

**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL
INSTITUTO POLITÉCNICO NACIONAL**

UNIDAD MONTERREY

**ANÁLISIS DE LA CONECTIVIDAD FUNCIONAL EN DATOS
ELECTROENCEFALOGRÁFICOS ASOCIADOS A SENTIMIENTOS**

Tesis que presenta

Juan David Carrillo López

para obtener el grado de Maestro en Ciencias en

Ingeniería y Física Biomédicas

Director de Tesis:

Dr. David Gutiérrez Ruiz

Agradecimientos

A la Dra. Dania Gutiérrez Ruiz, por otorgarme la encomienda para el desarrollo esta investigación. Por su atención y dedicación para guiarme con las diferentes tecnologías y aspectos en el área de investigación interdisciplinaria.

Al Dr. Mauricio Carrillo Tripp y al Dr. Jesús Guadalupe Rodríguez González al formar parte del comité Sinodal. Por su orientación en este trabajo.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por el financiamiento brindado a lo largo del posgrado así como para la finalización del proyecto de tesis. Especialmente al CINVESTAV Unidad Monterrey, por permitirme formar parte de la comunidad para continuar con estudios superiores.

A mis compañeros de generación, especialmente a Victoria Díaz, José Coral y Ramsés Muñoz por el apoyo y la convivencia durante estos dos años.

Finalmente quiero expresar mi sentir para con mi familia por la confianza y el apoyo en esta decisión.

Índice General

1. Introducción	1
1.1. Características de las señales EEG	5
2. Hipótesis	10
3. Objetivos	11
3.1. Objetivo General	11
3.2. Objetivos Particulares	11
4. Metodología	12
4.1. Materiales	12
4.2. Procesamiento de las señales	16
4.2.1. Coherencia parcialmente dirigida	17
4.2.2. Teoría de Grafos	19
4.2.3. Algoritmos de clasificación	21
4.2.4. Bosque de árboles aleatorios	21
4.3. Criterios de desempeño de clasificadores	23
4.3.1. Exactitud	23
4.3.2. Precisión	24
4.3.3. Exhaustividad	24
4.3.4. Valor F	24
4.4. Flujo de trabajo	25
4.4.1. Preprocesamiento de las señales EEG	25
4.4.2. Obtención de la PDC	26
4.4.3. Representación por teoría de grafos	28
4.4.4. Proceso de clasificación	30
5. Resultados	33

6. Conclusiones y trabajo futuro	46
6.1. Discusión	48
A. Apéndice de Figuras	51

Índice de Figuras

1.	Lóbulos del cerebro humano. Imagen tomada de [3]	2
2.	Esquema con la disposición de los electrodos de acuerdo al sistema internacional 10-20	3
3.	Montaje tipo <i>Biosemi, Amsterdam</i> de un voluntario. Resaltando en un círculo los electrodos de interés.	16
4.	Árbol de decisión.	22
5.	Registro EEG segmentado tras los filtros descritos previamente. En el eje vertical se encuentran las denominaciones para cada uno de seis canales del montaje de electrodos. Sobre el eje horizontal se encuentran los registros electroencefalográfico a través del tiempo.	26
6.	Representación visual de valores significativos de la PDC correspondientes al sentimiento de enojo para el sujeto 1.	27
7.	Mapa de calor de los valores estadísticamente significativos de la PDC para el sujeto 1 en el sentimiento de enojo indicando la influencia de un lóbulo cerebral sobre otro en la banda alfa de frecuencia. Siendo 0 una influencia débil y 1 un marcador de una fuerte influencia.	28
8.	En el eje horizontal se aprecian los valores umbral implementados para calcular la densidad de un grafo en cada una de las 5 bandas de frecuencia. En el eje vertical se encuentran los valores p obtenidos de una prueba Kruskal-Wallis. La línea roja salteada representa el nivel de significancia de 0.05.	29
9.	Conectividad funcional cerebral para el sentimiento <i>anger</i> del sujeto 1 representada por medio de un grafo. Un color rojo fuerte muestra una alta influencia como la que se aprecia de LFD a LFI mientras que tonos azules más claros indican una influencia débil como la que va de LPD a LFD.	30

10.	Puntuación <i>Out-Of-Bag</i> conforme aumenta el número de árboles de decisión implementados.	31
11.	Ponderación obtenida para cada una de las características durante la clasificación binaria utilizando todas las bandas de frecuencia.	34
12.	Ponderación obtenida en las variables características durante la clasificación binaria para cada banda de frecuencia	35
13.	Ponderación obtenida en las variables características durante la clasificación binaria para <i>frustración-felicidad</i>	41
14.	Ponderación obtenida en las variables características durante la clasificación binaria para <i>enojo-complacido</i>	42
15.	Ponderación obtenida en las variables características durante la clasificación binaria para <i>enojo-felicidad</i>	43
16.	Ponderación obtenida en las variables características durante la clasificación binaria para <i>tristeza-felicidad</i>	44
17.	Ponderación obtenida en las variables características durante la clasificación binaria para <i>miedo-felicidad</i>	45
18.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de ira para cada una de las bandas de frecuencia.	51
19.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de humildad para cada una de las bandas de frecuencia.	52
20.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de compasión para cada una de las bandas de frecuencia.	53
21.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de complacido para cada una de las bandas de frecuencia.	54

22.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de disgusto para cada una de las bandas de frecuencia.	55
23.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de emoción para cada una de las bandas de frecuencia.	56
24.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de miedo para cada una de las bandas de frecuencia.	57
25.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de frustración para cada una de las bandas de frecuencia.	58
26.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de duelo para cada una de las bandas de frecuencia.	59
27.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de felicidad para cada una de las bandas de frecuencia.	60
28.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de celos para cada una de las bandas de frecuencia.	61
29.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de alegría para cada una de las bandas de frecuencia.	62
30.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de amor para cada una de las bandas de frecuencia.	63

31.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de alivio para cada una de las bandas de frecuencia.	64
32.	Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de tristeza para cada una de las bandas de frecuencia.	65

Índice de Tablas

1.	Listado de sentimientos	14
2.	Ubicación de los electrodos de interés	25
3.	Variables utilizadas durante el proceso de clasificación.	32
4.	Listado de valores F utilizando diez validaciones cruzadas	33
5.	Pares de sentimientos con $F > F_{\max}$ correspondiente la banda delta de frecuencia	36
6.	Pares de sentimientos con $F > F_{\max}$ correspondiente la banda theta de frecuencia	37
7.	Pares de sentimientos con $F > F_{\max}$ correspondiente la banda alfa de frecuencia	38
8.	Pares de sentimientos con $F > F_{\max}$ correspondiente la banda beta de frecuencia	39
9.	Pares de sentimientos con $F > F_{\max}$ correspondiente la banda gamma de frecuencia	40

Abreviaturas

EEG	Electroencefalografía
PDC	Partial directed coherence
MVAR	Multivariate auto-regressive
PSD	Power spectral density
MRI	Magnetic resonance imaging
SNC	Sistema nervioso central
DWT	Discrete wavelet transform
BP	Band of power
SVM	Support vector machine
RF	Random forest

Resumen

En el presente estudio se propone la implementación de la coherencia parcialmente dirigida (PDC) para representar las interacciones de la actividad presente entre los lóbulos cerebrales durante la imaginación de episodios con carga afectiva. Los registros electroencefalográficos están disponibles vía internet y son producto de una sesión donde voluntarios imaginaron posibles escenarios que los llevaran a experimentar una serie concreta de sentimientos positivos y negativos. Se pidió a la persona en cuestión que invirtiera el tiempo necesario para registrar al menos un evento con carga afectiva. Los eventos de imaginación de sentimientos fueron señalados por botón que el voluntario presionaba cada vez que experimentaba algún episodio. Posteriormente fue seleccionado un lapso de las mediciones de EEG para formar un modelo autorregresivo multivariable que sirve para calcular la PDC. Los valores de la PDC pueden ser transformados a un grafo donde los nodos están dados por los electrodos EEG y las interacciones entre cada nodo están definidas por la magnitud de la PDC con su respectiva dirección. Un espacio de características fue construido obteniendo métricas propias de un grafo como la centralidad, la eficiencia, la cantidad de conexiones entrantes y salientes. Después se utilizó un algoritmo de aprendizaje supervisado conocido como árboles de decisión que entre sus puntos particulares resalta la ponderación que otorga a las variables utilizadas durante el proceso de discriminación. Los resultados exponen la diferenciación entre sentimientos positivos de negativos donde la imaginación de experiencias negativas relacionadas con el enojo, la tristeza, la frustración y el miedo predominan en el desempeño del clasificador. Por otro lado las situaciones afectivas positivas fueron menos constantes estando la felicidad en el primer lugar mientras que el amor se ubicó por debajo de sentimientos como el alivio, la emoción y la alegría.

Summary

This thesis proposes to use the partial directed coherence (PDC) as a tool to map brain interactions while subjects have a self-induced emotion. Dataset containing electroencephalography (EEG) signals for every session of positive and negative emotions freely available online is used in this study. Volunteers were asked to recall any possible scenario that would cause an event of emotion. These imagined affective states were marked by a press button every time the subject experienced the event. Because of PDC requires a multivariate autoregressive (MVAR) model a well suited processing window was selected from EEG signal. Next, PDC values were transformed in a graph-schema where nodes represents EEG electrodes and directed edges linking each node are the wighted interactions retrieved from the PDC magnitude. Next, a features space is built considering metrics related to the previously formed graph such as centrality, efficiency, in-going and out-going conections. A supervised learning algorithm known as random forest is used as signal classificator due to its characteristic of rating features. Our results show that negative emotions as anger, sadness, frustration and fear are more likely to be classified over positive emotions. Whereas positive affective states are scarce, love in particular. In addition, love appeared behind emotions like relief, excitement and joy.

1. Introducción

Las emociones juegan un papel fundamental en la toma de decisiones, la percepción, la interacción y la inteligencia. Una emoción es un proceso que involucra tres componentes: la experiencia subjetiva, la respuesta fisiológica y una respuesta expresiva o comportamiento [1]. Los sentimientos pueden ser considerados como representaciones subjetivas de las emociones mientras que el humor se trataría de estados afectivos que generalmente duran más tiempo y son más intensos que las emociones. Además, un sentimiento puede abarcar un conjunto de emociones.

Las personas expresan sus estados de ánimo al utilizar máquinas, incluso si estas no están diseñadas para tal cometido. Situaciones que van desde alguien atravesando una ruptura amorosa a través de las redes sociales hasta algo tan común como una persona frustrada porque la aplicación móvil de su banco está en mantenimiento. Es aquí donde encuentra cabida la computación afectiva, que surge con el propósito de modelar las interacciones emocionales entre el hombre y la máquina a través de la medición del estado emocional del usuario. Entre las varias aplicaciones podemos encontrar: asistencia en la interacción con niños con autismo, mejorando la comunicación referente a sus estados de ánimo; diagnóstico y tratamiento relacionado con la ansiedad, sobre todo en el análisis del trastorno de estrés postraumático; en el área de educación promoviendo la mejora de cursos basados en la respuesta emocional de los estudiantes.

La respuesta a emociones se asocia a diferencias en la actividad cerebral de ambos hemisferios. Diferentes regiones del cerebro presentan mayor actividad como los lóbulos frontal y temporal (Figura 1). El cerebro humano comúnmente es dividido en las porciones o lóbulos siguientes [2]:

- lóbulo frontal responsable del pensamiento consciente,
- lóbulo temporal encargado de las sensaciones del gusto y el sonido,

- lóbulo parietal que integra información sensorial variada así como la manipulación de objetos, y
- lóbulo occipital a cargo del sentido de la vista.

De acuerdo con [1] son dos las áreas relacionadas con actividad emocional:

- la amígdala, localizada en la porción frontal del lóbulo temporal,
- y el córtex pre-frontal, parte del lóbulo frontal.

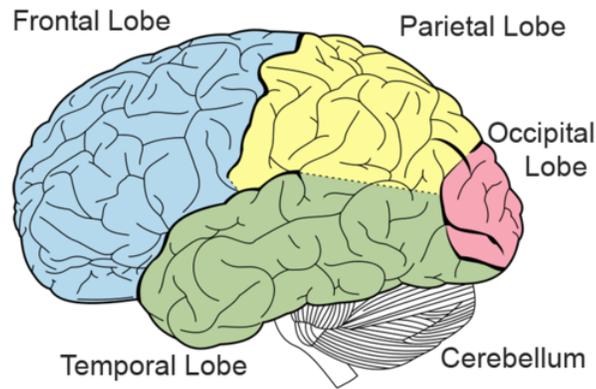


Figura 1: Lóbulos del cerebro humano. Imagen tomada de [3]

La unidad básica del cerebro es la neurona y está compuesta principalmente por: un cuerpo central, denominado soma, una extensión del soma llamado axón que posibilita la comunicación con otras células y una extensión conocida como dendritas por las cuales recibe señales de otras neuronas. El proceso por el cual una señal es transmitida a través de la neurona empieza en el momento en que las dendritas son cargadas positivamente con respecto al soma, provocando una corriente iónica a lo largo de la célula hasta finalizar en el axón. Este fenómeno es conocido como potencial de acción y la suma de múltiples de ellos actuando en una porción pequeña de la corteza cerebral puede ser registrada por medio de sensores (electrodos) colocados en el cuero cabelludo.

Así, la actividad del cerebro puede ser estudiada debido a las fluctuaciones de voltaje resultantes de la corrientes iónicas de las grandes cantidades de neuronas activándose sincrónicamente en una porción pequeña de la corteza y que pueden ser registradas de manera no invasiva. La electroencefalografía (EEG) es un método para medir este tipo de señales fisiológicas y por tal motivo pueden ser de utilidad al momento de evaluar respuestas fisiológicas a estímulos ya que se sirve de varios electrodos dispuestos sobre la cabeza del participante con ayuda de un gorro. También es necesario contar con un amplificador, un convertidor análogo digital y al menos tres electrodos (uno de tierra, uno referencia y el de registro). La cantidad y el arreglo de electrodos depende el esquema utilizado, por ejemplo el sistema internacional 10-20 usualmente emplea 21 sensores denominados no solo por el número sino también por la ubicación en la que se encuentran: Fp para polo frontal, F para la parte frontal, C en la región central, T para la zona temporal, A en los lóbulos de las orejas, P en el área parietal y O para la región occipital (ver Figura 2).

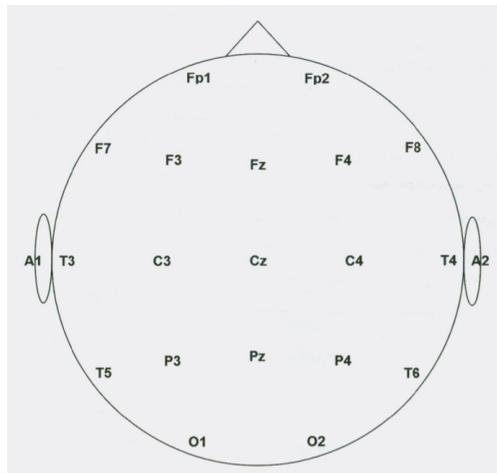


Figura 2: Esquema con la disposición de los electrodos de acuerdo al sistema internacional 10-20

La EEG provee información sobre la actividad cerebral durante lapsos de tiempo en el orden de milisegundos resultando conveniente ya que la propagación del potencial de acción tarda entre 0.5 y 130 milisegundos. Esto permite el estudio de sus cambios en

respuesta a estímulos emocionales. Además, EEG no es invasivo, relativamente rápido de armar para una sesión a un costo menor que otros procesos como la tomografía por emisión de positrones (PET) o imágenes de resonancia magnética funcional (fMRI) y con mejor resolución temporal que estos dos últimos.

La información contenida en las señales EEG se encuentra en el dominio del tiempo y usualmente es acotada a rangos de frecuencia o bandas [1] debido a las peculiares características que se han encontrado:

- las ondas predominantes durante el sueño profundo pueden encontrarse en la banda delta (1 a 3 Hz), también presentes en estados de inconsciencia;
- en actividades como la introspección que involucran la calma y la relajación profundas predomina la banda theta (4 a 7 Hz);
- en la banda alfa (8 a 12 Hz) encontramos aquellas típicamente presentes en los intervalos de descanso debido a procesos de estudio, por ejemplo estudiantes;
- estados de concentración como el estar en una competencia o contestar preguntas en una entrevista se ven reflejados en la banda beta (13 a 30 Hz);
- en la banda gamma (frecuencias mayores a 30 Hz) se localizan varias funciones relacionadas a la percepción, la memoria, la conciencia, el control motor, entre otras.

Podemos encontrar una gran cantidad de estudios concernientes al reconocimiento de emociones, como [1] expone. Estos trabajos abarcan desde el equipo utilizado para registrar las señales EEG, conjuntos de datos de acceso público, la descripción de los voluntarios envueltos en el experimento, estímulos usados para evocar respuestas emocionales, ventanas de tiempo, procesamiento de señales, modelado y caracterización de los estados con carga emocional hasta las últimas generaciones algoritmos de aprendizaje para la correspondiente clasificación.

1.1. Características de las señales EEG

A continuación se describen algunos de los modelos usualmente utilizados para extraer características de registros electroencefalográficos. Primeramente es necesario considerar una señal EEG como una serie de tiempo de la forma siguiente:

$$X(n) = [x_1, x_2, x_3, \dots, x_N], \quad (1)$$

donde n es el valor de la n -ésima muestra y N el número total de muestras. Estudios como [4], [5] y [6] emplean métricas obtenidas por estadística simple:

- la media que es calculada como

$$\mu_X = \frac{1}{N} \sum_{n=1}^N X(n), \quad (2)$$

- y la desviación estándar, obtenida por

$$\sigma_X = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (X(n) - \mu_X)^2}. \quad (3)$$

En [6], [7] y [8] otras métricas estadísticas conocidas como los parámetros HJORTH son implementados:

- la potencia de la señal o actividad (*activity*), dada por

$$A_X = \frac{\sum_{n=1}^N (X(n) - \mu)^2}{N} \quad (4)$$

donde μ es definida en 2;

- la movilidad (*mobility*) que indica una proporción de desviación estándar del espectro de potencia,

$$M_X = \sqrt{\frac{\text{var}(\dot{X}(n))}{\text{var}(X(n))}}, \quad (5)$$

donde $\text{var}(X(n)) = \sigma_X^2$ y $\text{var}(\dot{X}(n))$ la varianza pero de la primera derivada de la señal;

- la complejidad (*complexity*) calculada como

$$C_X = \frac{M(\dot{X}(n))}{M(X(n))}, \quad (6)$$

donde $M(\dot{X}(n))$ es la movilidad de la primera derivada de la señal y $M(X(n))$ está dada en 5.

Múltiples estudios de EEG también consideran a la densidad de potencia espectral (*power spectral density* o PSD), como por ejemplo en [9] y [10], la cual describe el nivel de dispersión de la potencia de la señal sirviéndose de la transformada de Fourier discreta para representar datos en el dominio del tiempo a datos en el dominio de la frecuencia, de modo que el registro EEG queda expresado como

$$X(e^{j\omega}) = \sum_{n=1}^N X(n)e^{-j\omega n}, \quad (7)$$

donde $\omega = \frac{2\pi}{N}$. Por tanto la PSD es calculada de la forma

$$\hat{S}_{NX}(\omega) = \frac{1}{N}|X(e^{j\omega})|^2, \quad (8)$$

donde $\hat{S}_{NX}(\omega)$ representa la contribución de cada componente de frecuencia respecto a la distribución total de la señal.

La transformada wavelet discreta (*discrete wavelet transform* o DWT), es utilizada en [11] por su característico análisis en el dominio de la frecuencia y del tiempo. Funciona también como un banco de filtros ya que descompone la señal repetidamente utilizando

$$\varphi_{j,k}(n) = 2^{j/2}h(2^j n - k) \quad \text{y} \quad (9)$$

$$\psi_{j,k}(n) = 2^{j/2}g(2^j n - k), \quad (10)$$

donde $n = 0, 1, 2, \dots, N - 1$, $j = 0, 1, 2, \dots, J - 1$, $k = 0, 1, 2, \dots, 2^j - 1$ y $J = \log 2(N)$.

Al representar la serie de tiempo en términos de (9) obtenemos que

$$A_i = \frac{1}{\sqrt{N}} \sum_n X(n) \cdot \varphi_{j,k}(n), \quad (11)$$

donde i se refiere a la i -ésima repetición, de donde se obtienen los coeficientes de aproximación (AC). Mientras que los coeficientes de detalle (DC) son calculados con (10) de la forma

$$D_i = \frac{1}{\sqrt{N}} \sum_n X(n) \cdot \psi_{j,k}(n). \quad (12)$$

En la revisión de métodos de análisis de señales de EEG también encontramos en [12] a los patrones espaciales comunes (*common spatial patterns* o CSP) cuyo cometido es maximizar la varianza de una señal mientras minimiza la varianza de otra señal. Tomando como ejemplo un par de actividades cerebrales (clases) particulares \mathbf{x}_1 y \mathbf{x}_2 , en registros EEG, primero son obtenidas un par de matrices de covarianza

$$R_1 = \frac{X_1 X_1^T}{\text{traza}(X_1 X_1^T)} \text{ y} \quad (13)$$

$$R_2 = \frac{X_2 X_2^T}{\text{traza}(X_2 X_2^T)}, \quad (14)$$

donde $\text{traza}(X_{(\cdot)} X_{(\cdot)}^T)$ es la suma de los elementos de la diagonal principal de la matriz para cada una de las clases, y el superíndice T se trata un operador para la traspuesta del vector. Las matrices pueden reformularse como

$$R = R_1 + R_2 = U_0 \Sigma U_0^T, \quad (15)$$

donde Σ es la diagonal de la matriz que contiene los eigenvalores, y en U_0 , los correspondientes a eigenvectores. Luego es formada una matriz identidad con estos valores de covarianza de la forma

$$P = \Sigma^{\frac{1}{2}} U_0^T. \quad (16)$$

Por lo que ahora puede aplicarse a las matrices obtenidas en (13) y (14) como

$$Y_1 = P R_1 P^T = U \Sigma_1 U^T \text{ y} \quad (17)$$

$$Y_2 = P R_2 P^T = U \Sigma_2 U^T. \quad (18)$$

Luego se definen matrices U_1 y U_2 para cada uno de los filtros

$$F_1 = U_1^T P \text{ y} \quad (19)$$

$$F_2 = U_2^T P, \quad (20)$$

que consecuentemente pueden ser implementados en las señales tal que

$$S_1 = F_1 X \text{ y} \quad (21)$$

$$S_2 = F_2 X, \quad (22)$$

donde S_1 es la señal X filtrada para maximizar actividad cerebral concerniente a la clase 1.

Es necesario recordar que el cerebro opera como un sistema cuyas variables fisiológicas cambian con el tiempo. Además de la sincronización que sucede a través de los sistemas neuronales, grandes grupos de neuronas procesan y transmiten información entre sus distintas regiones. Entonces, se entiende por conectividad cerebral a la comunicación entre estos conglomerados neuronales y como tal pone empeño en encontrar estas conexiones directas o indirectas [13]. La asociación de estas conexiones con alguna actividad en particular está modelada por conectividad cerebral funcional.

En varios estudios como [14], [15] y [16] la conectividad cerebral es abordada por medio de la coherencia, una medida en el dominio de la frecuencia y que se define como

$$\text{Coh}(f) = \frac{|S_{AB}(f)|^2}{(S_{AA}(f)S_{BB}(f))}, \quad (23)$$

donde $|S_{AB}(f)|^2$ representa a la densidad crospectral entre una par de señales A y B , S_{AA} es la autocorrelación de la señal A , y S_{BB} es la autocorrelación de la señal B . Valores altos implican un alto grado de comunicación entre dos registros EEG mientras que cierto grado de independencia está indicado por valores cercanos a cero. Es necesario

aclarar que si bien puede resultar útil al mostrar la correlación del espectro entre dos lóbulos cerebrales $\text{Coh}(f)$ obtendrá el mismo valor de A a B y de B a A .

Revisiones muestran un incremento en la cantidad de publicaciones enfocadas a la detección de estados afectivos por medio de las interfaces cerebro computadora [17] [18]. La mayoría de los procesos de clasificación consideran un listado reducido de sentimientos además de enfocarse principalmente en los registros EEG de manera individual y no como un conjunto. Un análisis de la conectividad cerebral funcional permitiría representar los distintos procesos que se llevan a cabo en la actividad y las interacciones a través de las distintas zonas del cerebro como respuesta a situaciones donde se experimenta una variedad de sentimientos. Por tal motivo en esta investigación se propone analizar ocho sentimientos positivos y siete sentimientos negativos a través de la conectividad cerebral funcional, con ayuda de un algoritmo de clasificación para identificar patrones característicos entre varios participantes.

Es por eso, que la tesis está estructurada de la forma siguiente: para empezar en el Capítulo 1 se encuentra la introducción donde se aborda el análisis de sentimientos a través de EEG, se mencionan trabajos relacionados y la justificación del presente trabajo de investigación, el Capítulo 2 enuncia la hipótesis seguido del Capítulo 3 presentando el objetivo general y los objetivos particulares, el Capítulo 4 detalla los procedimientos necesarios para crear el compendio de información con registros EEG para su posterior tratamiento y transformación en características que resultarán fundamentales en el flujo de clasificación, en el Capítulo 5 se describe los resultados correspondientes a diferentes combinaciones de sentimientos y por último, en el Capítulo 6 presenta las conclusiones y consideraciones de los resultados previos al mismo tiempo que se plantean puntos para continuar el trabajo a futuro.

2. Hipótesis

Existen patrones de conectividad cerebral funcional en común entre sujetos que experimentan distintas variedades de sentimientos, y la evaluación de dichos patrones a través de la coherencia parcialmente dirigida en mediciones electroencefalográficas permitirá su clasificación.

3. Objetivos

3.1. Objetivo General

Desarrollar un sistema basado en la coherencia parcialmente dirigida para la clasificación de datos electroencefalográficos (EEG) asociados a distintos sentimientos.

3.2. Objetivos Particulares

- Analizar la conectividad funcional de datos reales de EEG asociados a distintos sentimientos.
- Identificar las peculiaridades que conlleva el procesamiento de emociones positivas y negativas.
- Implementar un clasificador basado en características de conectividad funcional para la discriminación de distintos sentimientos.

4. Metodología

En este capítulo se describe una serie de procedimientos para identificar patrones en señales EEG mediante la imaginación de varios estados con carga sentimental. Primeramente se aborda el origen y características de los registros EEG así como también algunas técnicas concernientes a su estudio. Posteriormente se detallan los procedimientos seleccionados para caracterizar la actividad cerebral junto a la implementación de un algoritmo de clasificación para identificar los patrones generales. Finalmente se enumera un flujo de trabajo sintetizando todos los puntos anteriores.

4.1. Materiales

El conjunto de datos a utilizar para el análisis fue elaborado por [19] y se encuentra disponible de forma pública en <https://headit.ucsd.edu/studies/a2182780-945b-11e8-a7b8-00a0d1e831b8>. Está conformado por un total de 32 adultos que participaron como voluntarios en este experimento. Todas y todos afirmaron poder recordar situaciones que evocaran sentimientos, sin previo ejercicio requerido como lo sería la meditación. Para llevar a cabo las sesiones los voluntarios fueron colocados en un cuarto con luz tenue, tomando lugar en una silla con los ojos cerrados. La imaginación de sentimientos fue guiada mediante un par de audífonos donde podían escuchar instrucciones previamente grabadas. Cada sesión iniciaba y finalizaba con dos minutos de reposo en silencio con ambos ojos cerrados.

A continuación se podrá encontrar un descripción de los sentimientos analizados, junto a una palabra equivalente en el idioma español (la Tabla 1 resume el listado):

- *Love* (amor) se refiere al sentimiento que surge al querer a otro individuo. Puede tratarse de atracción romántica y sexual o en un sentido de cariño y apego.
- *Joy* (alegría) es una enorme sensación de felicidad.

- *Happy* (felicidad) un sentimiento de placer o satisfacción.
- *Relief* (alivio) la sensación de que algo no placentero ha pasado o no ocurrió.
- *Compassion* (compasión) un fuerte sentimiento de empatía, al querer ayudar a otros, y tristeza, debido al sufrimiento o mala situación en la que se encuentran.
- *Content* (complacido) estar satisfecho y feliz ante una situación particular.
- *Excite* (emoción) un fuerte estado de agitación debido a la felicidad y al entusiasmo.
- *Awe* (humildad) este sentimiento está relacionado con el respeto y va de la mano con el miedo o la sorpresa.
- *Anger* (enojo) poderosa sensación presente, como para querer lastimar a alguien, al estar ante algo injusto.
- *Jealousy* (celos) parte de la sensación de posesión tanto de personas como de objetos.
- *Disgust* (disgusto) se refiere a la desaprobación o la aversión hacia objetos, personas o acciones.
- *Frustration* (frustración) sentimiento de molestia debido al fracaso lo que origina duda en sí mismo.
- *Fear* (miedo) es el terror, pavor o sentido de alarma sea por algo peligroso o bien algo que podría pasar.
- *Sad* (tristeza) comúnmente relacionado a algo que ha pasado y ocasiona una sensación de pesar.
- *Grief* (duelo) se trata de profunda tristeza y aflicción, usualmente por la pérdida de un ser querido.

El propósito de las grabaciones era inducir un estado de concentración y proporcionar escenarios hipotéticos que ayudaran al voluntario a evocar situaciones concernientes al sentimiento en cuestión. Se indicó a los sujetos que tomaran el tiempo necesario para recordar o llevar a cabo la imaginación correspondiente.

Tabla 1: Listado de sentimientos

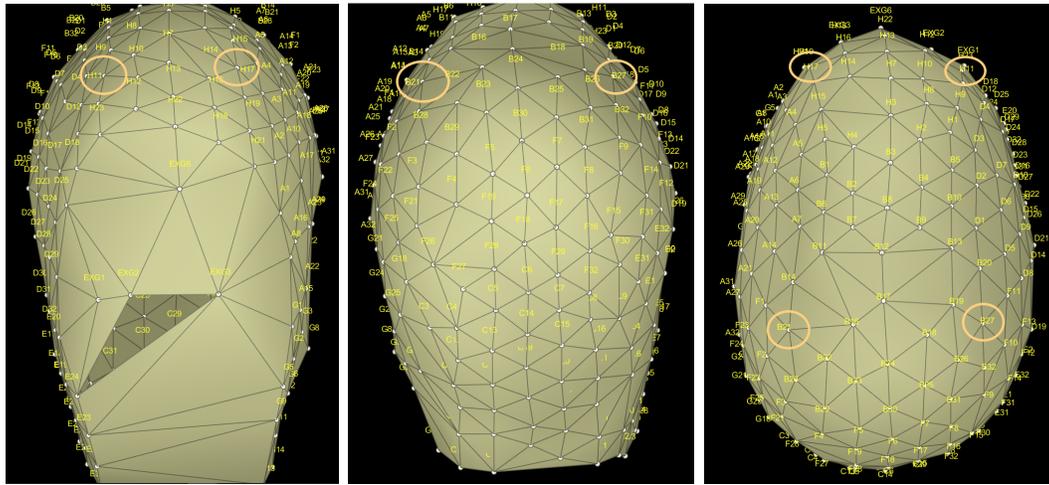
Love	Joy	Happiness	Relief	Compassion
Contentedness	Excitement	Awe	Anger	Jealousy
Disgust	Frustration	Fear	Sadness	Grief

La sesión empezaba con una explicación del proceso seguido de cinco minutos en los cuales se procedía a un estado de relajación y concentración. Posteriormente una serie de 15 narraciones indicaba el sentimiento en cuestión que debía ser imaginado. No fueron delimitados los tipos o características de recuerdos. Además se pidió a los voluntarios que prestaran atención a sensaciones somáticas durante la imaginación del sentimiento.

La secuencia de cada uno de los sentimientos fue alternada entre aquellas con valencia positiva (*love, happiness, compassion*) y aquellas con valencia negativa (*anger, frustration, fear*) con el fin de evitar que la intensidad de un grupo de sentimientos (particularmente los negativos) resultara extenuante para el voluntario. Cada lapso para imaginar el sentimiento en cuestión llevó entre tres y cinco minutos, ya que no se proporcionó estímulo externo a los usuarios con el fin de indicar un tiempo explícito de parada para la imaginación del sentimiento. Sólo debían presionar un botón con su mano derecha toda vez que comenzaran a experimentar el sentimiento. Entre tres y cinco minutos llevó a los sujetos imaginar cada uno de los sentimientos. La indicación de estar imaginando fue marcada por medio de un botón al presionarlo. Debido a la habilidad y experiencias subjetivas dependientes del sujeto cada período de imaginación

del sentimiento tomaba entre 43 segundos y 12 minutos. La duración de las sesiones fue de alrededor de 80 minutos.

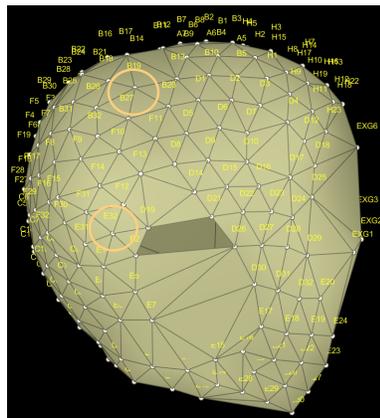
La cantidad máxima de electrodos utilizados es de 256, de los cuales cuatro eran infra-oculares y dos para electrocardiografía. El arreglo de electrodos es de tipo *Biosemi, Amsterdam* de 24-bits A/D de resolución a una frecuencia de muestro de 256 Hz. El gorro con este tipo de montaje cubría la frente, partes laterales de la cara excluyendo las mejillas y barbilla. La mayor parte del cráneo también se encontraba cubierta por el arreglo (Figura 3). Las hendiduras del gorro, donde se disponen los electrodos, contenían un gel conductor basado en agua.



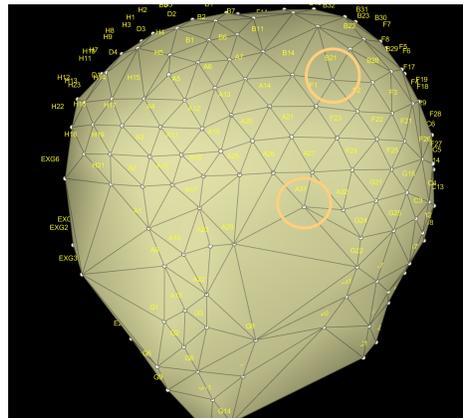
(a) Frontal

(b) Posterior

(c) Superior



(d) Lateral derecha



(e) Lateral izquierda

Figura 3: Montaje tipo *Biosemi, Amsterdam* de un voluntario. Resaltando en un círculo los electrodos de interés.

4.2. Procesamiento de las señales

En las siguientes subsecciones se describen los elementos que conforman el sistema de procesamiento propuesto en esta tesis.

4.2.1. Coherencia parcialmente dirigida

También conocida como *partial directed coherence* (PDC), se trata una métrica obtenida de las características espectrales que indica la relación entre un par de señales, en un conjunto de datos correspondientes a registros EEG. La relación para cada par de canales puede ser representada vía un modelo autorregresivo multivariable (MVAR). Así el muestreo de canal resulta ser la combinación lineal tanto valores pasados del propio canal como de los valores pasados de otros registros. Un modelo MVAR puede ser representado con el sistema de ecuaciones siguiente:

$$\begin{bmatrix} x_1(n) \\ \vdots \\ x_M(n) \end{bmatrix} = \sum_{r=1}^P \mathbf{A}_r \begin{bmatrix} x_1(n-r) \\ \vdots \\ x_M(n-r) \end{bmatrix} + \begin{bmatrix} e_1(n) \\ \vdots \\ e_M(n) \end{bmatrix}, \quad (24)$$

donde $x_m(n)$, para $m = 1, 2, \dots, M$ canales (sensores), $n = 1, 2, \dots, N$ muestras en el tiempo, P con $r = 1, 2, \dots, P$ como el orden del modelo MVAR, \mathbf{A}_r es una matriz con dimensiones $M \times M$ cuyo contenido son los coeficientes autorregresivos del modelo con los componentes $a_{ij}(r)$ que representan la interacción lineal de $x_j(n-r)$ sobre $x_j(n)$, mientras que $e_m(n)$ es el ruido relacionado a un canal m . Así, la función para obtener las características en el dominio de la frecuencia queda como

$$\bar{\mathbf{A}}(f) = \mathbf{I} - \sum_{r=1}^P \mathbf{A}_r e^{-2\pi i f r}, \quad (25)$$

donde matriz de identidad está definida en \mathbf{I} . Además, cada uno de los elementos contenidos en $\bar{\mathbf{A}}(f)$ están dados por

$$\bar{A}_{i,j} = \begin{cases} 1 - \sum_{r=1}^P a_{ij}(r) e^{-2\pi i f r} & i = j \\ - \sum_{r=1}^P a_{ij}(r) e^{-2\pi i f r} & i \neq j \end{cases}. \quad (26)$$

La PDC proporciona la magnitud y la dirección de las relaciones causales de x_j a x_i como

$$\pi_{i \leftarrow j}(f) = \frac{\bar{A}_{ij}(f)}{\sqrt{\bar{a}_j(f)\bar{a}_j^T(f)}}, \quad (27)$$

donde $\bar{A}_{ij}(f)$ y en $\bar{a}_j(f)$ son, respectivamente, el i -ésimo elemento y la j -ésima columna de $\bar{\mathbf{A}}(f)$. Debido a la definición como cociente se pueden encontrar las características de normalización, válidas para todo $1 \leq j \leq M$, de la forma siguiente:

$$0 \leq |\pi_{i \leftarrow j}|^2 \leq 1 \text{ y} \quad (28)$$

$$\sum_{i=1}^M |\pi_{i \leftarrow j}|^2 = 1. \quad (29)$$

Con el objeto de asegurar la conectividad entre los diferentes lóbulos cerebrales es necesario llevar a cabo una prueba estadística de significancia. La PDC se considera indicativa de conectividad funcional cuando su valor es significativo y la prueba estadística para verificarlo es la siguiente:

$$\pi_{i \leftarrow j}(w)_\alpha = \sqrt{\frac{C_{ij}(w)\chi_{1,1-\alpha}^2}{N\sum_k |A_{kj}(w)|^2}}, \quad (30)$$

donde $\alpha = 0.05$ representa el nivel de significancia considerando el 95 % de certidumbre,

$$C_{ij}(w) = \Delta_{ii} \left(\sum_{r=1}^P \sum_{m=1}^P F_{jj}(r, m) [\cos(rw) \cos(mw) + \sin(rw) \sin(mw)] \right), \quad (31)$$

siendo Δ_{ii} es el i -ésimo elemento en la diagonal de una matriz de covarianza y $F_{jj}(r, m)$ es el j -ésimo elemento en la diagonal de la inversa de dicha matriz, $\chi_{1,1-\alpha}^2$ es el percentil 95 de una distribución χ^2 con un grado de libertad, y A_{kj} es el i -ésimo y j -ésimo elemento de la matriz A_r en 24 para una frecuencia w .

4.2.2. Teoría de Grafos

La información que proporciona la PDC puede ser interpretada como un grafo donde los electrodos representan los nodos, y los enlaces y peso de las mismas están dados por la influencia que la i -ésima fila ejerce sobre la j -ésima columna. Esto lleva al modelo de un grafo dirigido con pesos en las uniones.

Un grafo puede ser definido como un conjunto de vértices o nodos con enlaces entre ellos denominados uniones o aristas. Un grafo simple estaría dado por la unión entre dos nodos mediante una arista. Además, puede indicarse la dirección del enlace con flechas y haber múltiples uniones entre el mismo par de nodos. Puede denotarse un grafo G de manera que el conjunto de nodos V y un conjunto de enlaces $E \subseteq V \times V$. Donde cada enlace está dado por un par de nodos (u, v) y $u, v \in V$. Entre las características que podemos encontrar de un grafo encontramos a la cantidad de enlaces que entran a un nodo $v \in V$, conocida como *in degree*:

$$ID(v) = \{(u, v) | (u, v) \in E\} \quad (32)$$

Por otro lado, *out degree* se refiere a la cantidad de conexiones que salen a un nodo $v \in V$, y está definido como

$$OD(x) = \{(x, y) | (x, y) \in E\} \quad (33)$$

Si consideramos un camino como una secuencia de pasos que atraviesan nodos y enlaces, la distancia que habrá sido recorrida está dada por la suma de los pesos correspondientes a sus enlaces. El conjunto de conexiones entrantes-salientes que comunica a un nodo con sus vecinos se le conoce como *betweenness centrality* y está dada por

$$C_B(v) = \sum_{i \neq v \neq j \in V} \frac{d_{ij}(v)}{d_{ij}}, \quad (34)$$

donde d_{ij} es el número de caminos más cortos empezando desde $i \in V$ hasta finalizar en $j \in V$. Por tanto $d_{ij}(v)$ se refiere a la cantidad de caminos más cortos para un nodo $v \in V$.

Si un grafo G es considerado como un sistema de comunicación entre los distintos nodos la capacidad para transmitir información a través del grafo (*global efficiency*) está definida como

$$E(G) = \frac{1}{N(N-1)} \sum_{i \neq j \in G} \frac{1}{d_{ij}}, \quad (35)$$

donde N es la cantidad de nodos y d_{ij} es el camino más corto que comunica al nodo i con j .

La densidad de un grafo (*density*) es una medida de cuántas conexiones existen entre los nodos a comparación del número de enlaces que hubiera disponibles y, para un grafo dirigido, es obtenida por

$$d(G)^d = \frac{m}{n(n-1)}, \quad (36)$$

donde m es el número total de enlaces y n la cantidad de nodos del grafo.

4.2.3. Algoritmos de clasificación

También denominados clasificadores, son un grupo de algoritmos que realizan conjeturas partiendo de una función matemática que generaliza observaciones de un conjunto de datos con instancias previamente conocidas. De esta manera puede predecir instancias nuevas recibiendo datos ajenos al grupo sobre el cual fue entrenado.

Un conjunto de datos puede definirse de la manera $C = \{c_{1,m}, c_{2,m}, c_{3,m}, \dots, c_{n,m}\}$ donde n representa la cantidad total de instancias y m el número de características que definen al espacio de características, siendo un vector de características $\mathbf{c}_{1,m} = \{c_{1,1}, c_{1,2}, c_{1,3}, \dots, c_{1,m}\}$. Comúnmente los datos son divididos en un conjunto de entrenamiento que contiene la información para entrenar al clasificador y un conjunto de prueba donde se encuentran vectores de características ajenos a la fase de entrenamiento. Este último es utilizado para evaluar el desempeño del proceso de discriminación.

4.2.4. Bosque de árboles aleatorios

Por su nombre en inglés *random forest* (RF), está conformado por varios árboles de decisión que obtienen de forma aleatoria partes del conjunto de entrenamiento y posteriormente la clasificación singular de cada uno es combinada. Un árbol de decisión es un clasificador basado en reglas deducidas del espacio de características. Cada nodo expresa el análisis de un atributo (Figura 4) y cada rama representa la solución y las clases estarían dadas por los nodos.

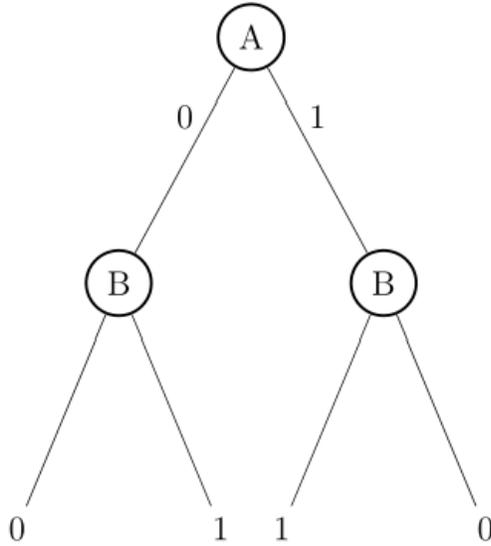


Figura 4: Árbol de decisión.

El criterio de clasificación usualmente usado por RF es llamado impureza de Gini (*Gini impurity*) y está basado en la probabilidad de que la muestra sea clasificada erróneamente de manera aleatoria. El valor de la impureza incrementaría si las muestras que está discriminando pertenecen a muchas categorías. La función de decisión está expresada como:

$$I_{\text{Gini}} = \sum_{i=1}^k p(i)(1 - p(i)), \quad (37)$$

donde k es cada una de las clases usadas para en el proceso de clasificación y $p(i)$ es la probabilidad de seleccionar una muestra que pertenece a la clase i .

Una particularidad de este clasificador es que las variables utilizadas en RF tienen una ponderación proporcional a la reducción de la impureza que esa variable aporta en la tarea de discriminación. Para una variable en particular es obtenido como

$$\text{IMP}_{\text{Gini}} = \sum_{N_c} \sum_j \Delta I(j, N_c), \quad (38)$$

donde $\Delta I(j, N_c)$ es el valor mínimo de impureza en todos los nodos j a través de todos los árboles de decisión N_c .

4.3. Criterios de desempeño de clasificadores

A continuación son descritos los criterios para evaluación el desempeño de los algoritmos de clasificación. Para ello será necesario definir los siguiente:

- TP, como las instancias clasificadas correctamente como positivas;
- FP, a aquellas clasificadas erróneamente como positivas;
- FN a las muestras etiquetadas erróneamente como negativas;
- TN como aquellas clasificadas correctamente como negativas.

4.3.1. Exactitud

La exactitud (*accuracy*) representa el porcentaje de todas las instancias clasificadas correctamente de todas las clases [20]:

$$\text{ACC} = \frac{1}{N} \sum_{i=0}^{N-1} \begin{cases} 1 & \hat{y}_i = y_i \\ 0 & \hat{y}_i \neq y_i \end{cases}, \quad (39)$$

donde N es la cantidad total de muestras, y \hat{y}_i la salida predecida.

4.3.2. Precisión

También conocida como *sensitivity* se refiere a la porción de muestras clasificadas correctamente como positivas:

$$P = \frac{TP}{TP + FP}. \quad (40)$$

4.3.3. Exhaustividad

Usualmente se hace referencia a ella como *specificity* o *recall*. Es el cociente de las observaciones catalogadas correctamente como positivas y de todas las muestras positivas:

$$R = \frac{TP}{TP + FN}. \quad (41)$$

4.3.4. Valor F

Representa la media armónica entre la precisión y la exhaustividad:

$$FS = \frac{2PR}{P + R}. \quad (42)$$

donde P es obtenida en (40) y R es calculada en (41).

4.4. Flujo de trabajo

A continuación se enumera la integración de cada uno de los puntos explicados previamente por el cual se obtienen los resultados para su posterior análisis.

4.4.1. Preprocesamiento de las señales EEG

Un conjunto de electrodos (resaltados en la Figura 3) fue seleccionado tomando en cuenta que su posición correspondiera a un hemisferio y lóbulo cerebral en particular. Esto debido a que el cálculo de valores de la PDC en los 256 electrodos totales resulta en un tiempo computacional extenso y el enfoque de este estudio es la conectividad funcional asociada a un sentimiento en particular. Es importante agregar que no la disponibilidad de los electrodos no es la misma entre todos los individuos ya que los registros obtenidos fueron inspeccionados por el equipo que llevó a cabo el protocolo de experimentación lo que llevó a descartar algunos electrodos y en consecuencia la Tabla 2 refleja aquellos registros EEG que fueron recurrentes entre las sesiones de los voluntarios.

Tabla 2: Ubicación de los electrodos de interés

Lóbulo	Hemisferio	Electrodo	Nomenclatura
Frontal	Izquierdo	H17	LFI
Frontal	Derecho	H11	LFD
Parietal	Izquierdo	B21	LPI
Parietal	Derecho	B27	LPD
Temporal	Izquierdo	A31	LTI
Temporal	Derecho	E32	LTD

El sistema eléctrico utilizado en Norteamérica presenta una característica en el espectro de la señales al identificar un pico en los 60Hz. Es por esto que se aplicó un filtro Notch para atenuar específicamente esta frecuencia. También se implementó un

filtro Butterworth en el rango de frecuencias que va de 0.5 a 100 Hz ya que es en este segmento donde se encuentra la actividad cerebral de interés.

Las señales fueron delimitadas de acuerdo a las sesiones en las cuales se imagina cada uno de las quince situaciones con carga afectiva. Considerando el evento de botón presionado fueron obtenidos intervalos de 2.5 segundos resultando en un total de 1,118 segmentos (en la Figura 5 puede apreciarse un ejemplo). La librería MNE Tools de Python fue implementada con la finalidad de llevar a cabo este tipo de operaciones en señales EEG.

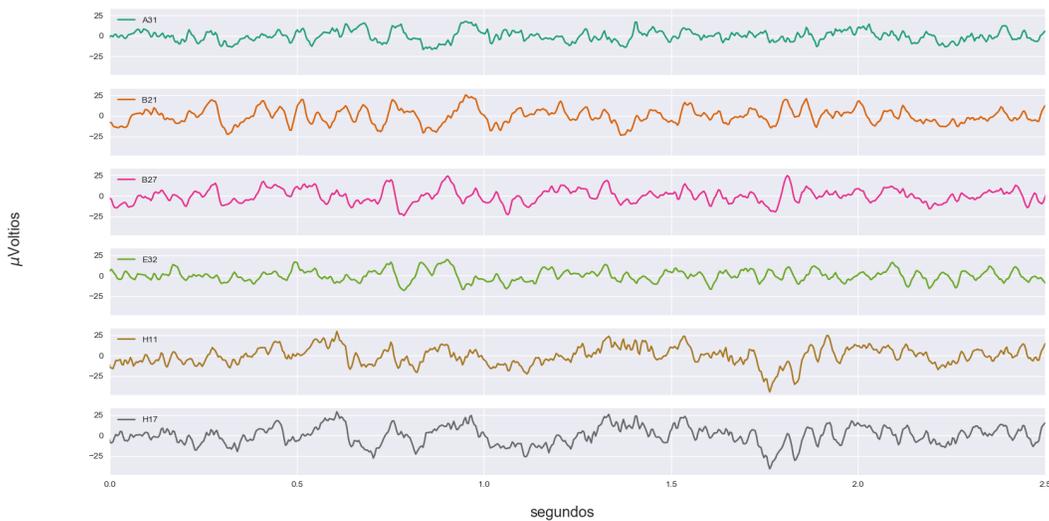


Figura 5: Registro EEG segmentado tras los filtros descritos previamente. En el eje vertical se encuentran las denominaciones para cada uno de seis canales del montaje de electrodos. Sobre el eje horizontal se encuentran los registros electroencefalográfico a través del tiempo.

4.4.2. Obtención de la PDC

En MATLAB puede encontrarse la herramienta ARFIT que permite llevar a cabo la estimación de modelo MVAR de orden 15 mientras que para obtener la coherencia

parcialmente dirigida de fue utilizada el paquete ASYMP-PDC que además permite determinar los valores significativos de la PDC. La PDC puede ser segmentada por bandas de frecuencia ya que cuenta con información del espectro de la señales (ver Figura 6).

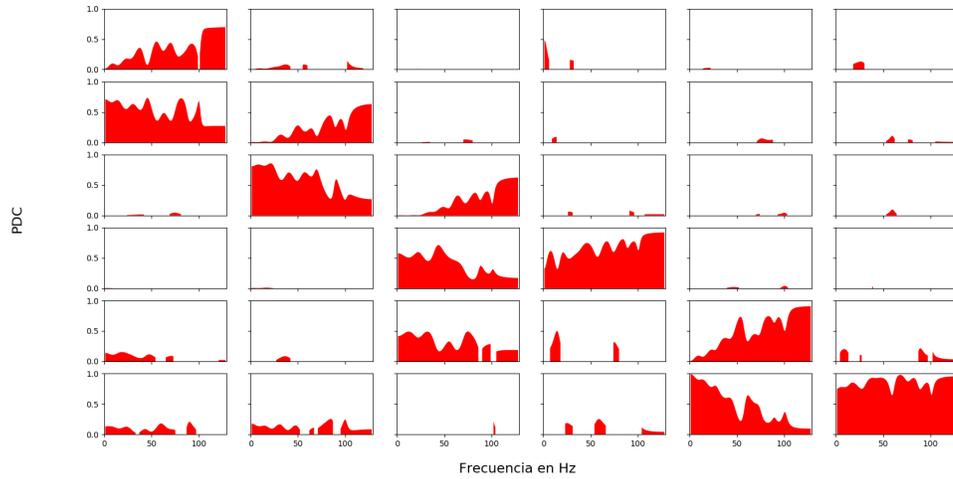


Figura 6: Representación visual de valores significativos de la PDC correspondientes al sentimiento de enojo para el sujeto 1.

La coherencia parcialmente dirigida puede representarse a través de un mapa de calor ya que su particular disposición resume las conectividades funcionales (ver Figura 7).

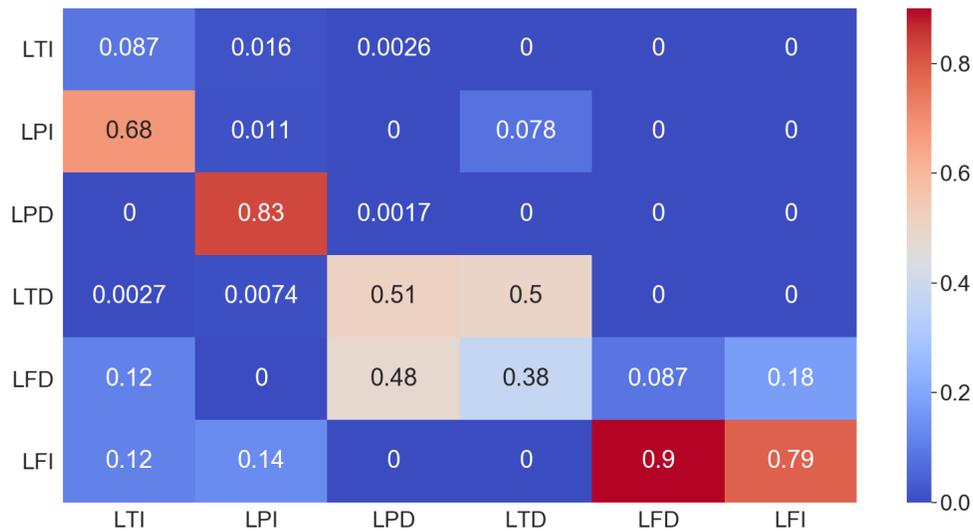


Figura 7: Mapa de calor de los valores estadísticamente significativos de la PDC para el sujeto 1 en el sentimiento de enojo indicando la influencia de un lóbulo cerebral sobre otro en la banda alfa de frecuencia. Siendo 0 una influencia débil y 1 un marcador de una fuerte influencia.

4.4.3. Representación por teoría de grafos

Una prueba estadística de Kruskal-Wallis sirvió para comparar diferentes los valores de la PDC de acuerdo a las bandas frecuencias definidas previamente. Con el fin de llevar a cabo la transformación a un grafo utilizando la mayor cantidad disponible de conexiones funcionales de gran influencia un umbral de 0.25 fue establecido (ver Figura 8).

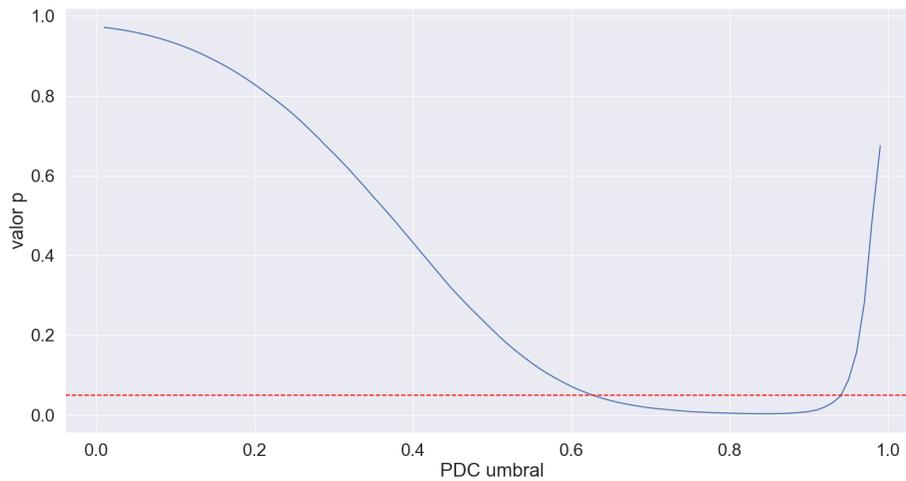


Figura 8: En el eje horizontal se aprecian los valores umbral implementados para calcular la densidad de un grafo en cada una de las 5 bandas de frecuencia. En el eje vertical se encuentran los valores p obtenidos de una prueba Kruskal-Wallis. La línea roja salteada representa el nivel de significancia de 0.05.

El umbral servirá para descartar los valores menores a este utilizando el mapa de calor previamente descrito que consecuentemente llevan a un grafo como tal (Figura 9). En el apéndice A se pueden encontrar las conectividades funcionales de todos los sujetos para cada sentimiento en las distintas bandas de frecuencia. Python también tiene disponible una librería dedicada a la manipulación y análisis de grafos conocida como NetworkX donde entre las características interés para este estudio son: *density*, *in degree*, *out degree*, *betweenness centrality* y *global efficiency*.

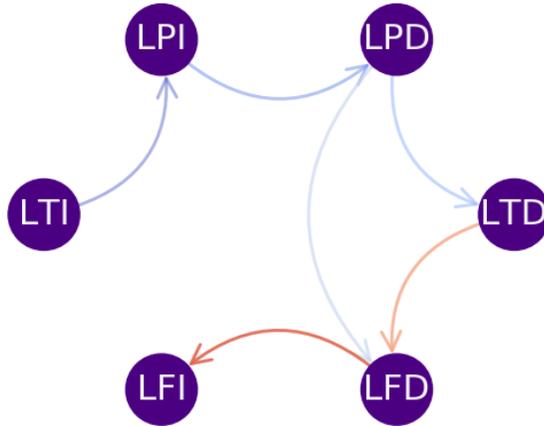


Figura 9: Conectividad funcional cerebral para el sentimiento *anger* del sujeto 1 representada por medio de un grafo. Un color rojo fuerte muestra una alta influencia como la que se aprecia de LFD a LFI mientras que tonos azules más claros indican una influencia débil como la que va de LPD a LFD.

4.4.4. Proceso de clasificación

Otro de los aspectos importantes es la implementación de un clasificador RF para discriminar sentimientos positivos de aquellos negativos, primeramente con miras a encontrar la mayor puntuación tomando en cuenta el valor F. La cantidad de árboles de decisión a implementar fue de 500 de ellos y este número fue determinado mediante la puntuación *Out-Of-Bag* (ver Figura 10). Recordando que este algoritmo construye cada árbol con una parte, formada aleatoriamente, del conjunto total de entrenamiento por lo que habrá datos que no serán proporcionados al árbol de decisión denominados muestras *Out-Of-Bag*, de donde parte la puntuación previamente mencionada representando la cantidad de estas instancias particulares clasificados correctamente.

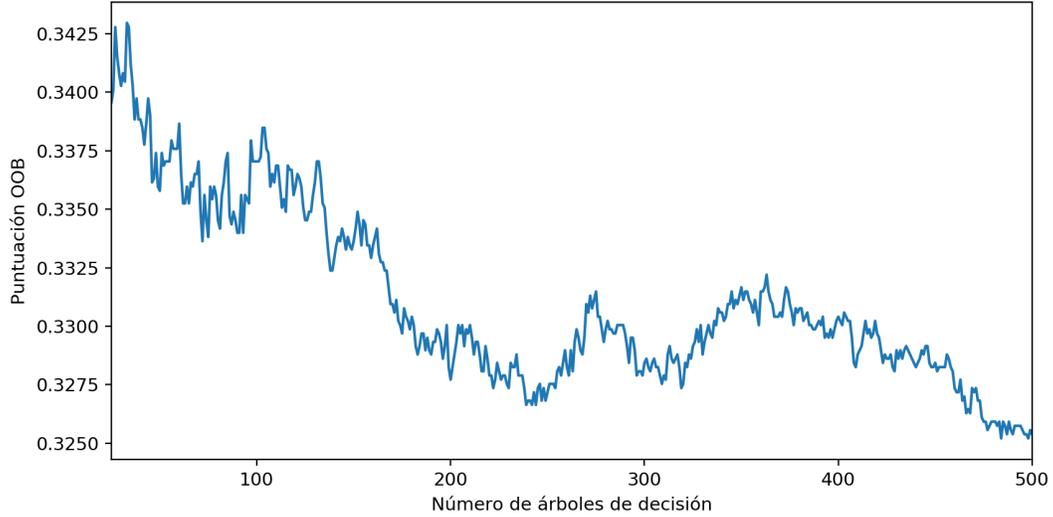


Figura 10: Puntuación *Out-Of-Bag* conforme aumenta el número de árboles de decisión implementados.

Para identificar los patrones nos serviremos de una propiedad del clasificador RF que otorga ponderaciones a las variables (ver Tabla 3) que utiliza para discriminar las clases. Después, como segundo escenario, parejas de sentimientos serán formadas para obtener nuevamente las puntuaciones de clasificación binarias apreciando los sentimientos que mejor son discriminados.

Tabla 3: Variables utilizadas durante el proceso de clasificación.

Variable	Característica del grafo	Región cerebral
c_1	$ID(v)$	LTI
c_2		LPD
c_3		LPI
c_4		LTD
c_5		LFD
c_6		LFI
c_7	$OD(x)$	LTI
c_8		LPD
c_9		LPI
c_{10}		LTD
c_{11}		LFD
c_{12}		LFI
c_{13}	$C_B(v)$	LTI
c_{14}		LPD
c_{15}		LPI
c_{16}		LTD
c_{17}		LFD
c_{18}		LFI
c_{19}	$E(G)$	todas

5. Resultados

Los resultados que a continuación se presentan fueron obtenidos considerando el valor F como métrica para evaluar el desempeño de clasificación previamente descrita en la Sección 4.3.4. Es importante recordar que los datos analizados son producto de los 15 sentimientos evocados para cada uno de los 32 voluntarios. En la Tabla 4 se muestran los resultados de una clasificación binaria entre sentimientos positivos y negativos siguiendo una validación cruzada destacando $F_{\max} = 0.6116$ como el valor máximo ubicado en la banda beta. Este proceso consiste obtener tanto el conjunto de entrenamiento como de prueba de forma aleatoria k veces donde en cada una de las repeticiones se evalúa un clasificador (para nuestro estudio fue de $k = 10$).

Tabla 4: Listado de valores F utilizando diez validaciones cruzadas

Banda de frecuencia	Valor F
delta	0.5269
theta	0.5566
alfa	0.5548
beta	0.6116
gama	0.5438
todas	0.5502

En la Sección 4.2.4 mencionamos a la impureza de Gini, definida formalmente en (37), que permite identificar a aquellas variables con mayor importancia para *random forest*. Para la clasificación binaria mencionada anteriormente y considerando todas las bandas de frecuencia encontramos (ver Figura 11):

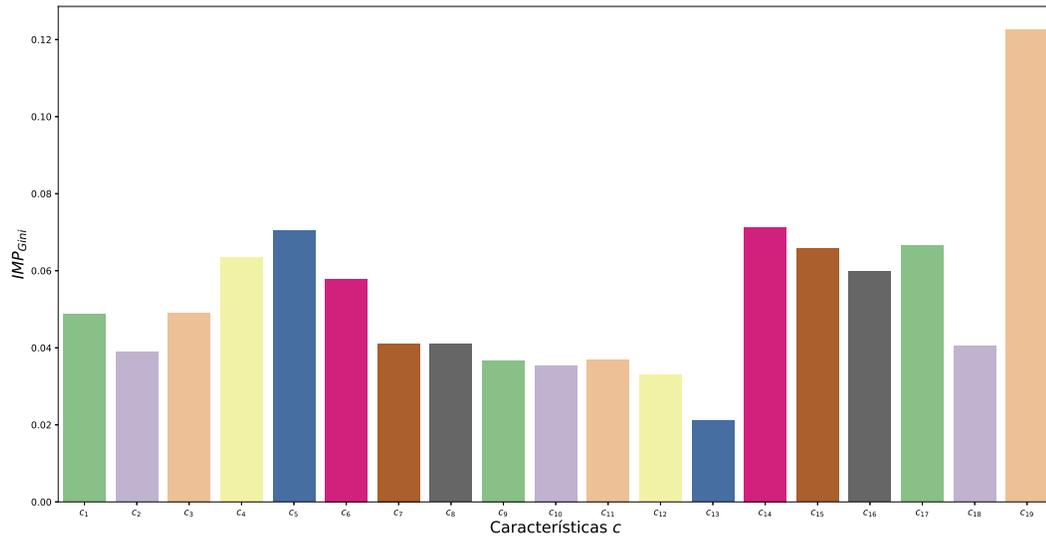


Figura 11: Ponderación obtenida para cada una de las características durante la clasificación binaria utilizando todas las bandas de frecuencia.

- *in-degree* del lóbulo temporal derecho y ambos hemisferios del lóbulo frontal;
- *betweenness centrality* de ambos hemisferios en el lóbulo parietal, del lóbulo temporal derecho así como del lóbulo frontal también derecho;
- *global efficiency*, como la variable que más aporta en la discriminación de clases.

En el caso concreto de las bandas de frecuencia son reportadas estas mismas características con excepción de la banda gama donde no se aprecia una diferencia entre el resto de las características (ver Figura 12).

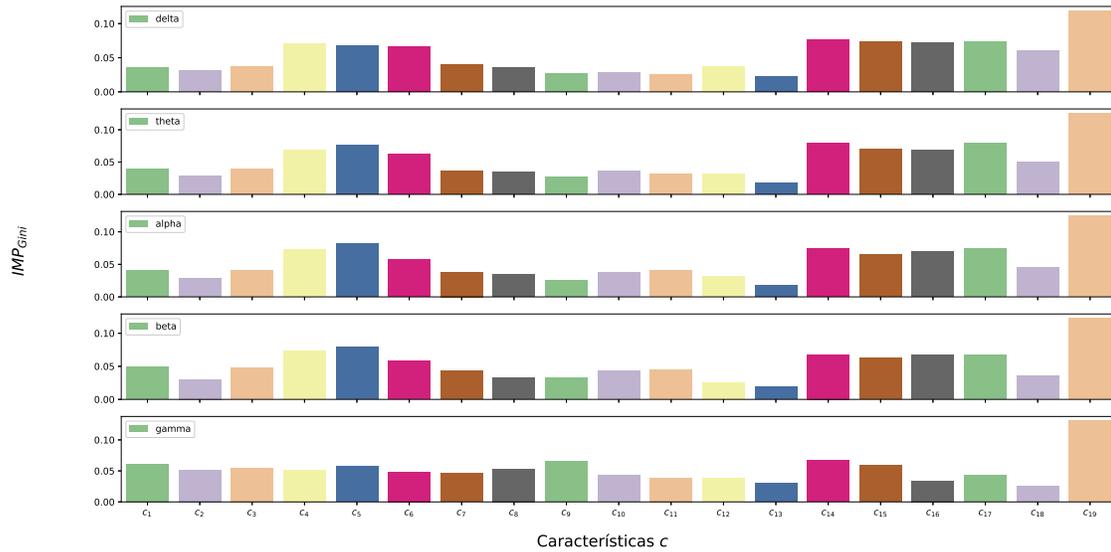


Figura 12: Ponderación obtenida en las variables características durante la clasificación binaria para cada banda de frecuencia

La banda de frecuencia delta puede notarse parejas de sentimientos que usualmente fueron mejor clasificadas: *felicidad*, *duelo*, *tristeza*, *compasión* y *enojo*. Por el contrario las menos frecuentes son: *humildad*, *frustración*, *alegría* y (ver Tabla 5).

Tabla 5: Pares de sentimientos con $F > F_{\max}$ correspondiente la banda delta de frecuencia

Sentimientos	Valor F
<i>felicidad-miedo</i>	0.7165
<i>alivio-frustración</i>	0.7042
<i>felicidad-duelo</i>	0.7024
<i>felicidad-frustración</i>	0.6788
<i>compasión-duelo</i>	0.6676
<i>felicidad-complacido</i>	0.6633
<i>felicidad-enojo</i>	0.6632
<i>felicidad-humildad</i>	0.6600
<i>felicidad-tristeza</i>	0.6571
<i>alivio-compasión</i>	0.6526
<i>emoción-duelo</i>	0.6500
<i>emoción-miedo</i>	0.6444
<i>miedo-tristeza</i>	0.6390
<i>emoción-humildad</i>	0.6325
<i>amor-duelo</i>	0.6256
<i>enojo-tristeza</i>	0.6250
<i>alegría-tristeza</i>	0.6236
<i>complacido-enojo</i>	0.6208
<i>alivio-tristeza</i>	0.6195
<i>felicidad-compasión</i>	0.6183
<i>disgusto-duelo</i>	0.6137
<i>compasión-disgusto</i>	0.6134
<i>complacido-disgusto</i>	0.6121

La Tabla 6 muestra las clasificaciones binarias correspondientes a la banda theta de frecuencia en donde puede apreciarse que *felicidad*, *enojo*, *duelo*, *tristeza* y *disgusto* resultan ser usualmente mejor clasificados. Los sentimientos menos frecuentes son: *humildad*, *compasión*, *miedo* y *amor*.

Tabla 6: Pares de sentimientos con $F > F_{\max}$ correspondiente la banda theta de frecuencia

Sentimientos	Valor F
<i>felicidad-frustation</i>	0.7608
<i>felicidad-enojo</i>	0.7421
<i>alegría-duelo</i>	0.7212
<i>felicidad-miedo</i>	0.7033
<i>felicidad-duelo</i>	0.7024
<i>alivio-frustración</i>	0.6971
<i>alivio-compasión</i>	0.6846
<i>felicidad-compasión</i>	0.6742
<i>disgusto-tristeza</i>	0.6733
<i>emoción-duelo</i>	0.6710
<i>alegría-tristeza</i>	0.6681
<i>felicidad-complacido</i>	0.6614
<i>felicidad-tristeza</i>	0.6581
<i>felicidad-humildad</i>	0.6571
<i>felicidad-disgusto</i>	0.6556
<i>miedo-tristeza</i>	0.6533
<i>enojo-duelo</i>	0.6521
<i>emoción-disgusto</i>	0.6480
<i>amor-frustración</i>	0.6429
<i>felicidad-emoción</i>	0.6389
<i>complacido-emoción</i>	0.6381
<i>frustración-duelo</i>	0.6378
<i>felicidad-alivio</i>	0.6343
<i>alivio-enojo</i>	0.6295
<i>humildad-enojo</i>	0.6287
<i>alegría-felicidad</i>	0.6272
<i>complacido-enojo</i>	0.6200
<i>emoción-tristeza</i>	0.6200
<i>disgusto-duelo</i>	0.6198
<i>enojo-tristeza</i>	0.6188
<i>enojo-disgusto</i>	0.6167

Los valores F para la banda de frecuencia alfa se encuentran en la Tabla 7 y aquí encontramos que: *felicidad*, *enojo*, *disgusto*, *tristeza* y *duelo* son los sentimientos más

comunes mientras que *frustración*, *celos*, *humildad* y *amor* fueron los menos habituales.

Tabla 7: Pares de sentimientos con $F > F_{\max}$ correspondiente la banda alfa de frecuencia

Sentimientos	Valor F
<i>felicidad-frustración</i>	0.7421
<i>alegría-disgusto</i>	0.7308
<i>felicidad-enojo</i>	0.7263
<i>felicidad-miedo</i>	0.7213
<i>emoción-tristeza</i>	0.7067
<i>alegría-tristeza</i>	0.7066
<i>felicidad-duelo</i>	0.7024
<i>felicidad-tristeza</i>	0.6976
<i>disgusto-tristeza</i>	0.6943
<i>enojo-tristeza</i>	0.6938
<i>alivio-compasión</i>	0.6869
<i>alegría-duelo</i>	0.6750
<i>alivio-frustración</i>	0.6708
<i>enojo-disgusto</i>	0.6602
<i>alivio-disgusto</i>	0.6551
<i>alivio-duelo</i>	0.6423
<i>enojo-miedo</i>	0.6409
<i>felicidad-complacido</i>	0.6405
<i>amor-duelo</i>	0.6404
<i>alegría-compasión</i>	0.6393
<i>alegría-celos</i>	0.63968
<i>felicidad-disgusto</i>	0.6366
<i>enojo-duelo</i>	0.6329
<i>felicidad-humildad</i>	0.6314
<i>felicidad-celos</i>	0.6310
<i>felicidad-compasión</i>	0.6196
<i>alivio-tristeza</i>	0.6186
<i>emoción-disgusto</i>	0.6180
<i>complacido-enojo</i>	0.6137

En la banda de frecuencia beta los sentimientos negativos continúan liderando: *fe-*

licidad, enojo, disgusto, alivio y tristeza. También puede notarse como los sentimientos infrecuentes resultan ser aquellos con una carga positiva: *frustración, alegría, complacido, celos y amor* (ver Tabla 8).

Tabla 8: Pares de sentimientos con $F > F_{\max}$ correspondiente la banda beta de frecuencia

Sentimientos	Valor F
<i>felicidad-enojo</i>	0.7558
<i>felicidad-duelo</i>	0.7238
<i>humildad-disgusto</i>	0.6848
<i>felicidad-disgusto</i>	0.6735
<i>disgusto-tristeza</i>	0.6733
<i>enojo-duelo</i>	0.6638
<i>emoción-celos</i>	0.6633
<i>felicidad-frustración</i>	0.6621
<i>complacido-enojo</i>	0.6608
<i>emoción-duelo</i>	0.6571
<i>alegría-disgusto</i>	0.6550
<i>alivio-compasión</i>	0.6480
<i>felicidad-miedo</i>	0.6478
<i>felicidad-humildad</i>	0.6467
<i>felicidad-tristeza</i>	0.6429
<i>alivio-enojo</i>	0.6427
<i>alivio-disgusto</i>	0.6335
<i>enojo-tristeza</i>	0.6325
<i>amor-frustración</i>	0.6186
<i>alivio-duelo</i>	0.6176
<i>compasión-enojo</i>	0.6175
<i>miedo-tristeza</i>	0.6170
<i>alivio-miedo</i>	0.6143
<i>alegría-compasión</i>	0.6140
<i>emoción-tristeza</i>	0.6133

En la Tabla 9, con el desempeño de clasificación para la banda de frecuencia gamma, observamos una mezcla repetitiva de sentimientos positivos y negativos: *enojo, emoción,*

felicidad, alegría y tristeza. Del mismo modo en para aquellos que aparecen de forma reiterada: *amor, humildad, compasión, frustración y alivio*.

Tabla 9: Pares de sentimientos con $F > F_{\max}$ correspondiente la banda gamma de frecuencia

Sentimientos	Valor F
<i>felicidad-enojo</i>	0.7158
<i>felicidad-tristeza</i>	0.6905
<i>alegría-tristeza</i>	0.6824
<i>disgusto-tristeza</i>	0.6743
<i>alegría-compasión</i>	0.6640
<i>emoción-duelo</i>	0.6619
<i>complacido-emoción</i>	0.6600
<i>felicidad-miedo</i>	0.6511
<i>alegría-enojo</i>	0.6507
<i>enojo-duelo</i>	0.6458
<i>alegría-complacido</i>	0.6429
<i>emoción-disgusto</i>	0.6412
<i>miedo-tristeza</i>	0.6401
<i>emoción-miedo</i>	0.6327
<i>felicidad-frustración</i>	0.6317
<i>amor-humildad</i>	0.6297
<i>complacido-enojo</i>	0.6267
<i>amor-enojo</i>	0.6239
<i>alivio-duelo</i>	0.6154

Las combinaciones que aparecen en todas las bandas de frecuencia fueron en concreto cinco y si bien el común denominador es que *global-efficiency* posee una alta importancia de Gini otras características destacables son:

- *frustración-felicidad* un decremento del *in-degree* para ambos lóbulos temporales en las bandas beta y gamma además de una ponderación mayor en el *in-degree* en el lóbulo parietal izquierdo y en el *out-degree* del lóbulo temporal derecho (Figura 13);

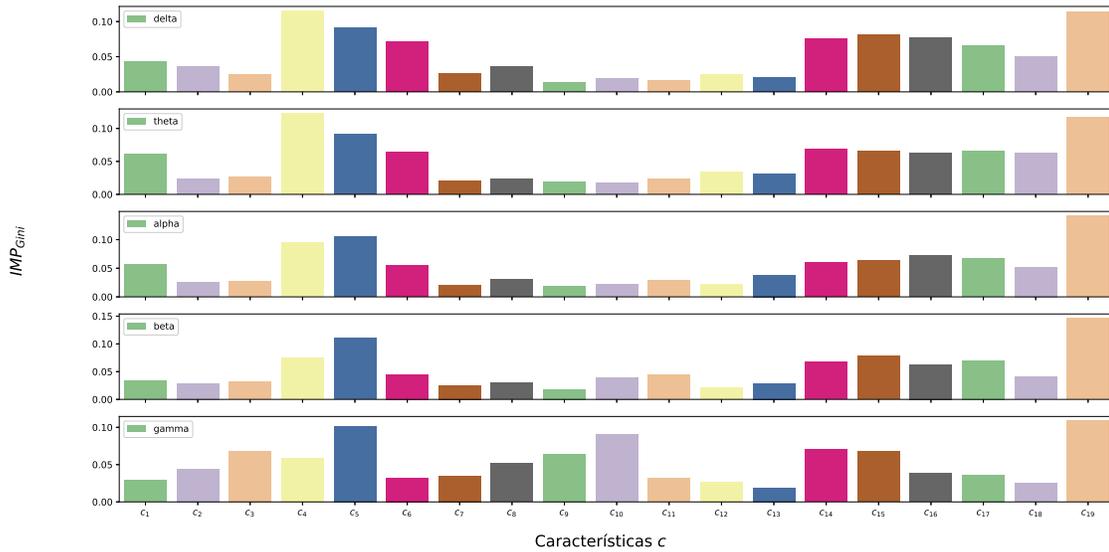


Figura 13: Ponderación obtenida en las variables características durante la clasificación binaria para *frustración-felicidad*

- *enojo-complacido* mayor importancia a *betweenness-centrality* de los lóbulos temporal y frontal ambos en el hemisferio derecho exceptuando el caso para la banda gamma donde esta misma característica sufre una disminución (Figura 14);

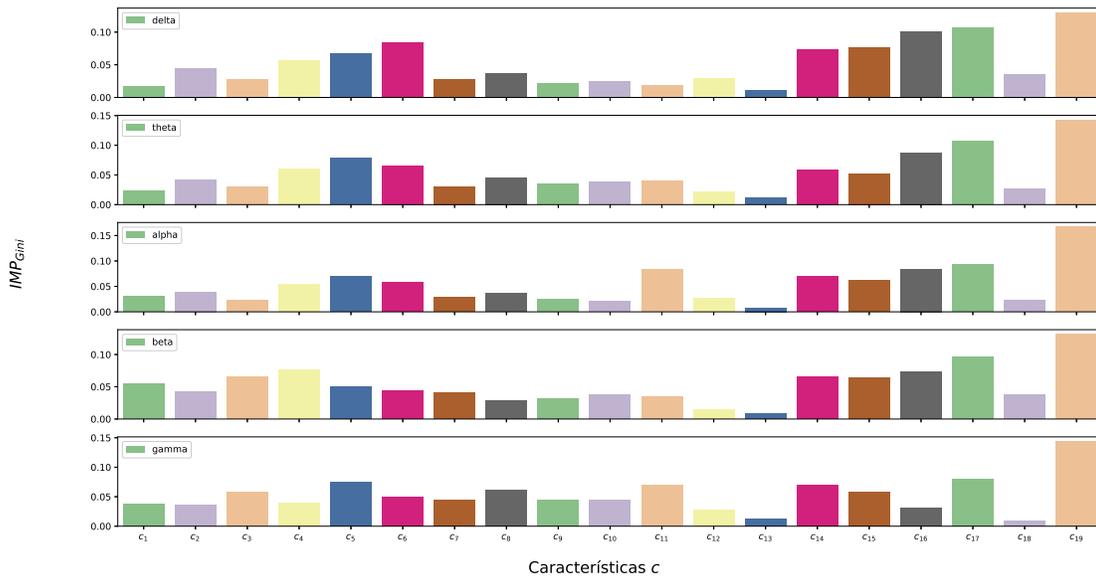


Figura 14: Ponderación obtenida en las variables características durante la clasificación binaria para *enojo-complacido*

- *enojo-felicidad* el *in-degree* del lóbulo temporal derecho sobrepasa incluso la puntuación de *global-efficiency* pero disminuye conforme se pasa bandas de alta frecuencia, específicamente en la banda gamma donde es superada por el *out-degree* de los lóbulos parietal izquierdo y temporal derecho (Figura 15);

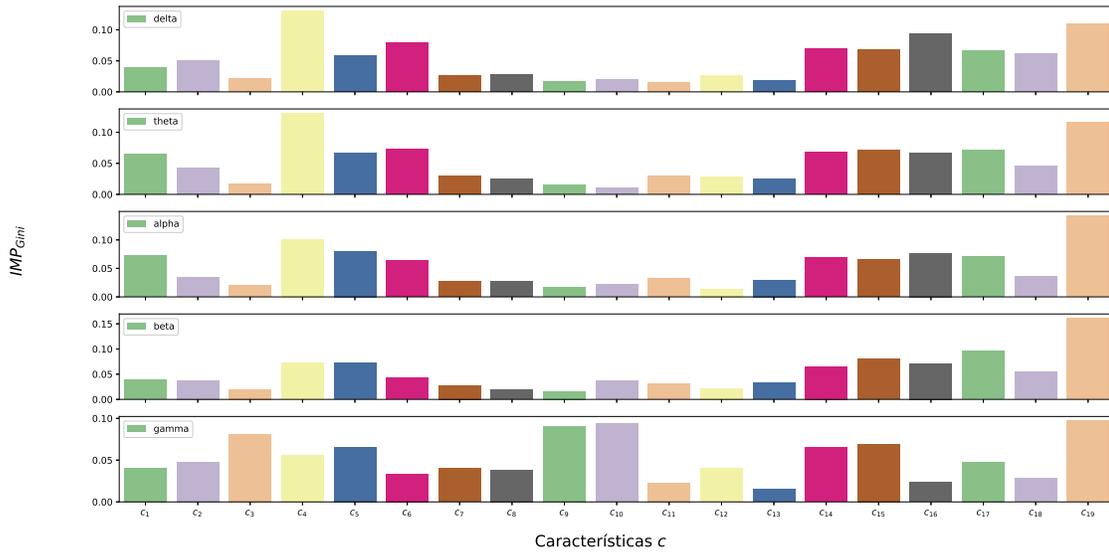


Figura 15: Ponderación obtenida en las variables características durante la clasificación binaria para *enojo-felicidad*

- *tristeza-felicidad* son habituales tanto el *in-degree* del lóbulo frontal derecho como el *betweenness-centrality* del lóbulo temporal derecho hasta la banda gamma donde el *out-degree* del lóbulo frontal derecho adquiere mayor relevancia (Figura 16);

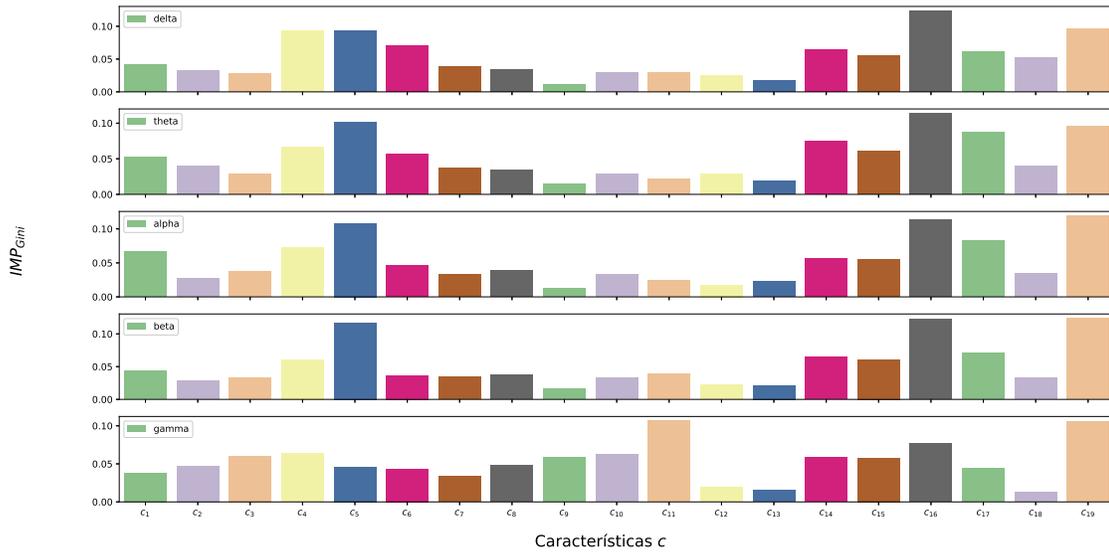


Figura 16: Ponderación obtenida en las variables características durante la clasificación binaria para *tristeza-felicidad*

- *miedo-felicidad* el *betweenness-centrality* de los lóbulos temporal derecho y parietal izquierdo permanecen con una importancia equiparable a la de *global-efficiency* que se ve reducida conforme pasamos las bandas de frecuencia como en la banda gamma donde el *ou-degree* del lóbulo parietal izquierdo se sobrepone (Figura 17).

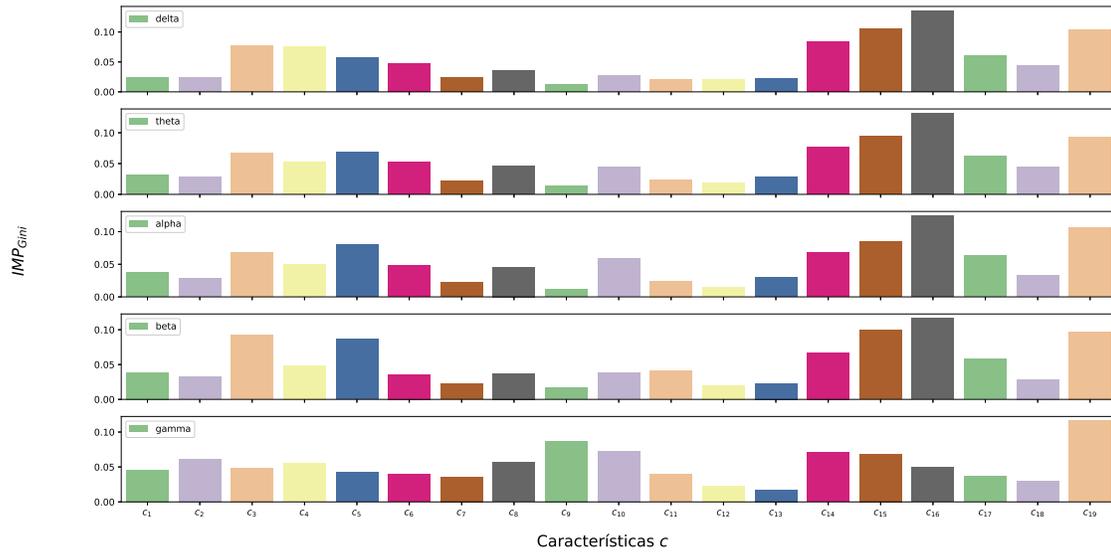


Figura 17: Ponderación obtenida en las variables características durante la clasificación binaria para *miedo-felicidad*

6. Conclusiones y trabajo futuro

De las tablas presentadas en la sección anterior puede notarse como el sentimiento de celos resultó ser el menos frecuente concordando con un reporte posterior de los voluntarios donde reportaban dificultades para lograr la imaginación correspondiente [19]. Por otra parte la felicidad (un sentimiento positivo) aparece múltiples ocasiones seguida del enojo, la tristeza, el duelo y el disgusto de tal suerte que conforman el grupo de los sentimiento negativos.

El objeto de la clasificación binaria es identificar los pares que pueden ser discriminados con mayor facilidad entre los cuales destacan tristeza-felicidad, enojo-complacido, miedo-felicidad, frustración-felicidad, enojo-felicidad, compasión-alivio, tristeza-alegría, tristeza-miedo, tristeza-enojo, y duelo-enojo. Desde luego parejas de sentimientos con valencias opuestas sobresalen en el proceso de clasificación y la lista continúa de esta manera. Una razón de esto puede atribuirse a los estados afectivos sencillos relacionados con la aversión y el interés que resultan útiles en la naturaleza. También hay que hacer notar aquellos pares donde ambos sentimientos son positivos como la compasión con el alivio, la humildad con la felicidad y el estar complacido también con la felicidad puesto que el afecto positivo usualmente es tratado a groso modo considerando únicamente a la felicidad o bien un grupo reducido de sentimientos relacionados [21].

Se observa que la felicidad resulta ser usualmente identificada en los procesos de clasificación junto a la alegría probablemente a que esta última es asociado a un estado de satisfacción o felicidad profunda. Los demás sentimientos positivos: estar complacido, la compasión y el alivio pueden atribuirse al rango de edad de los participantes que va de los 18 hasta los 38 años cuyas experiencias de vida estarían más enfocadas en, por citar algunos ejemplos, el haber ingresado a una institución de educación superior y los objetivos laborales. En lo que respecta a la valencia negativa la tristeza suele ser clasificada comúnmente en diversos protocolos mientras que el disgusto y el enojo podrían asociarse a la carga de trabajo ya sea por cuestiones laborales o el cumplir altas

expectativas personales. Por último, el duelo estaría relacionado a rupturas amorosas y la pérdida de una mascota o bien un ser amado.

La concepción y percepción de los sentimientos puede variar entre individuos de acuerdo a situaciones particulares y factores generales como la cultura, el lenguaje y el contexto [22]. Para ilustrar esto un estímulo asociado con la felicidad puede no resultar efectivo para alguien, incluso podría causar frustración ya que resultaría difícil para el voluntario llevar a cabo el experimento. Por tal motivo la imaginación de sentimientos por cuenta propia aparece como una alternativa donde la persona puede utilizar cualquier experiencia que haya tenido.

En relación a la problemática mencionada proponemos buscar específicamente a aquellos voluntarios que frecuentemente realicen ejercicios de introspección o bien cuenten con alguna experiencia en cuanto a inteligencia emocional se refiere. Así pues será posible aumentar la afinidad de los eventos con carga afectiva para su posterior diferenciación. Del mismo modo tomar a consideración sujetos que no hayan reportado ejercicios de autoconocimiento en lo que respecta a sus sentimientos de tal manera que se dispondría de dos grupos diferentes.

Naturalmente la lista palabras con carga afectiva utilizada en este trabajo de investigación fue elaborado en el contexto del lenguaje y cultura anglosajona, geográficamente se trata de personas pertenecientes a la comunidad universitaria de la Universidad de California en San Diego. En consecuencia otro diseño experimental puede ser enfocado en la construcción de un léxico referente a situaciones afectivas de acuerdo a la cultura y lenguajes de una localización mexicana. Si apelamos a un ejemplo «la pasión del fútbol» podría ser un buen punto de partida debido a la constante promoción y mercadotecnia que se le ha hecho a lo largo de los años.

Finalmente es imperativo recordar la importancia del análisis de los sentimientos por sus diversas aplicaciones entre las cuales mencionamos algunas de las que recoge [17]:

- el monitoreo y diagnóstico médico de esquizofrenia, autismo y depresión,
- en la industria del musical para explorar los efectos en el público de diferentes edades
- en el área de ventas para entender el comportamiento de consumo
- y en la pedagogía evaluando el proceso de aprendizaje en estudiantes.

Para el desarrollo humano la educación enfocada a los sentimientos ya que no se le ha dado un lugar a la par de asignaturas curriculares en escuelas de educación básica, por citar un ejemplo.

6.1. Discusión

Como se había mencionado en la sección 1.1 son varias las técnicas utilizadas en los estudios para la clasificación de sentimientos abarcando desde estadísticas simples como la media y la desviación estándar, pasando por el uso de la potencia del espectro hasta el análisis más elaborados como las transformadas Wavelet los patrones espaciales comunes y la coherencia. Nos enfocaremos en los estudios que se sirven de la coherencia ya que se aproximan a la estrategia descrita en el presente estudio sobre la conectividad cerebral funcional.

Primeramente en [14] además de la coherencia otras métricas fueron implementadas: la correlación y la sincronización de fase. Estas tres propuestas fueron evaluadas para discriminar sentimientos positivos, negativos y neutrales (tres clases) con un clasificador denominado *quadratic discriminant analysis*. Es importante este contraste en la discriminación de sentimientos ya que, además de tratarse de otro clasificador, los sentimientos fueron acotados a tres clases mientras que nuestra propuesta es una clasificación binaria para cada par de sentimientos. Además estas características no fueron

mapeadas a una representación de grafos. Por otro lado el estímulo usado para causar la respuesta afectiva fueron cortos de video cuya duración abarcaba desde 0.5 a 5 minutos.

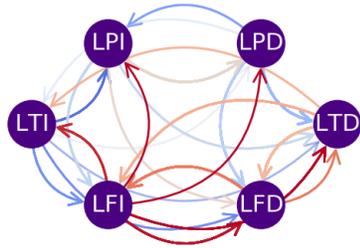
En segundo lugar tenemos a [15] cuya metodología se aproxima a nuestro flujo de trabajo descrito en la sección 4.4. Si bien la representación a un grafo también es llevada a cabo las características obtenidas de este difieren con las nuestras: la fuerza (*strength*), el coeficiente de agrupamiento (*clustering coefficient*) y la centralidad de eigenvectores (*eigenvector centrality*). Estas variables sirven a un clasificador conocido como máquina de soporte vectorial para llevar a cabo una clasificación de 3 categorías: la felicidad, un estado neutro y la tristeza. Los registros EEG usados fueron obtenidos de la base de datos SEED cuyos estímulos, al igual que en el estudio anterior, resultan ser cortos de video [17].

Finalmente encontramos más de tres sentimientos en [16] concretamente: la felicidad, la tristeza, el miedo, la ira, la sorpresa y el disgusto utilizando imágenes, audios y cortos de video para evocar la respuesta afectiva. Para la discriminación se apoyó de una máquina de soporte vectorial que analizó los mismos tres estimadores usados en [14], pero un cuarto fue agregado denominado como análisis biespectral.

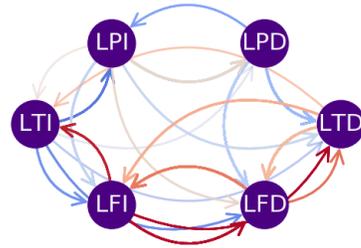
Debe señalarse, para estos tres estudios en particular, que previo al proceso de clasificación fue llevada a cabo una selección de características (conocido en inglés como *feature selection*) de tal manera que los algoritmos de clasificación consideren sólo las variables con mayor información. Mientras que nuestra metodología presenta a RF como clasificador cabe recalcar que puede ser utilizado también para una selección de características como se demostró con la importancia de Gini en la sección 6.

Es importante mencionar que existe otra forma de ponderar sentimientos y a estas evaluaciones se les conocen como la valencia que es un indicativo del gusto o disgusto por algo, y el aerosol que representa si una emoción está activa o inactiva. Ambas son mediciones proporcionadas por los voluntarios mediante cuestionarios tras llevar a cabo el registro correspondientes a las señales EEG.

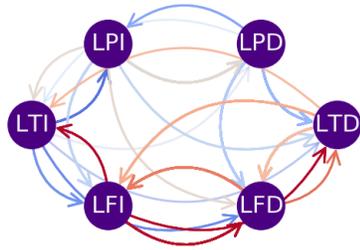
A. Apéndice de Figuras



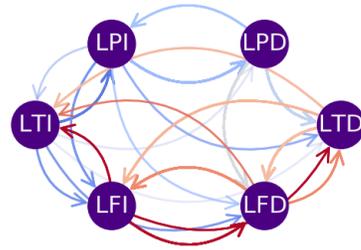
(a) Delta



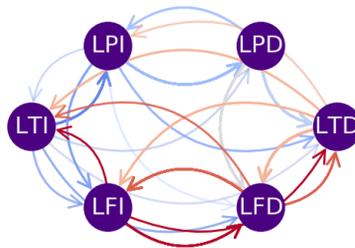
(b) Theta



(c) Alpha

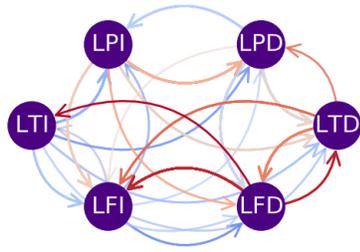


(d) Beta

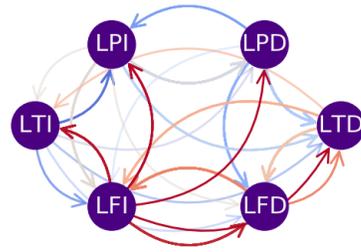


(e) Gamma

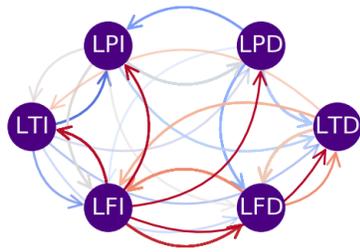
Figura 18: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de ira para cada una de las bandas de frecuencia.



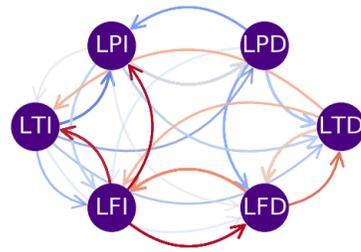
(a) Delta



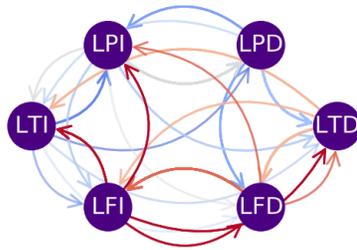
(b) Theta



(c) Alpha

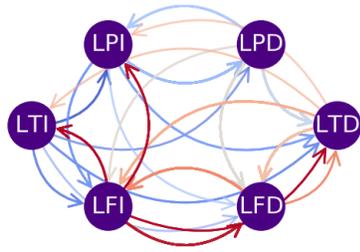


(d) Beta

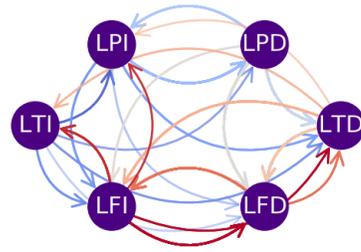


(e) Gamma

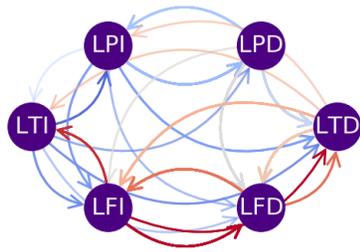
Figura 19: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de humildad para cada una de las bandas de frecuencia.



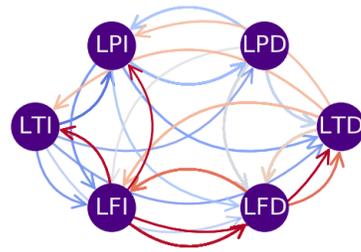
(a) Delta



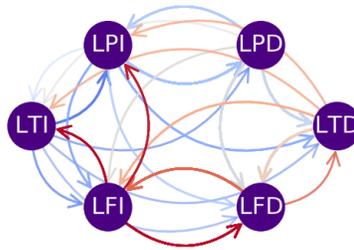
(b) Theta



(c) Alpha

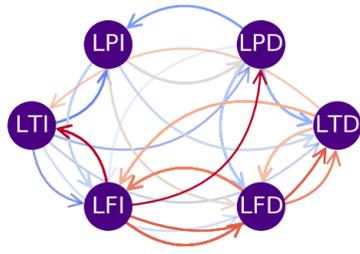


(d) Beta

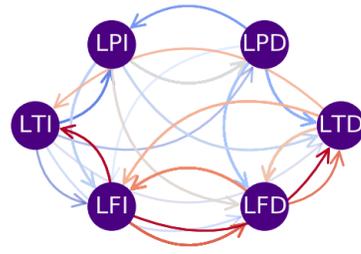


(e) Gamma

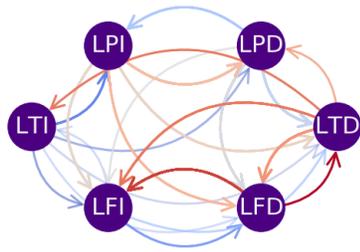
Figura 20: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de compasión para cada una de las bandas de frecuencia.



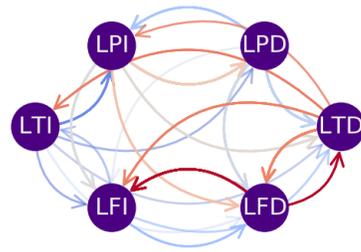
(a) Delta



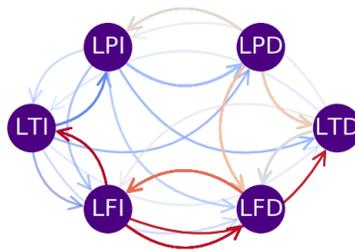
(b) Theta



(c) Alpha

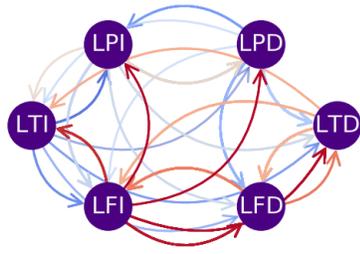


(d) Beta

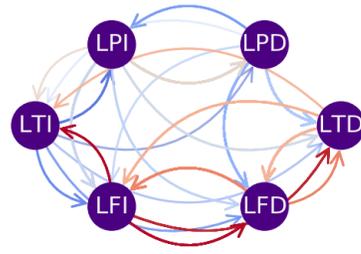


(e) Gamma

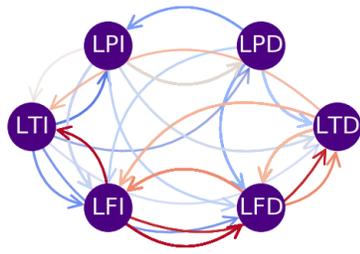
Figura 21: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de complacido para cada una de las bandas de frecuencia.



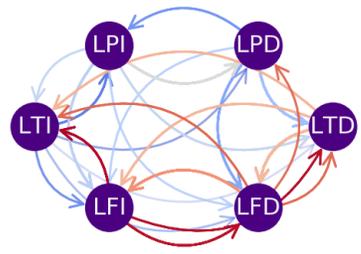
(a) Delta



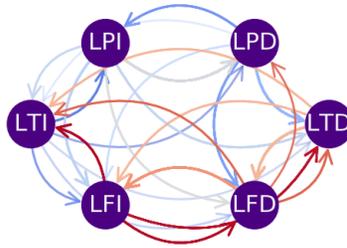
(b) Theta



(c) Alpha

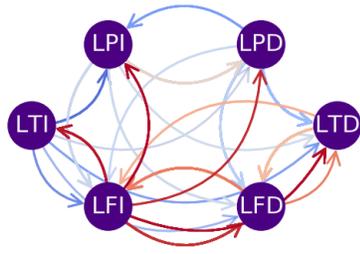


(d) Beta

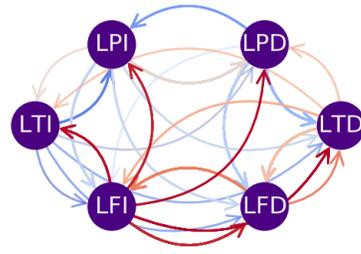


(e) Gamma

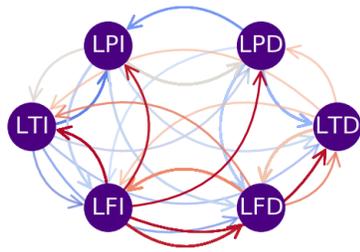
Figura 22: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de disgusto para cada una de las bandas de frecuencia.



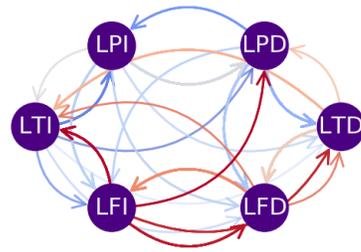
(a) Delta



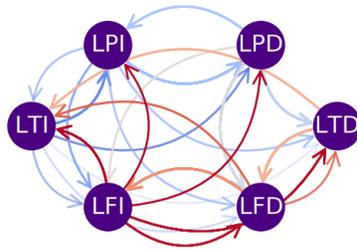
(b) Theta



(c) Alpha

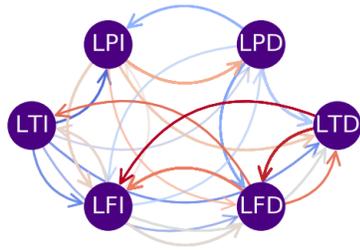


(d) Beta

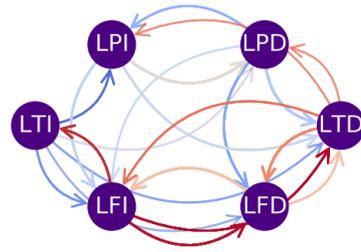


(e) Gamma

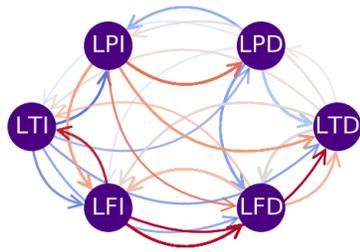
Figura 23: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de emoción para cada una de las bandas de frecuencia.



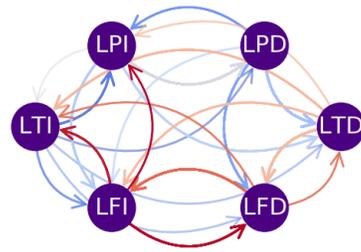
(a) Delta



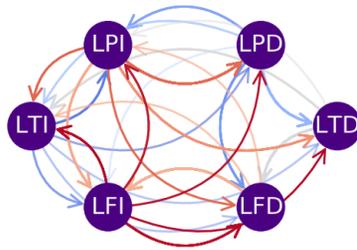
(b) Theta



(c) Alpha

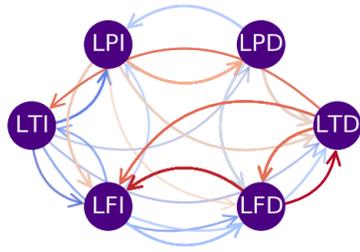


(d) Beta

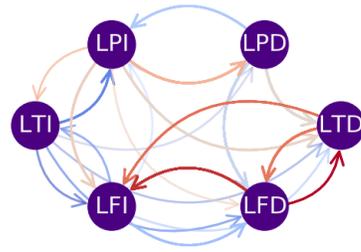


(e) Gamma

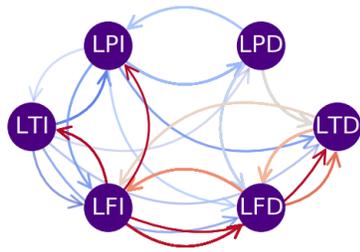
Figura 24: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de miedo para cada una de las bandas de frecuencia.



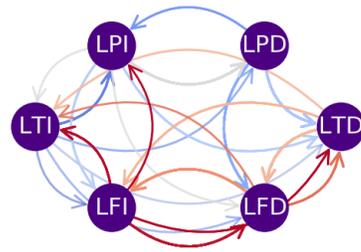
(a) Delta



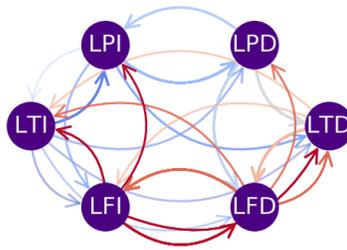
(b) Theta



(c) Alpha

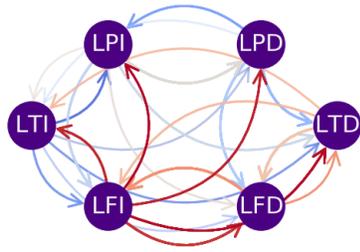


(d) Beta

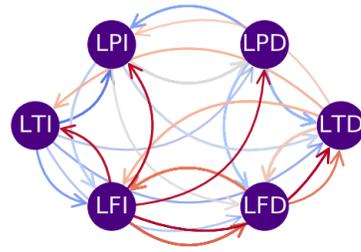


(e) Gamma

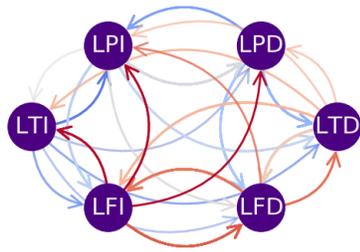
Figura 25: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de frustración para cada una de las bandas de frecuencia.



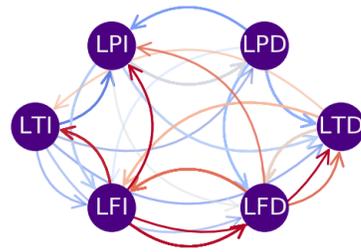
(a) Delta



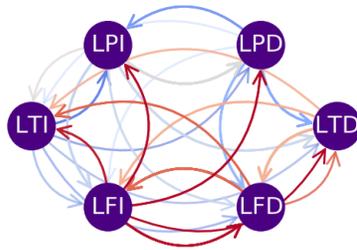
(b) Theta



(c) Alpha

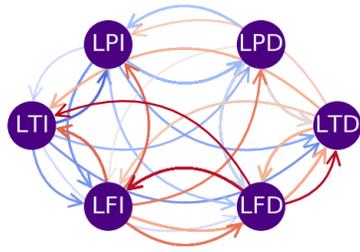


(d) Beta

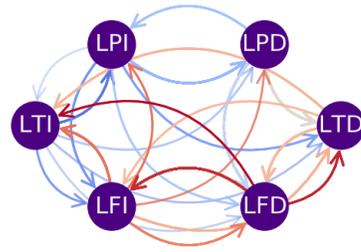


(e) Gamma

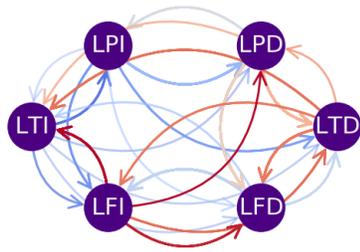
Figura 26: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de duelo para cada una de las bandas de frecuencia.



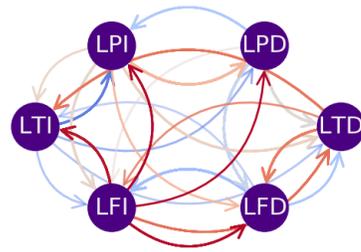
(a) Delta



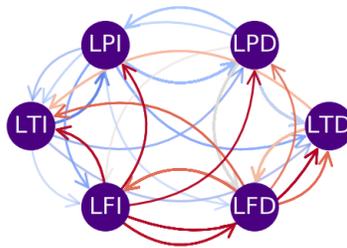
(b) Theta



(c) Alpha

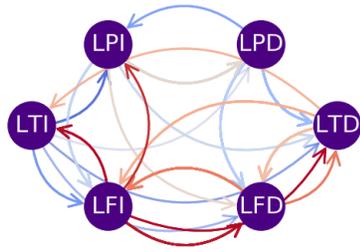


(d) Beta

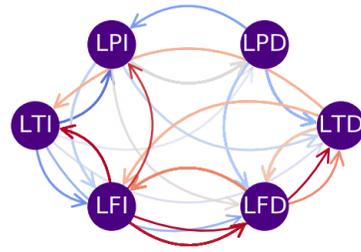


(e) Gamma

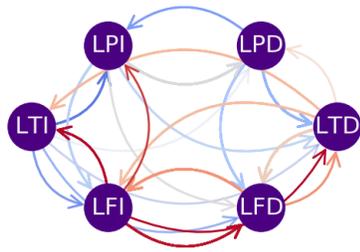
Figura 27: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de felicidad para cada una de las bandas de frecuencia.



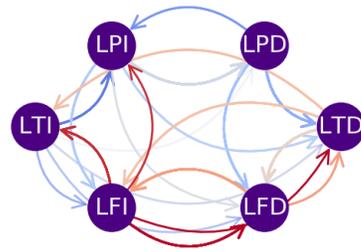
(a) Delta



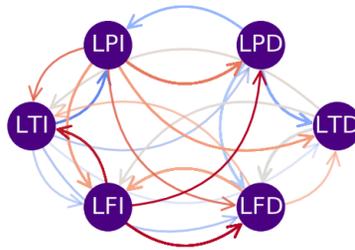
(b) Theta



(c) Alpha

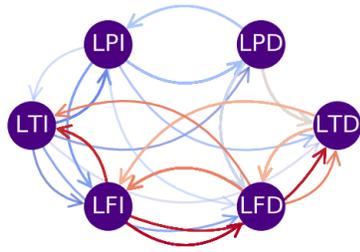


(d) Beta

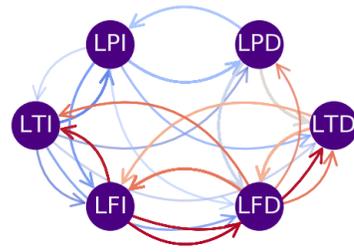


(e) Gamma

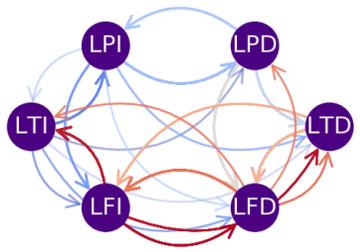
Figura 28: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de celos para cada una de las bandas de frecuencia.



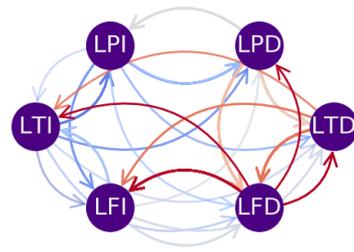
(a) Delta



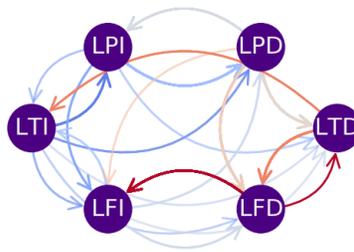
(b) Theta



(c) Alpha

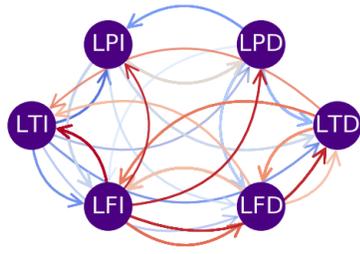


(d) Beta

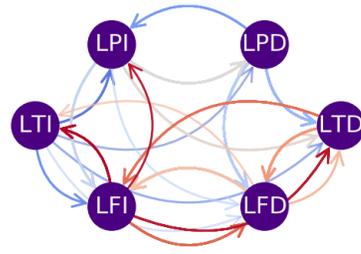


(e) Gamma

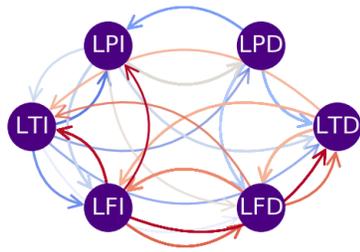
Figura 29: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de alegría para cada una de las bandas de frecuencia.



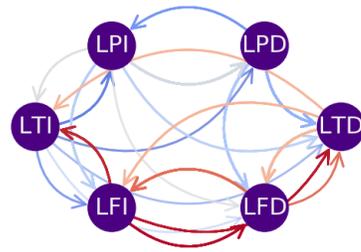
(a) Delta



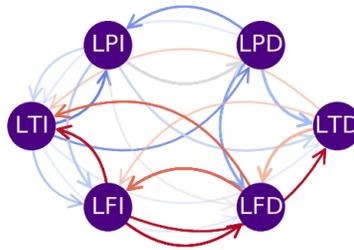
(b) Theta



(c) Alpha

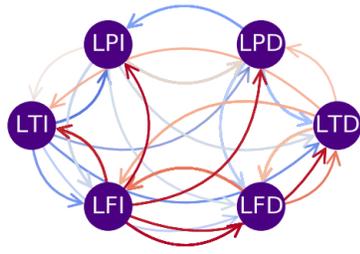


(d) Beta

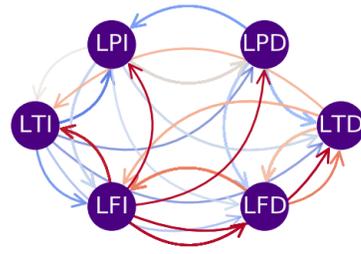


(e) Gamma

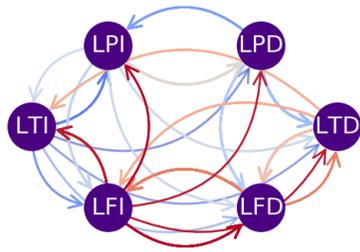
Figura 30: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de amor para cada una de las bandas de frecuencia.



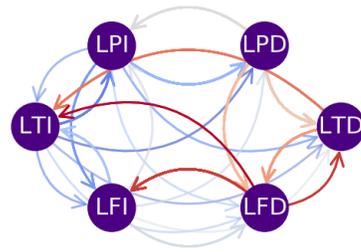
(a) Delta



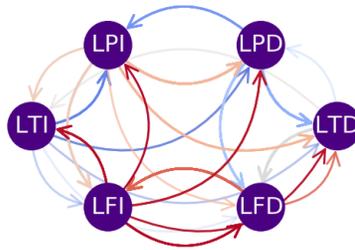
(b) Theta



(c) Alpha

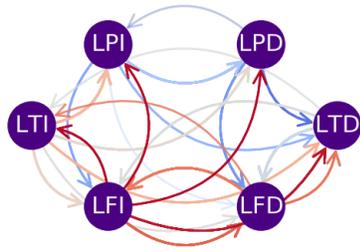


(d) Beta

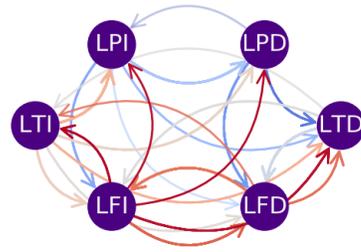


(e) Gamma

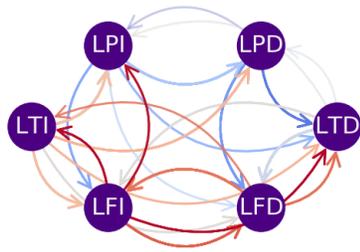
Figura 31: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de alivio para cada una de las bandas de frecuencia.



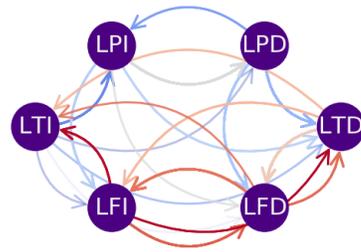
(a) Delta



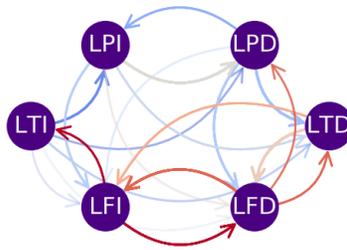
(b) Theta



(c) Alpha



(d) Beta



(e) Gamma

Figura 32: Grafos mostrando la conectividad funcional de todos los voluntario correspondiente al sentimiento de tristeza para cada una de las bandas de frecuencia.

Bibliografía

- [1] S. M. Alarcão and M. J. Fonseca, “Emotions recognition using EEG signals: A survey,” *IEEE Transactions on Affective Computing*, vol. 10, no. 3, pp. 374–393, 2017.
- [2] D. A. Candia Rivera, “Caracterización de la respuesta emocional ante estímulos visuales en registros electroencefalográficos,” *Repositorio Académico de la Universidad de Chile*, 2016. [Online]. Available: <http://repositorio.uchile.cl/handle/2250/143582>
- [3] Wikimedia. (2018, Jul.) Lobes of the brain. Internet. The University of Queensland. The Queensland Brain Institute QBI Building, 79 The University of Queensland St Lucia QLD 4072, Australia. [Online]. Available: <https://qbi.uq.edu.au/brain/brain-anatomy/lobes-brain>
- [4] Z. Lan, O. Sourina, L. Wang, and Y. Liu, “Real-time EEG-based emotion monitoring using stable features,” *The Visual Computer*, vol. 32, no. 3, pp. 347–358, 2016.
- [5] T. Song, W. Zheng, P. Song, and Z. Cui, “EEG emotion recognition using dynamical graph convolutional neural networks,” *IEEE Transactions on Affective Computing*, 2018.
- [6] M. R. Benítez Aldás *et al.*, “Estudio y análisis de métodos para la extracción de características y clasificación de emociones basados en EEG,” Master’s thesis, Universidad Autónoma de Madrid, 2018.
- [7] X. Li, D. Song, P. Zhang, Y. Zhang, Y. Hou, and B. Hu, “Exploring EEG features in cross-subject emotion recognition,” *Frontiers in neuroscience*, vol. 12, p. 162, 2018.

- [8] A. Q.-X. Ang, Y. Q. Yeong, and W. Wee, “Emotion classification from EEG signals using time-frequency-dwt features and ann,” *Journal of Computer and Communications*, vol. 5, no. 3, pp. 75–79, 2017.
- [9] P. Li, H. Liu, Y. Si, C. Li, F. Li, X. Zhu, X. Huang, Y. Zeng, D. Yao, Y. Zhang *et al.*, “EEG based emotion recognition by combining functional connectivity network and local activations,” *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 10, pp. 2869–2881, 2019.
- [10] B. MEDINA, J. E. SIERRA, and A. B. ULLOA, “Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas bci,” *Revista ESPACIOS*, vol. 39, no. 22, 2018.
- [11] M. Murugappan, N. Ramachandran, Y. Sazali *et al.*, “Classification of human emotion from EEG using discrete wavelet transform,” *Journal of biomedical science and engineering*, vol. 3, no. 04, p. 390, 2010.
- [12] D. Huang, C. Guan, K. K. Ang, H. Zhang, and Y. Pan, “Asymmetric spatial pattern for EEG-based emotion detection,” in *The 2012 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2012, pp. 1–7.
- [13] M. Hamed, S.-H. Salleh, and A. M. Noor, “Electroencephalographic motor imagery brain connectivity analysis for bci: a review,” *Neural computation*, vol. 28, no. 6, pp. 999–1041, 2016.
- [14] Y.-Y. Lee and S. Hsieh, “Classifying different emotional states by means of EEG-based functional connectivity patterns,” *PloS one*, vol. 9, no. 4, p. e95415, 2014.
- [15] X. Wu, W.-L. Zheng, and B.-L. Lu, “Identifying functional brain connectivity patterns for EEG-based emotion recognition,” in *2019 9th International IEEE/EMBS Conference on Neural Engineering (NER)*. IEEE, 2019, pp. 235–238.

- [16] R. Yuvaraj, M. Murugappan, U. R. Acharya, H. Adeli, N. M. Ibrahim, and E. Mesquita, “Brain functional connectivity patterns for emotional state classification in parkinson’s disease patients without dementia,” *Behavioural brain research*, vol. 298, pp. 248–260, 2016.
- [17] A. Al-Nafjan, M. Hosny, Y. Al-Ohali, and A. Al-Wabil, “Review and classification of emotion recognition based on EEG brain-computer interface system research: a systematic review,” *Applied Sciences*, vol. 7, no. 12, p. 1239, 2017.
- [18] C. Mühl, B. Allison, A. Nijholt, and G. Chanel, “A survey of affective brain computer interfaces: principles, state-of-the-art, and challenges,” *Brain-Computer Interfaces*, vol. 1, no. 2, pp. 66–84, 2014.
- [19] J. A. Onton and S. Makeig, “High-frequency broadband modulation of electroencephalographic spectra,” *Frontiers in human neuroscience*, vol. 3, p. 61, 2009.
- [20] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, “Scikit-learn: Machine learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [21] X. Hu, J. Yu, M. Song, C. Yu, F. Wang, P. Sun, D. Wang, and D. Zhang, “EEG correlates of ten positive emotions,” *Frontiers in human neuroscience*, vol. 11, p. 26, 2017.
- [22] N. Zhuang, Y. Zeng, K. Yang, C. Zhang, L. Tong, and B. Yan, “Investigating patterns for self-induced emotion recognition from EEG signals,” *Sensors*, vol. 18, no. 3, p. 841, 2018.