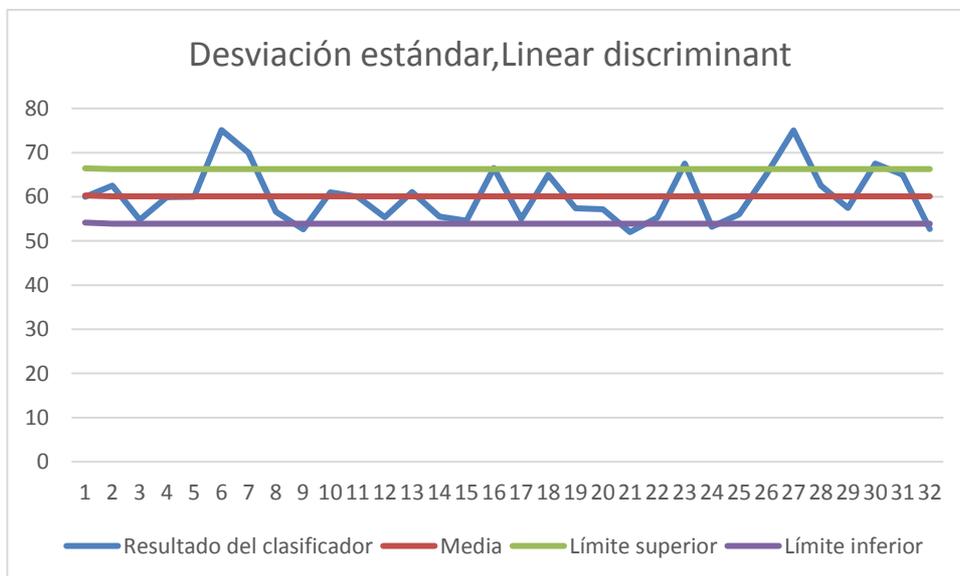


Ilustración 45: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador 'Linear Discriminant'.

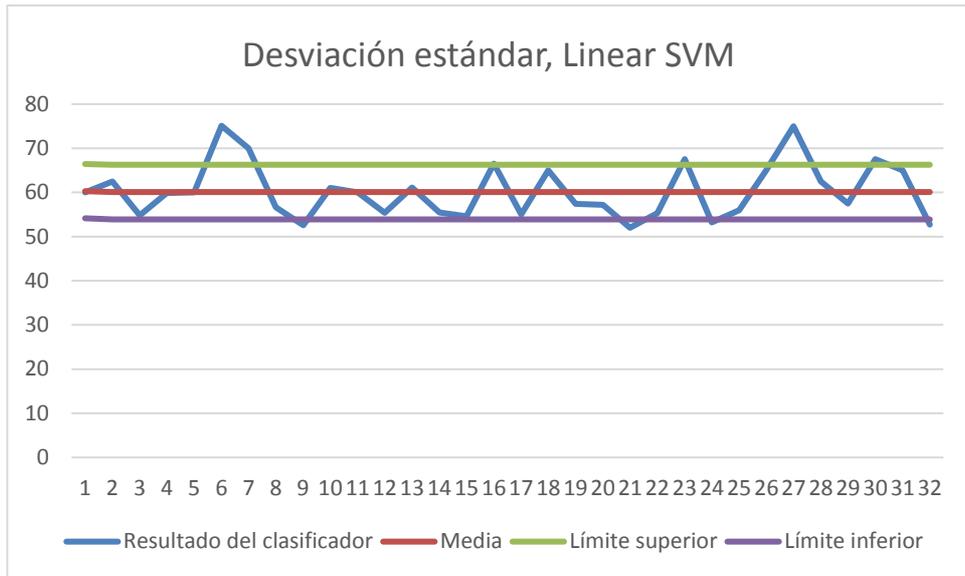


Ilustración 46: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador ‘Linear SVM’.

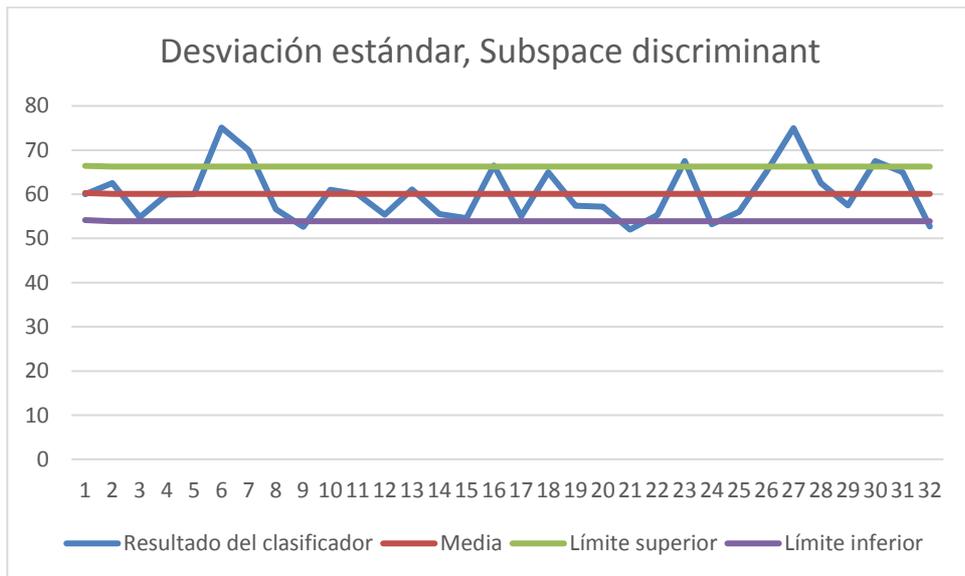


Ilustración 47: Representación de la desviación estándar, en el caso 2, para la medida de Arousal y con el clasificador ‘Subspace discriminant’.

Clasificador	Media (%)	Desviación típica (%)
Medium tree	64,79	9,06
Linear discriminant	65,15	9,37
Linear SVM	65,06	9,48
Subspace discriminant	65,16	9,34
LIBSVM [8]	72	-----

Tabla 8: Resultados obtenidos para el caso 2 en la medida de arousal.

Como en el primer caso, la elección del clasificador más estable en esta ocasión sigue siendo complicada, además ahora hemos conseguido que los resultados proporcionados por el clasificador SVM estén dentro del rango del resto de clasificadores, como se aprecia en la Tabla 8, por lo tanto se complica aún más la elección. Desde el punto de vista de la desviación típica, parece ser que el clasificador *Medium tree* presenta el mejor resultado, pero desde el punto de vista de la media, tanto *Linear Discriminant* como *Subspace discriminant* presentan resultados parecidos. Como la estabilidad nos la indica mayoritariamente la desviación, nos quedamos con que el clasificador más estable es el *Medium tree*.

7.2.4- DESVIACIÓN ESTÁNDAR CASO 2, VALENCIA

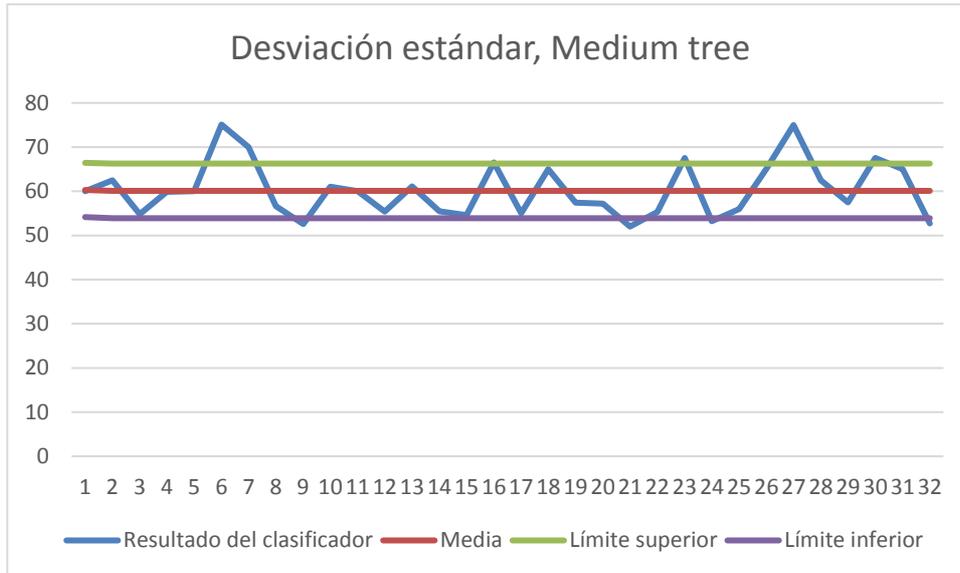


Ilustración 48: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador 'Medium tree'.

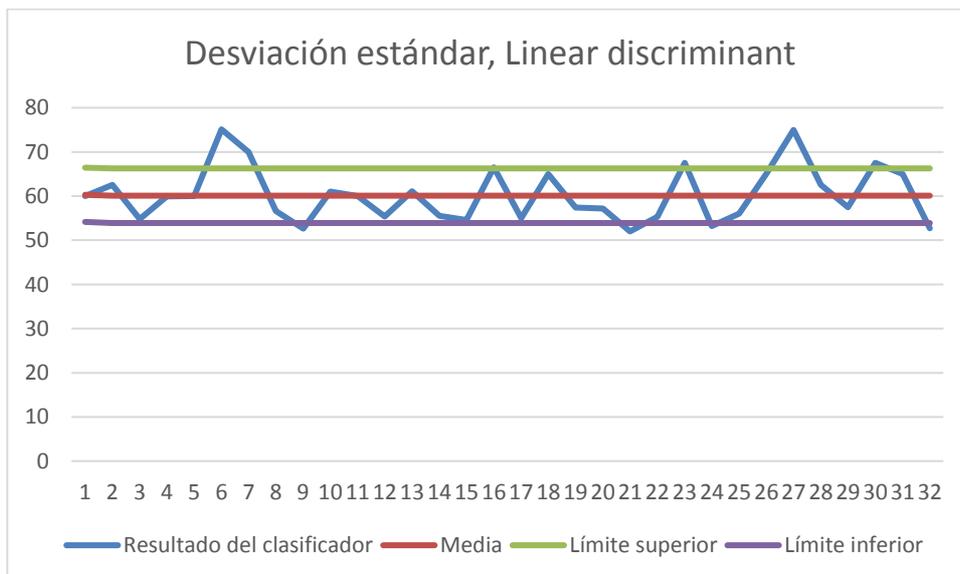


Ilustración 49: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador 'Linear Discriminant'.

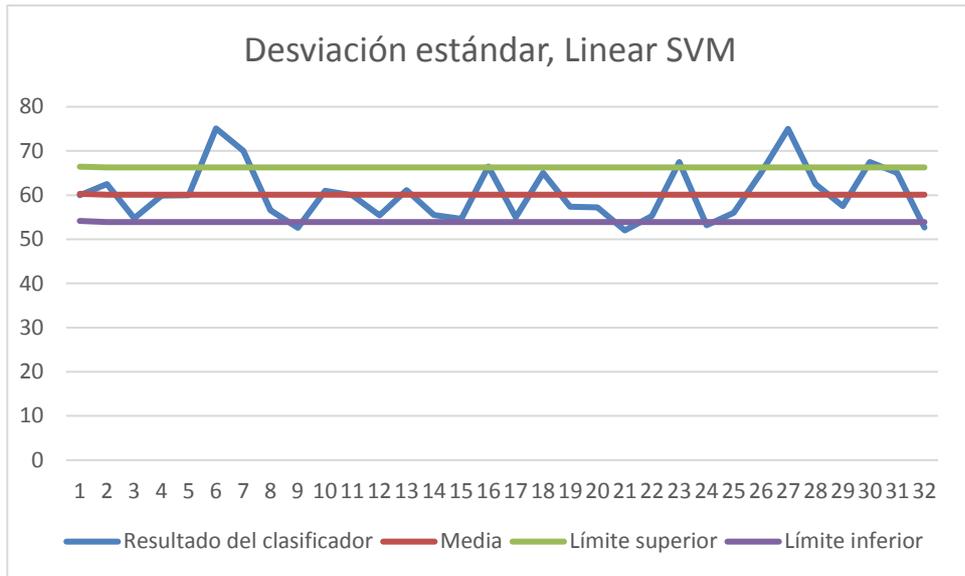


Ilustración 50: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador ‘Linear SVM’.

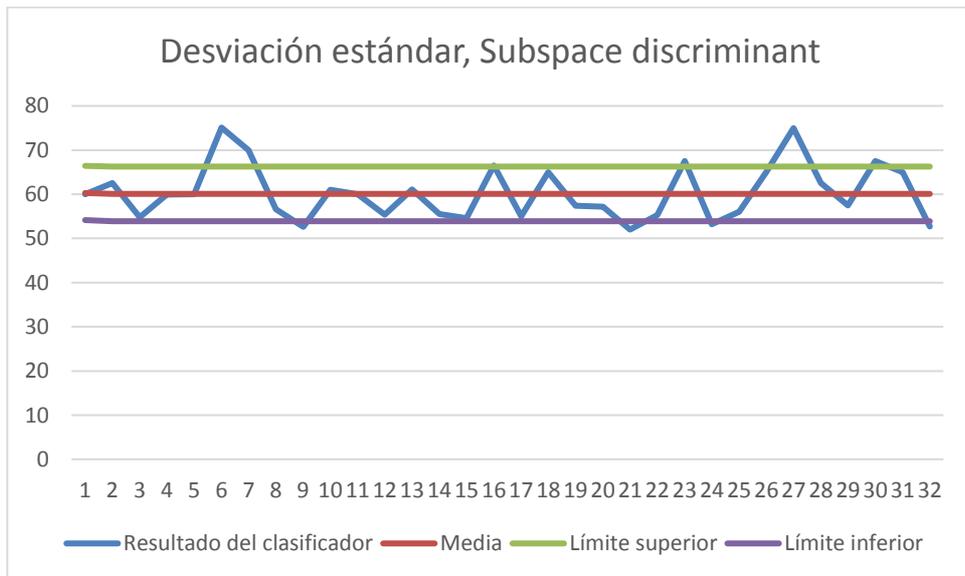


Ilustración 51: Representación de la desviación estándar, en el caso 2, para la medida de Valencia y con el clasificador ‘Subspace discriminant’.

Clasificador	Media (%)	Desviación típica (%)
Medium tree	60,36	5,75
Linear discriminant	60,29	6,12
Linear SVM	60,09	6,19
Subspace discriminant	60,29	6,14
LIBSVM [8]		-----

Tabla 9: Resultados obtenidos para el caso 2 en la medida de valencia.

De nuevo la elección del clasificador para la medida de valencia resulta más sencilla, puesto que

nos coincide la mejor media con la desviación típica más pequeña, como podemos ver en la Tabla 9. Por lo tanto, podemos decir que en este caso el clasificador más estable será el *Medium tree*.

7.3- RESUMEN FINAL DE LOS RESULTADOS

A continuación mostraremos en la Tabla 10 todos los resultados obtenidos para cada uno de los casos y su desviación estándar correspondiente, esta última aparecerá entre paréntesis junto con el valor medio obtenido por el clasificador. Además hemos incluido una columna para comparar con los resultados obtenidos en [2].

CASO 1: 40 VÍDEOS/PRUEBAS, 32 CANALES, 12 FRAMES Y 5 IMF'S PARA LA MEDIDA DE AROUSAL				
MEDIUM TREE (%)	LINEAR DISCRIMINANT (%)	LINEAR SVM (%)	SUBSPACE DISCRIMINANT (%)	LIBSVM (%)
64,68 (9,92)	64,64 (9,96)	46,21 (10,09)	64,53 (9,87)	67
CASO 1: 40 VÍDEOS/PRUEBAS, 32 CANALES, 12 FRAMES Y 5 IMF'S PARA LA MEDIDA DE VALENCIA				
MEDIUM TREE (%)	LINEAR DISCRIMINANT (%)	LINEAR SVM (%)	SUBSPACE DISCRIMINANT (%)	LIBSVM (%)
59,51 (6,51)	59,23 (6,74)	45,50 (6,60)	59,17 (6,82)	64,60
CASO 2: 40 VÍDEOS/PRUEBAS, 8 CANALES, 12 FRAMES Y 1 IMF PARA LA MEDIDA DE AROUSAL				
MEDIUM TREE (%)	LINEAR DISCRIMINANT (%)	LINEAR SVM (%)	SUBSPACE DISCRIMINANT (%)	LIBSVM (%)
64,79 (9,06)	65,15 (9,37)	65,06 (9,48)	65,16 (9,34)	72
CASO 2: 40 VÍDEOS/PRUEBAS, 8 CANALES, 12 FRAMES Y 1 IMF PARA LA MEDIDA DE VALENCIA				
MEDIUM TREE (%)	LINEAR DISCRIMINANT (%)	LINEAR SVM (%)	SUBSPACE DISCRIMINANT (%)	LIBSVM (%)
60,36 (5,75)	60,29 (6,12)	60,09 (6,19)	60,29 (6,14)	

Tabla 10: Resumen de los resultados de todos los casos por clasificador, junto con la desviación típica obtenida en cada uno de ellos y el resultado conseguido en [2] mediante LIBSVM.

Finalmente, vamos a representar una figura para comparar todos los resultados por clasificador junto con su error.

Como podemos observar en la Ilustración 52 hemos representado los dos casos distintos de estudio por clasificador para cada una de las características, es decir, tanto para valencia como para arousal.

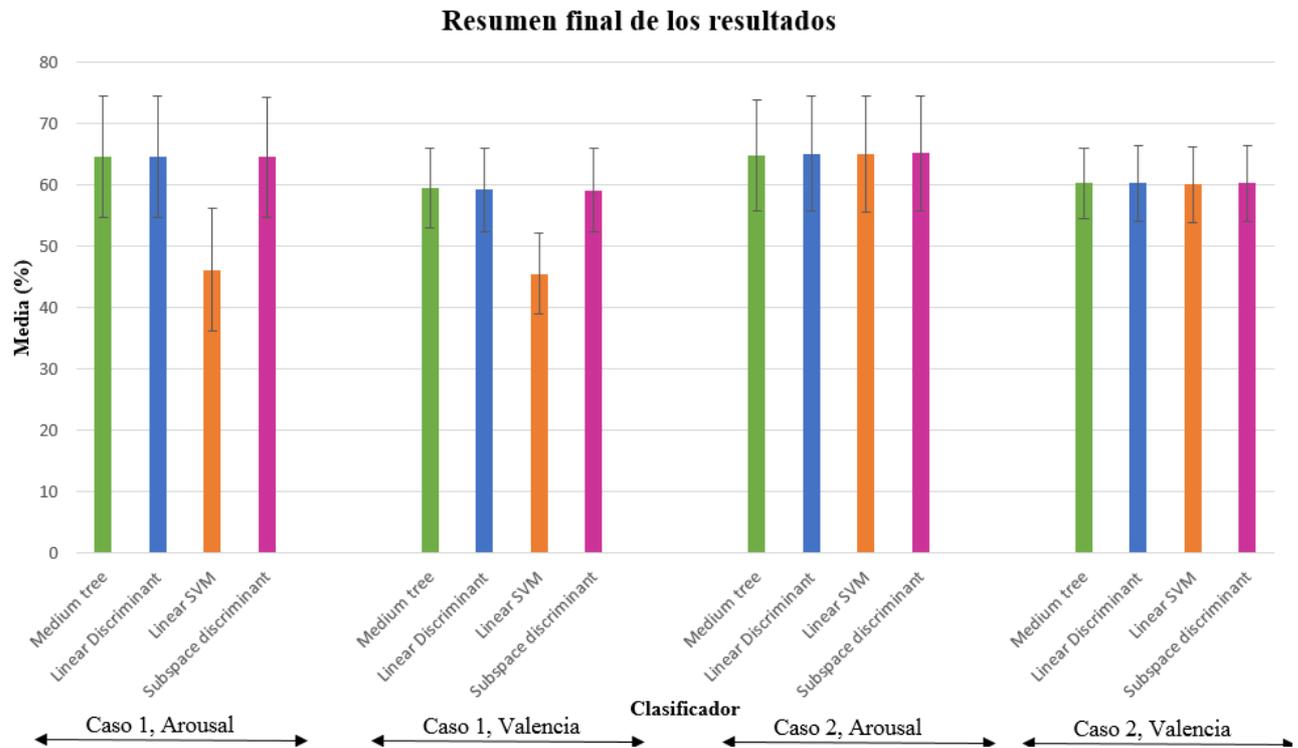


Ilustración 52 : Representación gráfica de todos los resultados obtenidos por clasificador y casos, junto con la desviación típica.

Como podemos ver en la figura anterior y como ya hemos comentado, en los casos 1 tanto para la medida de valencia como para la medida de arousal en el clasificador 3 (SVM) se produce una inestabilidad considerable respecto al resto de clasificadores, esto es debido como dijimos al principio del apartado, a que al trabajar con una gran cantidad de datos los resultados proporcionados se ven claramente alterados no proporcionándonos fiabilidad. Destacar también como se aprecia la mejora en el caso 2 para la medida de valencia con respecto al caso 1, además en esta ocasión podemos observar la estabilidad de los resultados obtenidos por los cuatro clasificadores. Dicha mejora en los resultados también se puede observar para el caso de arousal, aunque en menor proporción.

Con respecto a la estabilidad, podemos ver como los resultados no cambian mucho de un clasificador a otro, sobretodo para las medidas de los casos 2. Además destacar que cuando medimos la valencia, la desviación típica, es decir, el distanciamiento de los resultados con respecto a la media es menor que para el caso de arousal, donde la diferencia es mayor.

8- CONCLUSIONES

En este trabajo hemos querido corroborar la idea llevada a cabo por Ning Zhuang et al en [2] donde haciendo uso de una base de datos ‘DEAP’ ya etiquetada, basada en la captación señales EEG por medio de un casco de electrodos, se consigue clasificar las emociones de forma automática desde el punto de vista de arousal y valencia.

Los resultados presentados en el apartado previo siguen la estela de investigaciones anteriores como la realizada por Ning Zhuang et al en [2]. La diferencia porcentual existente entre ambos resultados se debe a las distintas herramientas que hemos utilizado nosotros para clasificar con respecto a la llevada a cabo por el modelo de estudio que hemos seguido. Además resaltar que el hecho de simplificar datos, utilizando los 8 canales más influyentes según el artículo que hemos seguido [2] y con una sola función IMF presenta mejores resultados, sobretodo en valencia, que utilizando todos los datos posibles, es decir, 32 canales EEG y 5 funciones IMF por individuo.

Si bien, los objetivos puestos en este proyecto se han cumplido, ya que hemos comprobado de primera mano que existe una relación entre el ámbito emocional del ser humano y el científico, ya que queda demostrado que por medio de las señales EEG somos capaces de conseguir clasificar el ámbito emocional en las dimensiones de arousal y valencia.

Además queda constancia de la importancia que este tipo de desarrollos científicos puede tener para todos los ámbitos que engloben a la capacidad emocional del ser humano. Tanto para el diagnóstico médico, como para el ámbito psicológico, pero también para intentar mejorar el comportamiento de la sociedad en nuestros días.

9- FUTURAS LÍNEAS DE INVESTIGACIÓN

Teniendo en cuenta los resultados obtenidos en nuestro análisis, que siguen la estela de investigaciones realizadas en el mismo ámbito, es cierto que existe posibilidad de mejora. Además viendo los avances tecnológicos que se dan en la actualidad pronto se conseguirá alcanzar resultados más óptimos.

Entre todas las posibles señales fisiológicas que podemos medir para el análisis de las emociones, queda demostrado que el estudio de las señales EEG es el que más información nos presenta y mayor potencial de estudio tendrá en un futuro, por lo tanto, pensamos que no se debe de parar de trabajar en este ámbito.

Sin embargo, uno de los puntos fuertes de investigaciones futuras debería de ser analizar las emociones, pero utilizando recursos propios, es decir, alargar el estudio en el tiempo para que se pueda recopilar datos e información propia, llevando a cabo la realización de una base de datos amplia donde todos los elementos sean conocidos y el tratamiento con los individuos se conozca de primera mano, ya que aunque hemos utilizado información correctamente etiquetada y explicada, en ocasiones hemos tenido que realizar suposiciones que pueden dar lugar a error, sin embargo, esto se puede solventar si conocemos de primera mano los datos, cómo se han tomado, qué se ha tenido en cuenta, etc.

Por otro lado, en estudios posteriores, sería necesario realizar un análisis más detallado de las características a utilizar o ver si sería necesario aumentar el número de características que hemos realizado en nuestro estudio. Durante la realización del estado del arte, pudimos comprobar que la tendencia con respecto a las características es abarcar características tanto en el dominio del tiempo como en el dominio de la frecuencia y no centrarse únicamente en el estudio de características en un dominio concreto.

Finalmente, sería interesante realizar un estudio más amplio de los clasificadores a utilizar y analizar qué herramienta nos puede proporcionar mejores resultados. En nuestro caso, se puede comprobar que la librería utilizada por Ning Zhuang et al en [2] proporciona mejores resultados que los clasificadores utilizados por nosotros con la herramienta de *Classification Learner* de Matlab.

Destacar que el análisis de las emociones será un tema puntero en el futuro, ya que se están desarrollando técnicas que pueden proporcionarnos mejores resultados como puede ser la espectroscopía del infrarrojo cercano mediante la cual se penetra dentro del cráneo de forma no

invasiva y con gran profundidad, además esta técnica es más resistente al ruido eléctrico e impone menos restricciones al movimiento del cuerpo.

REFERENCIAS

- [1] P. Florín, «La Opinión,» Enero 2014. [En línea]. Available: <https://laopinion.com/2014/01/07/enfermedades-emocionales-y-fisicas-estan-conectadas/>. [Último acceso: Mayo 2020].
- [2] Z. Ning, Z. Ying, Li Tong, Z. Hanming y Y. Bin , «Emotion recognition from EEG signals using multidimensional information in EMD domain,» *Hindawi*, vol. 2017, pp. 1-9, 2017.
- [3] Fucsia, «Fucsia,» 2019. [En línea]. Available: <https://www.fucsia.co/belleza-y-salud/bienestar/articulo/efectos-de-las-emociones-en-el-cuerpo/71162>. [Último acceso: Mayo 2020].
- [4] R. Bisquerra, E. Punset, F. Mora, E. García Navarro, E. López Cassa, J. C. Pérez González, L. Lantieri, M. Nambiar, P. Aguilera, N. Segovia y O. Planells, ¿Cómo educar las emociones?: la inteligencia emocional en la infancia y en la adolescencia, Hospital Sant Joan de Déu, 2012.
- [5] I. Pico, «Psicopico,» 2016. [En línea]. Available: <https://psicopico.com/la-rueda-las-emociones-robert-plutchik/>. [Último acceso: Mayo 2020].
- [6] B. D. Ovejero, «Control de respuestas emocionales: investigación y aplicaciones,» 2013.
- [7] J. M. Mestre Navas y R. Guil Bozal, La regulación de las emociones, Madrid: Ediciones Pirámide , Grupo Anaya, 2012.
- [8] A. Reyes, «psicoemocionat,» 2017. [En línea]. Available: <https://www.psicoemocionat.com/6-diferencias-entre-emociones-y-sentimientos/>. [Último acceso: Abril 2020].
- [9] «DTMqueretaro,» [En línea]. Available: <http://www.dtmqueretaro.com/2015/06/intensamente-una-pelicula-llena-de.html>. [Último acceso: Abril 2020].
- [10] A. Triglia, «Culturainquieta,» 24 Febrero 2017. [En línea]. Available: <https://culturainquieta.com/es/inspiring/item/11643-sistema-limbico-el-area-del-cerebro-donde-nacen-las-emociones.html>. [Último acceso: Mayo 2020].
- [11] J. I. Pérez, «CulturaCientífica,» 8 Agosto 2017. [En línea]. Available: <https://culturacientifica.com/2017/08/08/sistemas-nerviosos-sistema-limbico/>. [Último acceso: Mayo 2020].
- [12] S. M. Collado, «PsicoActiva,» [En línea]. Available: <https://www.psicoactiva.com/blog/sistema-limbico-anatomia-memoria-emociones/>. [Último acceso: Mayo 2020].
- [13] A. Torres, «Psicologiaymente,» 2019. [En línea]. Available: <https://psicologiaymente.com/neurociencias/hipotalamo>. [Último acceso: Mayo 2020].

- [14] G. Boeree, «webspaceship.edu» [En línea]. Available: <http://webspaceship.edu/cgboer/genesp/emocional.html>. [Último acceso: Mayo 2020].
- [15] G. Boeree, «Psicología-online,» Marzo 2018. [En línea]. Available: <https://www.psicologia-online.com/el-sistema-nervioso-emocional-1171.html>. [Último acceso: Mayo 2020].
- [16] J. B. Vázquez, *Determinación de estados emocionales durante el uso de BCI mediante señales fisiológicas*, Sevilla: Escuela Técnica Superior de Ingeniería, 2013.
- [17] Real Academia Española, «Real Academia Española,» 2019. [En línea]. Available: <https://dle.rae.es/emocion>. [Último acceso: 13 Abril 2020].
- [18] S. González, «Wikipedia,» 2020. [En línea]. Available: <https://es.wikipedia.org/wiki/Electroencefalografia>. [Último acceso: 23 Abril 2020].
- [19] Y. Hyun Joong y C. Seong Youb, «EEG Spectral Analysis in Valence and Arousal Dimensions of Emotion,» de *International Conference on Control, Automation and Systems*, Gyeonggi-do (Corea), 2011.
- [20] L. Yuan Pin y J. Tzyy Ping, «Exploring Day-to-Day Variability in EEG-based Emotion Classification,» de *IEEE International Conference on Systems, Man and Cybernetics*, San Diego (USA), 2014.
- [21] C. Guillaume, A.-A. Karim y P. Thierry, «Valence-arousal evaluation using physiological signals in an emotion recall paradigm,» *IEEE*, pp. 2662-2667.
- [22] Z. Hanieh y F. Hassan, «A new feature extraction method to improve emotion detection using EEG signals,» *Electronic Letters on Computer Vision and Image Analysis*, vol. 17, n° 1, pp. 29-44, 2018.
- [23] Z. Wei-Long y L. Bao-Liang, «Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition With Deep Neural Networks,» *IEEE TRANSACTIONS ON AUTONOMOUS MENTAL DEVELOPMENT*, vol. 7, n° 3, pp. 162-174, 2015.
- [24] M. Á. Guevara Pérez y M. Hernández González, «EEGmagic: programa para analizar señales electroencefalográficas,» *Revista Mexicana de ingeniería biomédica*, vol. 30, n° 1, pp. 41-53, 2009.
- [25] R. B. Navarro, «Pardell,» 2016. [En línea]. Available: <https://www.pardell.es/electroencefalografo.html>. [Último acceso: Mayo 2020].
- [26] R. B. Navarro, *Electroencefalografía*, Madrid: Universidad de Alcalá.
- [27] Pardo Anatomy, «Pardo Anatomy,» [En línea]. Available: <https://sites.google.com/site/pardoanatomy/home/puntos-craneometricos>. [Último acceso: Mayo 2020].
- [28] Neurofeedback, «Neurofeedback,» Julio 2019. [En línea]. Available: <https://www.neurofeedback.cat/question-las-ondas-cerebrales/>. [Último acceso: Mayo 2020].
- [29] S. G. Priyanka y P. A.N., «Human emotion recognition using non linear and non stationary EEG signal,» de *International Conference on Automatic and Dynamic Optimization Techniques (ICACDOT)*, Pune (India), 2016.
- [30] I. Aldecoa Bilbao, N. Carné Serrano y E. Monte Moreno, «Separación ciega de fuentes,» *Rama de estudiantes del IEEE de Barcelona*, pp. 63-72, 2003.

- [31] S. Koelstra, C. Muhl, M. Soleymani, J.-S. Lee, A. Yazdani, T. Ebrahimi , T. Pun, A. Nijholt y Y. Patras, «DEAP: A Database for Emotion Analysis Using Physiological Signals,» *IEEE TRANSACTIONS ON AFFECTIVE COMPUTING*, vol. 3, n° 1, 2012.
- [32] MQL5, «MQL5,» Mayo 2014. [En línea]. Available: <https://www.mql5.com/es/articles/439>. [Último acceso: Mayo 2020].
- [33] F. M. Rodríguez, «Transformada de Hilbert-Huang y sus aplicaciones en ingeniería y ciencias,» *Laboratorio de Acústica y Electroacústica - Escuela de Ingeniería Electrónica - Universidad Nacional de Rosario*.
- [34] G. R. Cebollero, «Procesado de señales electroencefalográficas para determinar características espectrales de episodios epilépticos,» 2011.

Aunque como hemos relatado en diversas ocasiones hemos realizado dos análisis, variando tanto el número de canales como de IMF's. En esta parte del trabajo vamos a incorporar el código Matlab creado para uno de los individuos tanto en el primer caso, es decir con todos los canales y 5 IMF's; como en el segundo, con 8 canales concretos y 1 IMF.

El mismo código se ha utilizado para el resto de individuos cambiando siempre la señal de entrada.

Como ejemplo mostraremos ambos casos para el individuo 6.

CASO 1: 40 VÍDEOS/PRUEBAS, 32 CANALES, 12 FRAMES, 5 IMF'S

```
clc
clear all

%% Aplicamos para las 32 señales --> 32 individuos %%
person6=load('s06.mat');
%Como se trata de un elemento struct me quedo solamente con los datos.
datosPerson6 = person6.data;
%Vamos a muestrear con una frecuencia de 128 Hz
fs = 128;
%Segundo iniciales que no contienen información útil para estudio
segini=3;
%Numero de videos
nvideos =size(datosPerson6,1);
%Numero de canales, cada canal se corresponde con un
%sensor
ncanales =32;
%Numero de segundos que dura cada video 63s*128Hz
nlen =size(datosPerson6,3);
%Numero de trozos en los que vamos a dividir cada video para su posterior
%estudio, calculado eliminando los tres segundos iniciales en los cuales no
%hay información útil y dividiendo en pequeñas señales de 5 segundos de
%duracion
nframe = round ((nlen-segini*fs)/(5*fs));
%Quitamos los 3s iniciales a cada prueba
datosEstudio6=datosPerson6(:,1:32,segini*fs+1:end);
%Obtenemos 12 señales de 5 segundos cada una, para cada uno de los videos,
%en total vamos a tener 480 señales por individuo. El orden de senal_aux
%es: pruebas, canales, tiempo, frames
senal_aux6=reshape(datosEstudio6,nvideos,ncanales,640,[]);
nlen2=size(senal_aux6,3);

%% Calculo de los IMF%%
```

```

%Inicializo la señal IMF, uno para cada individuo, para no tener problemas
%de memoria
numIMF=5;
IMF6=zeros(nvideos,ncanales,nlen2,numIMF,nframe);
%Para cada video, para cada canal, para cada señal, calculo los imf

for i=1:nvideos
    for j=1:ncanales
        for r=1:nframe
            aux6=emd(squeeze(senal_aux6(i,j,:,r)), 'MaxNumIMF',5);
            IMF6(i,j,:,1:(size(aux6,2)),r)=aux6;

        end
    end
end

%% Feature extraction %%
%Una vez que hemos calculado los diferentes IMF, tenemos que calcular las
%características, vamos a utilizar tres, una en el dominio del tiempo, una
%en el dominio de la frecuencia y una en el dominio de la energía

%% First difference of IMT time series %%
%Inicializo la matriz, una para cada individuo
Dt6=zeros(nvideos,ncanales,nframe,numIMF,1);

for i2=1:nvideos
    for j2=1:ncanales
        for r2=1:nframe
            for s=1:5
                for t=1:nlen2-1
                    Dt6(i2,j2,r2,s,1)=Dt6(i2,j2,r2,s,1)+(1/(nlen2-
1)*abs((IMF6(i2,j2,t+1,s,r2))-(IMF6(i2,j2,t,s,r2))));

                end
            end
        end
    end
end

%% First difference of IMF phase %%
% Lo primero que tenemos que hacer en este caso es obtener la transformada
% de Hilbert para poder tener las señales como  $z(n) = x(n)+jy(n)$ 
Dp6=zeros(nvideos,ncanales,nframe,5,1);
thilbert6=zeros(nvideos,ncanales,nframe,5,nlen2);
phase6=zeros(nvideos,ncanales,nframe,5,nlen2);

for i3=1:nvideos
    for j3=1:ncanales
        for r3=1:nframe
            for s2=1:5
                for t2=1:nlen2-1
                    thilbert6(i3,j3,r3,s2,t2)= hilbert(IMF6(i3,j3,t2,s2,r3));
                    phase6(i3,j3,r3,s2,t2)=angle(thilbert6(i3,j3,r3,s2,t2));
                    Dp6(i3,j3,r3,s2,1)=Dp6(i3,j3,r3,s2,1)+(1/(nlen2-
1)*abs((phase6(i3,j3,r3,s2,t2+1))-(phase6(i3,j3,r3,s2,t2))));

                end
            end
        end
    end
end

end
%% Normalized energy of IMF %%

```

```

% Tercera característica a calcular, se calcula a partir de los imf^2, y
% los puntos de la señal original al cuadrado.
numerador6=zeros(nvideos,ncanales,nframe,5,1);
denominador6=zeros(nvideos,ncanales,nframe,1);
energia6=zeros(nvideos,ncanales,nframe,5,1);

for i4=1:nvideos
    for j4=1:ncanales
        for r3=1:nframe
            for s3=1:5
                for t3=1:nlen2-1

numerador6(i4,j4,r3,s3,1)=numerador6(i4,j4,r3,s3,1)+IMF6(i4,j4,t3,s3,r3)^2;

denominador6(i4,j4,r3,1)=denominador6(i4,j4,r3,1)+senal_aux6(i4,j4,t3,r3)^2;

energia6(i4,j4,r3,s3,1)=numerador6(i4,j4,r3,s3,1)/denominador6(i4,j4,r3,1);
                    end
                end
            end
        end
    end
end

%% Unificar características %%
%Una vez que tenemos las tres características, tenemos que unificar estas
%en una matriz, donde cada columna sea una característica
columna1=reshape(Dt6,nvideos*ncanales*nframe*numIMF, []);
columna2=reshape(Dp6,nvideos*ncanales*nframe*numIMF, []);
columna3=reshape(energia6,nvideos*ncanales*nframe*numIMF, []);
%% Verdad de referencia e inserción en características%%
valence=person6.labels(:,1);
arousal=person6.labels(:,2);
tamano=size(arousal,1);
for g=1:tamano
    if (valence(g)>= 5)
        valence(g)=1;
    else
        valence (g)=0;
    end
    if (arousal(g) >=5)
        arousal(g)=1;
    else
        arousal(g)=0;
    end
end
arousalC=repmat(arousal,1920,1);
valenceC=repmat(valence,1920,1);
%Características para valence
caracteristica1V=[columna1,valenceC];
caracteristica2V=[columna2,valenceC];
caracteristica3V=[columna3,valenceC];
%Matriz características para maquina arousal
caracteristica1A=[columna1,arousalC];
caracteristica2A=[columna2,arousalC];
caracteristica3A=[columna3,arousalC];
% 3 características juntas para valence
caracteristicaVTotal=[columna1,columna2,columna3,valenceC];
% 3 características juntas para arousal
caracteristicaATotal=[columna1,columna2,columna3,arousalC];

```

CASO 2: 40 VÍDEOS/PRUEBAS, 8 CANALES, 12 FRAMES, 1 IMF

```
clc
clear all

%% Aplicamos para las 32 señales --> 32 individuos %%
person6=load('s06.mat');
%Como se trata de un elemento struct me quedo solamente con los datos.
datosPerson6 = person6.data;
%Vamos a muestrear con una frecuencia de 128 Hz
fs = 128;
%Segundo iniciales que no contienen grabación información útil para estudio
segini=3;
%Numero de videos que contiene la señal
nvideos =size(datosPerson6,1);
%Analizamos solamente 8 canales, segun estudio esto da mejores resultados,
%teniendo en cuenta distancia de fisher, los mejores canales son:
%FP1(1),FP2(17),F7(4),F8(21),T7(8),T8(26),P7(12),P8(30).
canales=[1,4,8,12,17,21,26,30];
ncanales=8;
%Numero de segundos iniciales que dura cada video de la señal 63s*128Hz
nlen =size(datosPerson6,3);
%Numero de trozos en los que vamos a dividir cada video para su posterior
%estudio, calculado eliminando los tres segundos iniciales en los cuales no
%hay información útil y dividiendo en pequeña señales de 5 segundos de
%duracion
nframe = round ((nlen-segini*fs)/(5*fs));
%Quitamos los 3s iniciales a cada prueba
datosEstudio6=datosPerson6(:,canales,segini*fs+1:end);
%Obtenemos 12 señales de 5 segundos cada una, para cada uno de los videos,
%en total vamos a tener 480 señales por individuo. El orden de senal_aux
%es: pruebas, canales, tiempo, frames
senal_aux6=reshape(datosEstudio6,nvideos,ncanales,640,[]);
nlen2=size(senal_aux6,3);

%% Calculo de los IMF%%
%Inicializo la señal IMF, uno para cada individuo, para no tener problemas
%de memoria
numIMF=1;
IMF6=zeros(nvideos,ncanales,nlen2,numIMF,nframe);
%Para cada video, para cada canal, para cada señal, calculo los IMF

for i=1:nvideos
    for j=1:ncanales
        for r=1:nframe
            aux6=emd(squeeze(senal_aux6(i,j,:,r)), 'MaxNumIMF',1);
            IMF6(i,j,:,1:(size(aux6,2)),r)=aux6;
        end
    end
end

%% Feature extraction %%
%Una vez que hemos calculado los diferentes IMF, tenemos que calcular las
%características, vamos a utilizar tres, una en el dominio del tiempo, una
%en el dominio de la frecuencia y una en el dominio de la energía

%% First difference of IMT time series %%
%Inicializo la matriz, una para cada individuo
Dt6=zeros(nvideos,ncanales,nframe,numIMF,1);

for i2=1:nvideos
```

```

    for j2=1:ncanales
        for r2=1:nframe
            for s=1:numIMF
                for t=1:nlen2-1
                    Dt6(i2,j2,r2,s,1)=Dt6(i2,j2,r2,s,1)+(1/(nlen2-
1)*abs((IMF6(i2,j2,t+1,s,r2))-(IMF6(i2,j2,t,s,r2))));
                end
            end
        end
    end
end

%% First difference of IMF phase %%
% Lo primero que tenemos que hacer en este caso es obtener la transformada
% de Hilbert para poder tener las señales como  $z(n) = x(n)+jy(n)$ 
Dp6=zeros(nvideos,ncanales,nframe,numIMF,1);
thilbert6=zeros(nvideos,ncanales,nframe,numIMF,nlen2);
phase6=zeros(nvideos,ncanales,nframe,numIMF,nlen2);

for i3=1:nvideos
    for j3=1:ncanales
        for r3=1:nframe
            for s2=1:numIMF
                for t2=1:nlen2-1
                    thilbert6(i3,j3,r3,s2,t2)= hilbert(IMF6(i3,j3,t2,s2,r3));
                    phase6(i3,j3,r3,s2,t2)=angle(thilbert6(i3,j3,r3,s2,t2));
                    Dp6(i3,j3,r3,s2,1)=Dp6(i3,j3,r3,s2,1)+(1/(nlen2-
1)*abs((phase6(i3,j3,r3,s2,t2+1))-(phase6(i3,j3,r3,s2,t2))));
                end
            end
        end
    end
end

end
%% Normalized energy of IMF %%
% Tercera característica a calcular, se calcula a partir de los  $imf^2$ , y
% los puntos de la señal original al cuadrado.
numerador6=zeros(nvideos,ncanales,nframe,numIMF,1);
denominador6=zeros(nvideos,ncanales,nframe,1);
energia6=zeros(nvideos,ncanales,nframe,numIMF,1);

for i4=1:nvideos
    for j4=1:ncanales
        for r3=1:nframe
            for s3=1:numIMF
                for t3=1:nlen2-1

numerador6(i4,j4,r3,s3,1)=numerador6(i4,j4,r3,s3,1)+IMF6(i4,j4,t3,s3,r3)^2;

denominador6(i4,j4,r3,1)=denominador6(i4,j4,r3,1)+senal_aux6(i4,j4,t3,r3)^2;

energia6(i4,j4,r3,s3,1)=numerador6(i4,j4,r3,s3,1)/denominador6(i4,j4,r3,1);
                end
            end
        end
    end
end

end
%% Unificar características %%
%Una vez que tenemos las tres características, tenemos que unificar estas
%en una matriz, donde cada columna sea una característica
columnal=reshape(Dt6,nvideos*ncanales*nframe*numIMF, []);

```

```

columna2=reshape(Dp6,nvideos*ncanales*nframe*numIMF, []);
columna3=reshape(energia6,nvideos*ncanales*nframe*numIMF, []);
%% Verdad de referencia e inserción en características%%
valence=person6.labels(:,1);
arousal=person6.labels(:,2);
tamano=size(arousal,1);
for g=1:tamano
    if (valence(g)>= 5)
        valence(g)=1;
    else
        valence (g)=0;
    end
    if (arousal(g) >=5)
        arousal(g)=1;
    else
        arousal(g)=0;
    end
end
arousalC= repmat(arousal,96,1);
valenceC= repmat(valence,96,1);
%Características para valence
caracteristica1V=[columna1,valenceC];
caracteristica2V=[columna2,valenceC];
caracteristica3V=[columna3,valenceC];
%Matriz características para maquina arousal
caracteristica1A=[columna1,arousalC];
caracteristica2A=[columna2,arousalC];
caracteristica3A=[columna3,arousalC];
% 3 características juntas para valence
caracteristicaVTotal=[columna1,columna2,columna3,valenceC];
% 3 características juntas para arousal
caracteristicaATotal=[columna1,columna2,columna3,arousalC];

```

