



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

CARACTERIZACIÓN DE LA RESPUESTA EMOCIONAL ANTE ESTÍMULOS
VISUALES EN REGISTROS ELECTROENCEFALOGRÁFICOS

MEMORIA PARA OPTAR EL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

DIEGO ANDRÉS CANDIA RIVERA

PROFESOR GUÍA:
PABLO ESTÉVEZ VALENCIA

MIEMBROS DE LA COMISIÓN:
PEDRO MALDONADO ARBOGAST
CLAUDIO PÉREZ FLORES

SANTIAGO DE CHILE
2016

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE: Ingeniero Civil Eléctrico
POR: Diego Andrés Candia Rivera
FECHA: Noviembre 2016
PROFESOR GUÍA: Pablo Estévez Valencia

CARACTERIZACIÓN DE LA RESPUESTA EMOCIONAL ANTE ESTÍMULOS VISUALES EN REGISTROS ELECTROENCEFALOGRÁFICOS

El presente trabajo de título tiene por objetivo caracterizar la respuesta en la actividad neuronal de sujetos que han sido expuestos a estímulos visuales con contenido emocional mediante el análisis de series de tiempo de los registros electroencefalográficos (EEG). En particular, se comparan tres estados emocionales en base a sus diferencias en los valores de valencia y excitación emocional.

La hipótesis de este trabajo es que la respuesta emocional ante estímulos visuales puede ser caracterizada en registros EEG en las dimensiones de tiempo, frecuencia y topografía en el cuero cabelludo. Para esto se introduce un enfoque metodológico en el que se analizan canales individuales de EEG descompuestos en bandas de frecuencia.

La base de datos utilizada consiste en nueve sujetos, cuyos registros fueron pre-procesados para eliminar el ruido y artefactos oculares. La metodología propuesta consiste en extracción de características, y la construcción de modelos predictivos de emociones basados en Máquinas de Soporte Vectorial y Bosques Aleatorios.

De los nueve sujetos, seis fueron utilizados como conjunto de entrenamiento para construir los modelos predictivos y los tres sujetos restantes fueron usados como conjunto de prueba. Los resultados obtenidos fueron una completa discriminación entre emociones positivas y negativas. Para la distinción entre las tres emociones a la vez se obtuvo una precisión de 2/3. Las 20 características utilizadas para la clasificación incluyen canales de distintos lóbulos del cerebro y frecuencias que van desde la banda delta hasta la gamma. Se observó además una alta influencia de la actividad de la banda alfa en los estados emocionales.

Los resultados sugieren que el registro de la actividad neuronal a través de EEG permite obtener signos del estado emocional en respuesta a estímulos visuales, pero para obtener una mayor precisión se deben combinar características de múltiples canales y frecuencias.

TABLA DE CONTENIDO

1	Introducción.....	8
1.1	Objetivos	9
1.1.1	Objetivo General	9
1.1.2	Objetivos específicos.....	9
1.2	Alcances.....	9
1.3	Estructura de la memoria	10
2	Antecedentes	11
2.1	Las emociones y sus respuestas fisiológicas.....	11
2.1.1	Caracterización bidimensional de las emociones	11
2.1.2	Respuestas fisiológicas en el procesamiento emocional.....	13
2.2	Neurobiología de las emociones	13
2.2.1	Hipotálamo	14
2.2.2	Amígdala	14
2.2.3	Corteza prefrontal.....	15
2.2.4	Caracterización hemisférica.....	16
2.3	La electroencefalografía y el registro de actividad bioeléctrica	17
2.3.1	Las neuronas y la generación de potenciales	17
2.3.2	Electroencefalografía.....	18
2.3.3	Potenciales relacionados a un evento	19
2.3.4	Ventajas y desventajas de la electroencefalografía.....	21
2.4	Estado del arte de la caracterización de emociones en EEG.....	22
2.5	Métodos usados en este trabajo para el procesamiento de señales y extracción de características	24
2.5.1	Filtros de frecuencia.....	24
2.5.2	Análisis de componentes independientes	25
2.5.3	Clasificación y aprendizaje supervisado	26
2.5.4	Máquinas de soporte vectorial	28
2.5.5	Random Forests	32
3	Metodología	35
3.1	Adquisición de los datos	35
3.2	Pre-procesamiento	37

3.3	Detección y reparación de canales defectuosos	38
3.4	Detección y extracción de artefactos oculares	41
3.5	Extracción de épocas y promediación	43
3.6	Extracción de bandas de frecuencia	44
3.7	Selección de características	45
3.8	Prueba de los modelos construidos	48
4	Resultados	49
4.1	Extracción de características	49
4.1.1	Banda delta	49
4.1.2	Banda theta	50
4.1.3	Banda alfa	50
4.1.4	Banda beta	52
4.1.5	Banda gamma	53
4.2	Selección de características y separabilidad en el conjunto de prueba 53	
4.2.1	Selección de las mejores características en base al conjunto de entrenamiento	53
4.3	Construcción de modelos de clasificación de emociones.....	56
4.3.1	Modelos basados en máquinas de soporte vectorial.....	57
4.3.2	Modelo basado en Random Forests	58
5	Discusión	61
5.1	Base de datos	61
5.1.1	Sujetos disponibles	61
5.1.2	Definición de estados emocionales	61
5.2	Metodología propuesta	62
5.2.1	Electroencefalografía.....	62
5.2.2	Pre-procesamiento.....	63
5.2.3	Selección de características.....	63
5.2.4	Construcción de modelos predictivos.....	64
5.3	Resultados obtenidos	67
6	Conclusiones	70
7	Bibliografía.....	72

ÍNDICE DE FIGURAS

Figura 1. Valencia y excitación.	12
Figura 2. Escala SAM.....	12
Figura 3. Sistema límbico.	13
Figura 4. Polarización de una neurona.	18
Figura 5. Distribución y etiquetado de electrodos.....	19
Figura 6. Potencial relacionado a un evento (ERP).	20
Figura 7. Potencial evocado visual.	20
Figura 8. Lóbulos del cerebro.	23
Figura 9. Ejemplo de filtro pasa banda.	25
Figura 10. Clasificación binaria con SVM	28
Figura 11. Transformación del espacio original a uno de atributos donde las muestras sean linealmente separable.....	31
Figura 12. Ejemplo de un árbol de decisión para clasificar frutas.	33
Figura 13. Sistema de electroencefalografía Biosemi.	35
Figura 14. Valores de valencia y excitación para las imágenes utilizadas....	36
Figura 15. Procedimiento experimental de estimulación visual.....	36
Figura 16. Banda de paso del filtro utilizado (1-40 Hz).	37
Figura 17. Efecto del re-referenciado de los canales.....	38
Figura 18. Ejemplo de canales defectuosos.	39
Figura 19. Densidad de probabilidad de un ensayo.....	40
Figura 20. Componente obtenida a través de ICA que contiene artefactos oculares	41
Figura 21. Espectro de potencia de una componente con artefactos no oculares (A) y una componente con artefactos oculares (B).....	42
Figura 22. Reconstrucción del canal FP ₁ sin componentes oculares.....	42
Figura 23. Potencial evocado visual en el canal O1.....	43
Figura 24. Efecto de normalizar un potencial evocado visual	44
Figura 25. Bandas de frecuencia de una señal	45
Figura 26. Ejemplo de las entradas usadas a través del tiempo para el SVM en la banda alfa baja	46
Figura 27. Precisión obtenida a través del tiempo después de la presentación del estímulo.....	47
Figura 28. Modelo promedio para estimar la relevancia de los canales en la clasificación.	47
Figura 29. Modelo promedio de la relevancia en la clasificación de cada canal.	51
Figura 30. P-valor de las características con mayor separabilidad entre emociones positivas y negativas en el conjunto de entrenamiento.	54
Figura 31. P-valor de las características con mayor separabilidad entre emociones positivas y neutrales en el conjunto de entrenamiento.....	55

Figura 32. P-valor de las características con mayor separabilidad entre emociones positivas y negativas en el conjunto de entrenamiento.	56
Figura 33. Disimilitudes de latencia en la banda alfa baja ante estímulos visuales positivos en el canal Pz.	66
Figura 34. Disimilitudes en los ERP de la banda alfa baja ante estímulos visuales negativos en el canal PO ₄	67

ÍNDICE DE TABLAS

Tabla 1. Bandas de frecuencia.....	44
Tabla 2. Características de la banda delta.....	50
Tabla 3. Características de la banda theta.....	50
Tabla 4. Características de la banda alfa.....	51
Tabla 5. Características de la banda beta.....	52
Tabla 6. Características de la banda gamma.....	53
Tabla 7. Precisión obtenida para distintos modelos de SVM en los tres sujetos de prueba.....	57
Tabla 8. Principales características usadas en SVM lineal para distinguir tres estados emocionales.....	58
Tabla 9. Precisión obtenida utilizando bosques aleatorios.....	59
Tabla 10. Principales características usadas en RF para distinguir tres estados emocionales.....	59
Tabla 11. Principales características usadas en RF para distinguir entre emociones positivas y negativas.....	60
Tabla 12. Rango de valencia y excitación de los estados emocionales.....	62

1 INTRODUCCIÓN

En los últimos años el estudio de las emociones ha crecido de forma significativa desde que se reconoció su importancia en la toma de decisiones y comunicación de las personas [1]. Otros factores han sido introducidos tales como el concepto de inteligencia emocional asociada a un tipo de cognición orientada a lo social [2] y considerar a las emociones como un factor importante para el éxito social, independiente de la inteligencia cognitiva [3].

Las emociones constituyen una serie de mecanismos corporales desarrollados durante la historia evolutiva de los organismos, susceptibles de modificarse por medio del aprendizaje y la experiencia, con el objetivo de aumentar la homeostasis, la supervivencia y el bienestar del organismo [4] [5].

Como resultado del procesamiento cognitivo, las emociones ayudan a moverse hacia lo que es evaluado como agradable, alejándose de lo que resulta desagradable. Las emociones adquieren un rol importante en la toma de decisiones y la resolución de conflictos. Así mismo, el procesamiento emocional resulta ser de gran relevancia en situaciones en que se presenta información incompleta, o en situaciones donde no es directo resolver a través de la razón. Por lo que las emociones tendrían la capacidad de modular otras funciones cognitivas.

Es sabido que las emociones tienen gran relevancia en la comunicación de las personas. Por este motivo la importancia y necesidad de reconocer emociones de manera automática han ido creciendo con el desarrollo de las interfaces humano-computador, acercando las máquinas a los humanos incluyendo el contenido emocional en la comunicación.

El reconocimiento de emociones se puede realizar a través del habla, las expresiones faciales o gestos. Sin embargo algunos de los mencionados pueden ser no del todo acertados, o bien pueden ser inmensurables en el caso de personas que padecen enfermedades que no les permiten comunicarse a través de la kinésica o el habla. Por esta razón las señales fisiológicas podrían ser una forma más objetiva de interpretar lo que está sucediendo en la conciencia de un tercero. En esta memoria se desea determinar emociones utilizando señales fisiológicas medidas a través de registros de electroencefalografía (EEG), que son señales provenientes de las fluctuaciones de voltaje de miles de neuronas en el cerebro.

La hipótesis del estudio a realizar es que la respuesta emocional a determinados estímulos visuales puede ser mapeada a la topografía en la cabellera, la frecuencia y el tiempo en que ocurre tal respuesta desde que se presenta el estímulo, a través de EEG.

1.1 OBJETIVOS

1.1.1 OBJETIVO GENERAL

El objetivo de este estudio es caracterizar las respuestas obtenidas en electroencefalografía ante estímulos visuales con contenido emocional.

1.1.2 OBJETIVOS ESPECÍFICOS.

Para poder cumplir el objetivo general del proyecto se debe cumplir los siguientes objetivos específicos.

1. Diseñar una metodología de extracción de características en señales de EEG en respuesta a estímulos visuales.
2. Seleccionar las características que permitan distinguir entre los estados emocionales positivo, negativo y neutral.
3. Comparar desempeño de clasificación para distintas formas de combinación de las características seleccionadas.

1.2 ALCANCES

El principal alcance de tener una caracterización de estados emocionales es el poder realizar una posterior detección automatizada de emociones en tiempo real.

En el área clínica, se encuentran pacientes que han pasado por una aguda etapa de coma, los que al despertar tienen como posibles diagnósticos el síndrome de enclaustramiento o encontrarse en estado mínimamente consciente, los cuales pueden mostrar ciertos signos de consciencia pero no son capaces de moverse o comunicarse de forma clara [6]. Como también se tienen las enfermedades degenerativas como la esclerosis lateral amiotrófica, que disminuye progresivamente la capacidad del paciente de moverse [7]. Para este tipo de diagnósticos un apoyo en la comunicación de estos pacientes podría mejorar su calidad de vida y la de sus familias.

Por otro lado existen aplicaciones comerciales del reconocimiento de emociones. El neuromarketing investiga los niveles de atención, memoria y emoción ante estímulos presentados, y la neuroeconomía investiga la toma de decisiones de las personas en un contexto dado [8]. Nuevas herramientas en esta área para la descripción emocional de un usuario ante un estímulo presentado pueden ser útiles para la investigación de mercados y comportamiento del consumidor.

1.3 ESTRUCTURA DE LA MEMORIA

La estructura principal de esta memoria se divide en 4 capítulos, explicados brevemente a continuación.

El capítulo dos tiene el objetivo de contextualizar al lector. Se describen los conceptos generales básicos que dan marco al proyecto. Los conceptos a revisar son la neurobiología de las emociones, el uso de electroencefalografía para el registro neuronal, el estado del arte en el reconocimiento de emociones y métodos de inteligencia computacional.

El capítulo tres describe las actividades del plan de trabajo que permitirán desarrollar el proyecto, además de la metodología propuesta.

En el cuarto capítulo se exponen y analizan los resultados obtenidos en la realización de las actividades. Se efectúa un análisis usando medios tales como tablas para las características seleccionadas y gráficos que muestran medidas de separabilidad de tales medidas.

En el capítulo 5 se discuten los resultados obtenidos y la metodología propuesta.

Finalmente en el capítulo 6 se presentan las conclusiones del trabajo a la luz de los resultados obtenidos. Se realizan recomendaciones en el sentido de abordar ciertos aspectos o actividades en proyectos futuros.

2 ANTECEDENTES

El presente capítulo tiene por objetivo ubicar al lector en el entorno en el cual se desarrolla este trabajo de título, entregando los antecedentes previos y necesarios para su contextualización.

2.1 LAS EMOCIONES Y SUS RESPUESTAS FISIOLÓGICAS

Las emociones, tanto las agradables como las desagradables, están directamente relacionadas con la biología. Las respuestas emocionales tuvieron un rol importante en los procesos de adaptación y supervivencia de los seres humanos, por lo que estas respuestas realizadas por las conductas emocionales guiaron en gran parte la evolución del cerebro [9].

A comienzos del siglo XIX, Charles Darwin definió y clasificó ocho emociones básicas, las cuales se observan tanto en los animales como en los humanos: alegría, malestar psicológico, interés, sorpresa, miedo, rabia, disgusto, y vergüenza. En el marco de su teoría de la selección natural postuló que el fenómeno emocional y su expresión están directamente relacionados. Señaló que la expresión facial y el cuerpo son los medios primarios de la expresión emocional, y que tales expresiones son innatas y que provienen de un "programa biológico" que determina la respuesta [5].

2.1.1 CARACTERIZACIÓN BIDIMENSIONAL DE LAS EMOCIONES

El modelo de las emociones más usado incluye dos dimensiones continuas que representan qué tan agradable y qué tan energética es la emoción: Valencia o *valence* que va de agradable a desagradable y Excitación o *arousal* que va desde calmado hasta activado. A estas características además se les asocia procesos de activación metabólica y neuronal, respectivamente [10].

En la figura 1 se observan ejemplos de emociones respecto a estas dimensiones.

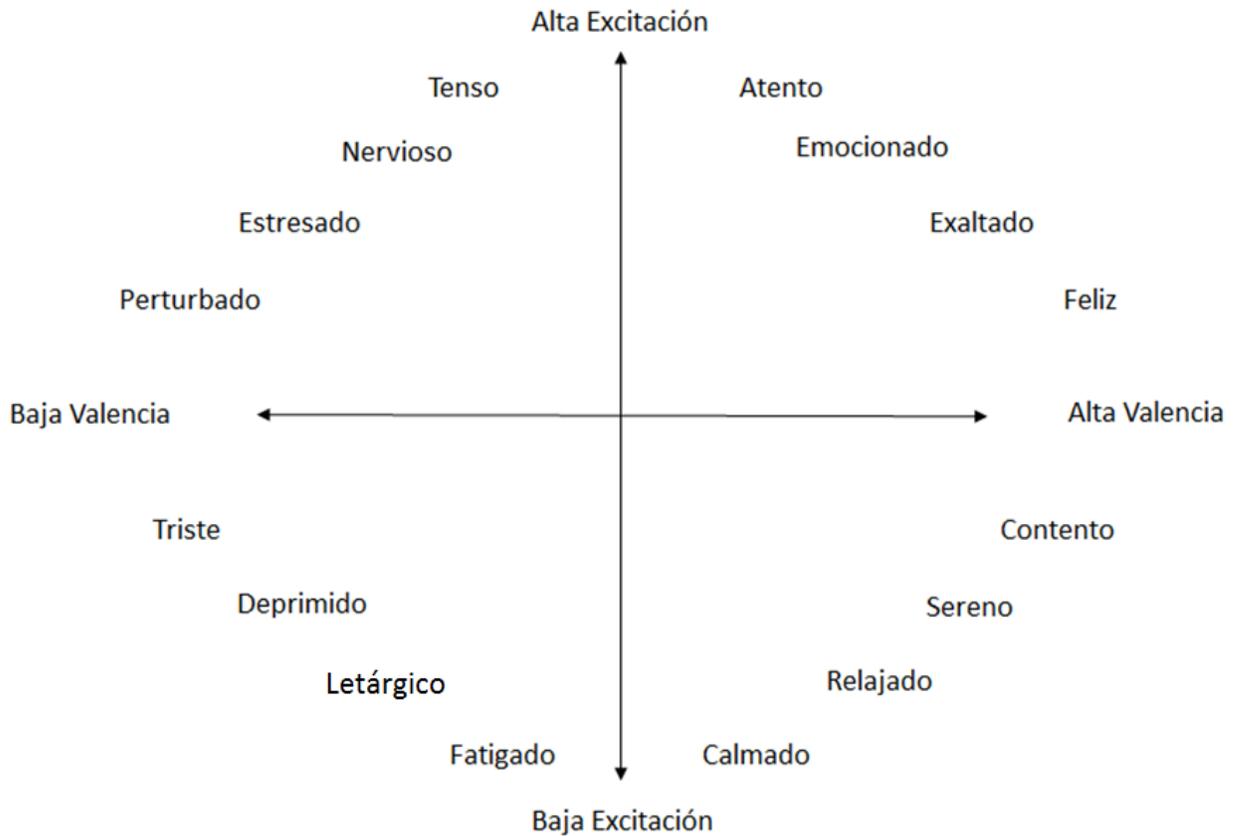


Figura 1. Valencia y excitación. Ejemplos de emociones para distintos niveles de valencia y excitación tomados de [11].

En la figura 2 se describe gráficamente el significado de valencia y excitación bajo la Escala SAM (Self-assessment manikin) [12]. La convención *International Affective Picture System* utiliza esta escala para encuestar personas y así clasificar imágenes a un nivel de valencia y excitación determinado [13].

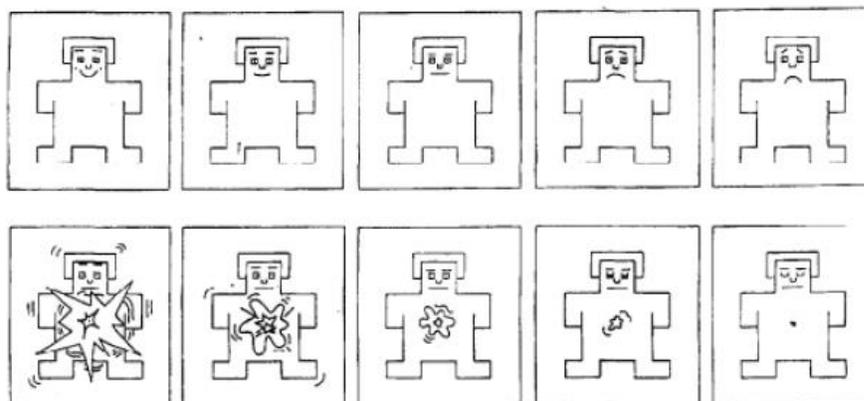


Figura 2. Escala SAM. Gráfico de autoevaluación tomado de un experimento para medir la emoción. Uno puede ver la diferencia entre la valencia (arriba) y la excitación (abajo), tomado de [11].

2.1.2 RESPUESTAS FISIOLÓGICAS EN EL PROCESAMIENTO EMOCIONAL

Las emociones son fenómenos desencadenados por múltiples factores que ejercen una gran influencia sobre el comportamiento de las personas y posibilitan su adaptación [5] [14]. Los procesos emocionales tienen atributos que pueden incluir expresión corporal, sensorial, hormonal, atencional y afectiva [10]. Una emoción es la combinación de un proceso mental de evaluación, donde las respuestas a ese proceso son dirigidas principalmente al cuerpo dando como resultado un estado emocional. Sin embargo, estas respuestas también son dirigidas al cerebro lo cual produce cambios mentales adicionales. De este modo, una emoción sería la respuesta corporal de un proceso de evaluación realizado por el cerebro [15].

Las emociones pueden definirse en términos de respuestas de los sistemas neurales y tales respuestas pueden ser identificadas en virtud del valor que posee tal emoción. Se ha mostrado que existe una relación cercana entre la valencia y la activación de otras respuestas fisiológicas, como la actividad electromiográfica, la frecuencia cardiaca, la conductancia de la piel y los Potenciales Relacionados a Eventos en el cerebro [10].

2.2 NEUROBIOLOGÍA DE LAS EMOCIONES

Se ha mostrado que ciertas estructuras del cerebro participan activamente en procesos emocionales. Estas estructuras conforman al denominado "Sistema Límbico" (figura 3), donde tienen alta participación el hipotálamo y la amígdala. También se ha observado que otras estructuras corticales están involucradas en procesos emocionales, como la corteza frontal [16].

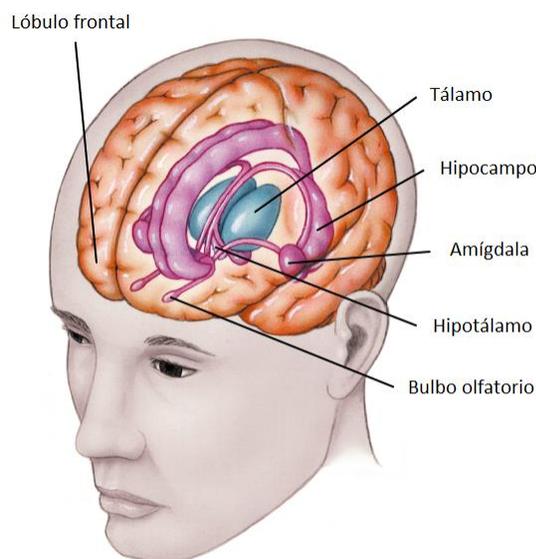


Figura 3. Sistema límbico.
Tomada y traducida de [17].

2.2.1 HIPOTÁLAMO

El hipotálamo es una estructura nuclear del cerebro que actúa como el factor principal de regulación de diversos procesos del cuerpo humano para mantener un estado de homeostasis. Dentro de sus principales funciones se encuentra la regulación de la liberación de hormonas, mantiene la temperatura corporal, y controla las acciones de alimentación, apareamiento y agresión [18].

Se ha postulado al hipotálamo como uno de los actores principales del cerebro en los procesos emocionales [19]. Se mostró que lesiones del hipotálamo anterior en ratas provocan reacciones desorganizadas de ira, y que la estimulación del hipotálamo posterior y de las regiones adyacentes provocan reacciones de ira y ataque, acompañadas de reacciones del sistema simpático (taquicardia, hipertensión, hiperpnea, secreción de adrenalina e inhibición de la motilidad intestinal), por lo que se postuló al hipotálamo como la estructura encargada de la defensa [20]. Sin embargo, ha sido cuestionado el papel del hipotálamo en el inicio de la respuesta de defensa. Por ejemplo, se ha registrado que la inyección de glutamato en el cerebro medio induce una respuesta de defensa, pero al realizar lo mismo en el hipotálamo no se obtiene el mismo resultado, por lo que se sugiere que la respuesta de defensa se encuentra mediada por neuronas efectoras hacia la sustancia gris central provenientes de otras regiones distintas al hipotálamo, particularmente la amígdala. Ante estos antecedentes se le atribuye el inicio al proceso emocional a la amígdala y no al hipotálamo, y que éste es la estructura responsable de los cambios vegetativos que acompañan a la emoción [21].

2.2.2 AMÍGDALA

La amígdala es una estructura compuesta por núcleos de neuronas localizadas en la profundidad de los lóbulos temporales y se le reconoce el procesamiento y almacenamiento de reacciones emocionales como principales funciones [22].

Estudios realizados en monos mostraron que la extirpación bilateral del lóbulo temporal anterior provocaba reacciones de ira, miedo, mansedumbre, hiperoralidad, cambios en los hábitos alimenticios e hipersexualidad [23]. Luego se atribuyó que tal extirpación correspondían a lesiones directas a la amígdala [24].

La amígdala está considerada como una estructura clave para el procesamiento emocional de las señales sensoriales, debido a que recibe proyecciones de todas las áreas de asociación sensorial. Esta convergencia

neuronal sitúa a la amígdala como la estructura responsable para la asociación de los estímulos [25].

Se ha estudiado en humanos la participación de la amígdala en la conducta emocional. La extirpación de la amígdala se ha empleado en humanos con fines terapéuticos, en concreto para reducir la agresividad, violencia e hiperactividad [26]. Tras la extirpación de esta estructura es más difícil provocar miedo y agresividad en el paciente, y aparece un aumento del control emocional [27]. También se ha visto que la lesión amigdalina produce una alteración del reconocimiento de expresiones faciales emocionales, reduciendo la capacidad de los pacientes para identificar tanto la emoción de miedo como su intensidad en imágenes de rostros humanos [4].

Se demostró experimentalmente que durante la visión de imágenes de contenido afectivo agradable, la magnitud de la respuesta de parpadeo reflejo es menor que cuando se está visualizando una imagen de contenido neutro, pero cuando se está visualizando una imagen de contenido afectivo desagradable la magnitud de dicha respuesta es mayor que ante la visualización de imágenes neutras y agradables [28]. También se observó ausencia de la potenciación del reflejo ante estímulos desagradables en un paciente con lesión amigdalina, lo que indica que esta lesión bloquea la potenciación de dicha respuesta ante estímulos negativos, lo que es una prueba más de la participación de la amígdala en el control emocional [29].

En resumen, los estudios realizados con pacientes con lesiones en la amígdala muestran que esta estructura es necesaria para la asociación entre estímulos sensoriales y afecto, una posterior generación de emociones y la identificación de las expresiones faciales emocionales.

2.2.3 CORTEZA PREFRONTAL

La corteza prefrontal corresponde a la parte anterior de los lóbulos frontales del cerebro. Ha sido asociada a procesos de comportamiento cognitivamente complejos, expresión de la personalidad, la toma de decisiones y al comportamiento social circunstancial [30].

Topográficamente se puede dividir en tres regiones: prefrontal dorso-lateral, órbito-frontal y medial. De estas tres regiones la corteza órbito-frontal y la medial son las que se han relacionado de un modo más concreto con la emoción [31]. La región orbito-frontal y medial recibe aferencias de todas las áreas sensoriales [32]. Además la región órbito-frontal recibe una gran cantidad de proyecciones de la amígdala, la región prefrontal medial recibe aferencias del hipocampo y una mayor cantidad de proyecciones sensoriales auditivas [32].

En general se considera que la corteza prefrontal medial es una región relacionada tanto con la experiencia como con la expresión emocional, y es crítica para el procesamiento de emociones asociadas con situaciones sociales y personales complejas [33].

Las personas que poseen una lesión focalizada en la porción orbital lateral suelen presentar incontinencia emocional, impulsividad, irritabilidad, conductas de utilización y de imitación, trastornos del estado de ánimo de tipo depresivo o maníaco, y trastornos obsesivo-compulsivos. Por el contrario, cuando la lesión se focaliza a nivel orbital basal las alteraciones observadas estarían más relacionadas con cambios en conductas sociales, como también presentarían incontinencia emocional e impulsividad [34].

Con respecto a las lesiones de la región frontal medial, estas se han asociado con una disminución de la expresividad facial emocional, tanto fingida como espontánea [35]. Los pacientes con lesiones bilaterales de la corteza prefrontal ventromedial presentan dificultades para anticipar consecuencias futuras tanto positivas como negativas [36].

Otros estudios sugieren que la corteza prefrontal se encuentra implicada en el procesamiento de los estímulos emocionales positivos [37]. Ésto sugiere que la respuesta neuronal ante estímulos emocionales dependería de la integridad de las estructuras frontales, mientras que el procesamiento perceptivo y cognitivo de estos estímulos dependerían de estructuras corticales posteriores [38].

2.2.4 CARACTERIZACIÓN HEMISFÉRICA

Existen diversas hipótesis que consideran que el hemisferio derecho de la corteza cerebral tiene mayor relevancia en el reconocimiento de la información emocional así como para la regulación del estado de ánimo y del afecto, debido a que con medidas electrofisiológicas de la actividad cortical se ha mostrado una mayor activación del hemisferio derecho en distintas condiciones experimentales [39], como también durante la visión de material visual emocional [40] y durante el recuerdo de experiencias emocionales [41].

Otra hipótesis plantea que el reconocimiento y la regulación emocional son bilaterales, pero que el hemisferio derecho tiene mayor relevancia en el procesamiento de las emociones de carácter negativo, mientras que el izquierdo lo está para el procesamiento de las emociones positivas [42]. Sin embargo, se sigue cuestionando tal derivación entre emoción positiva y negativa como base de la asimetría hemisférica, proponiendo en su lugar las dimensiones de aproximación y rechazo. La aproximación conductual (felicidad o ira) estaría relacionada con la actividad de las regiones cerebrales anteriores

del hemisferio izquierdo, mientras que la evitación (miedo o asco) se encontraría asociada con las regiones anteriores del hemisferio derecho. Bajo esta misma hipótesis, se agrega que la región parieto-temporal derecha se encuentra relacionada con la activación emocional [43].

Se ha mostrado que pacientes con daño cerebral en el hemisferio derecho poseen una mayor alteración en el procesamiento emocional en el reconocimiento de expresiones faciales, respecto a pacientes con daño en el hemisferio izquierdo [44].

En adición al planteamiento de que el hemisferio derecho se encontraría implicado en las emociones negativas y el hemisferio izquierdo en las emociones positivas, se sugiere que el hemisferio derecho estaría implicado en la generación de activación emocional provocada por estímulos emocionales, y el hemisferio izquierdo con los procesos de control emocional [45].

2.3 LA ELECTROENCEFALOGRAFÍA Y EL REGISTRO DE ACTIVIDAD BIOELÉCTRICA

Se ha presentado en el punto anterior que existe evidencia sobre diversas estructuras del cerebro que estarían relacionadas con eventos emocionales. Para comprender la actividad bioeléctrica del cerebro se describe en este punto a la neurona, unidad básica del sistema nervioso, y cómo es registrada la actividad de poblaciones de neuronas a través de electroencefalografía.

2.3.1 LAS NEURONAS Y LA GENERACIÓN DE POTENCIALES

Las neuronas son células que forman parte del sistema nervioso, cuyos principales componentes son: el Soma, que corresponde a la estructura central de la neurona que además contiene al núcleo celular, las Dendritas que son extensiones de la célula por la cual se reciben señales desde otras células, y el Axón que es una extensión que sale del soma que permite la comunicación con las neuronas cercanas y, donde se producen los potenciales de acción [46].

En la figura 4 se observa lo que corresponde a un potencial de acción, proceso en que una neurona se activa y sus extensiones quedan cargadas positivamente respecto a su cuerpo central. Tal fenómeno genera una corriente iónica que se desencadena a través de las neuronas. La suma de este

proceso desencadenado en múltiples neuronas permite que sea registrado a nivel de cuero cabelludo [47].

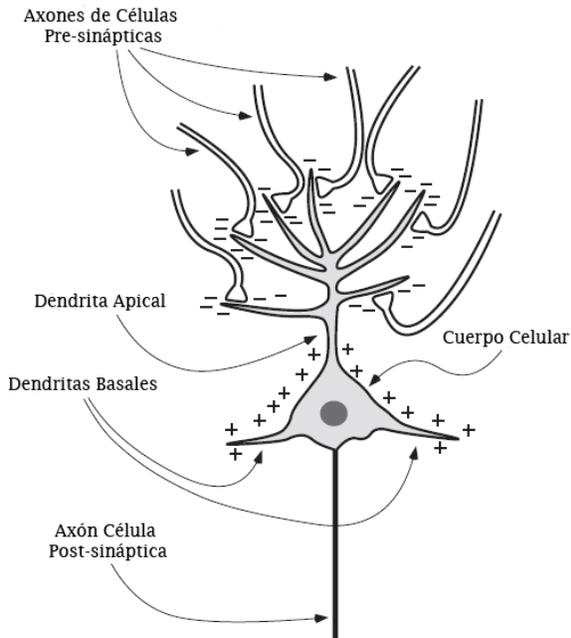


Figura 4. Polarización de una neurona.
Tomada de [48].

2.3.2 ELECTROENCEFALOGRAFÍA

La electroencefalografía (EEG) es un método para medir la actividad eléctrica del cerebro. Consiste en una serie de electrodos que generalmente son situados en el cuero cabelludo, por lo que es no invasivo. El EEG mide específicamente fluctuaciones de voltaje que resultan de la corriente iónica de las neuronas en el cerebro [49].

La ubicación y nombre de los electrodos son especificados por el sistema internacional 10-20 (figura 5). Cada electrodo está conectado a una entrada de un amplificador diferencial y un electrodo de referencia está conectado a la otra entrada de cada amplificador. Ésto para amplificar el voltaje entre el electrodo activo y el de referencia entre 60-100 dB de ganancia [50]. Las señales de EEG son usualmente procesadas con un filtro paso alto con una frecuencia de corte entre 0,5 a 1 Hz para filtrar artefactos lentos como la actividad electrodermal, y uno pasa bajo con una frecuencia de corte entre 35 a 70 Hz para descartar el ruido de alta frecuencia como las electromiografías [49].

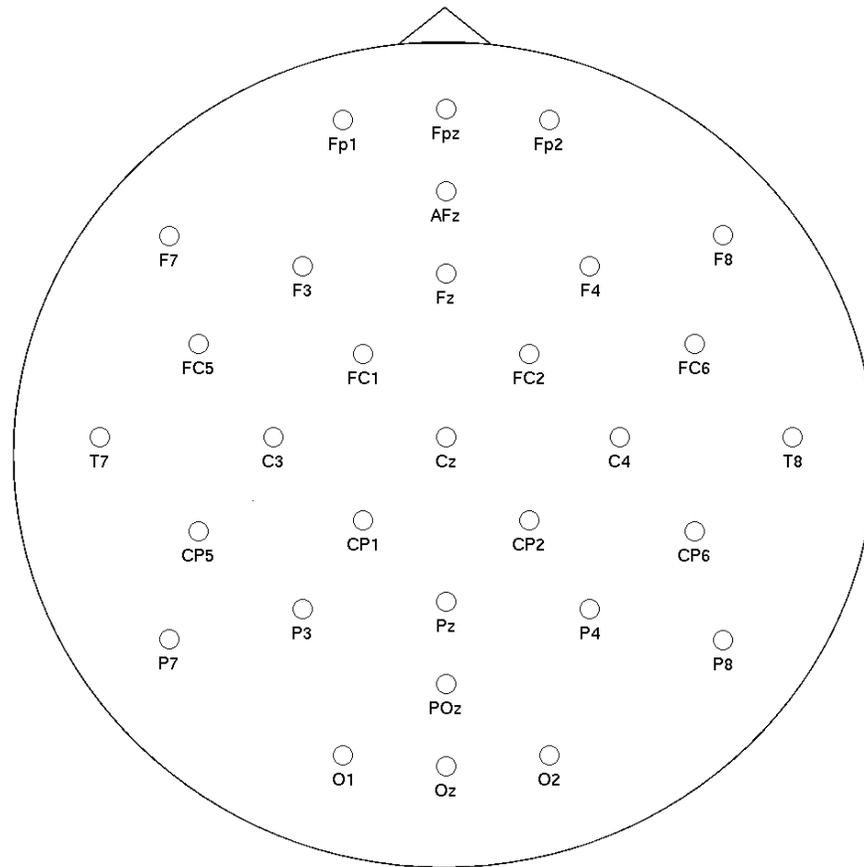


Figura 5. Distribución y etiquetado de electrodos.
Tomada de [51].

2.3.3 POTENCIALES RELACIONADOS A UN EVENTO

Un potencial relacionado a un evento (ERP, de su sigla en inglés *Event Related Potential*) es la respuesta neuronal ante un evento. Se considera como un evento a un estímulo que puede ser de tipo sensorial, motor o cognitivo [48].

Usualmente los ERP son estudiados en EEG a través de promedios de registros de repetidos ensayos para un mismo tipo de evento [52]. Por lo tanto las respuestas emocionales pueden ser estudiadas a través del ERP que generan.

Existe una nomenclatura para definir los potenciales usando las letras para definir los máximos locales, con una P si corresponde a un máximo local positivo y una N para los negativos, seguido de un número que indica la latencia respecto al estímulo, expresada en decisegundos o milisegundos [53]. Por ejemplo en la figura 6, P3 (P300) es el máximo local positivo característico que se muestra en una vecindad temporal alrededor de los 300 ms.

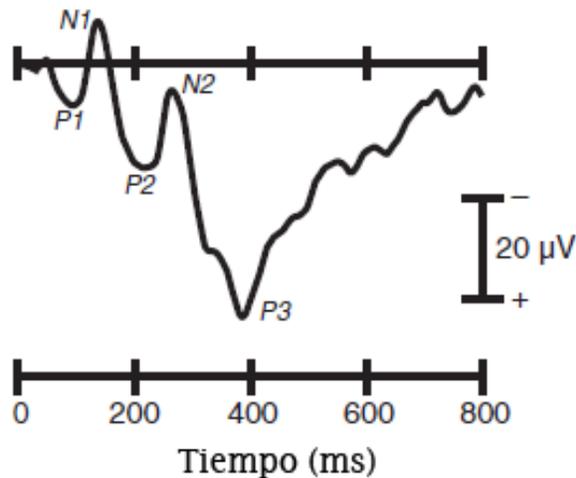


Figura 6. Potencial relacionado a un evento (ERP).
Ejemplo para ERP con su respectiva nomenclatura para identificar los máximos y mínimos locales de interés.
Tomado de [54].

2.3.3.1 POTENCIALES EVOCADOS VISUALES

Un potencial evocado (PE) es un potencial eléctrico del sistema nervioso que aparece luego de un estímulo el cual puede ser medido a través de mediciones electrofisiológicas como el EEG. Las amplitudes de los PE pueden ser bajas ($\sim 1 \mu\text{V}$) respecto a las otras componentes como el resto de la actividad electrofisiológica, otras señales biológicas y ruido general. La gran mayoría del ruido ocurre de forma aleatoria, por lo que el ruido sería minimizado al promediar respuestas repetidas ante un mismo estímulo [55]. Los potenciales evocados visuales (PEV) son PE bajo un estímulo visual, los cuales pueden ser observados inicialmente como cambios de potencial en EEG en la zona occipital (figura 7A) alrededor de los 100 milisegundos, por lo que se denomina P100 (figura 7B) [56].

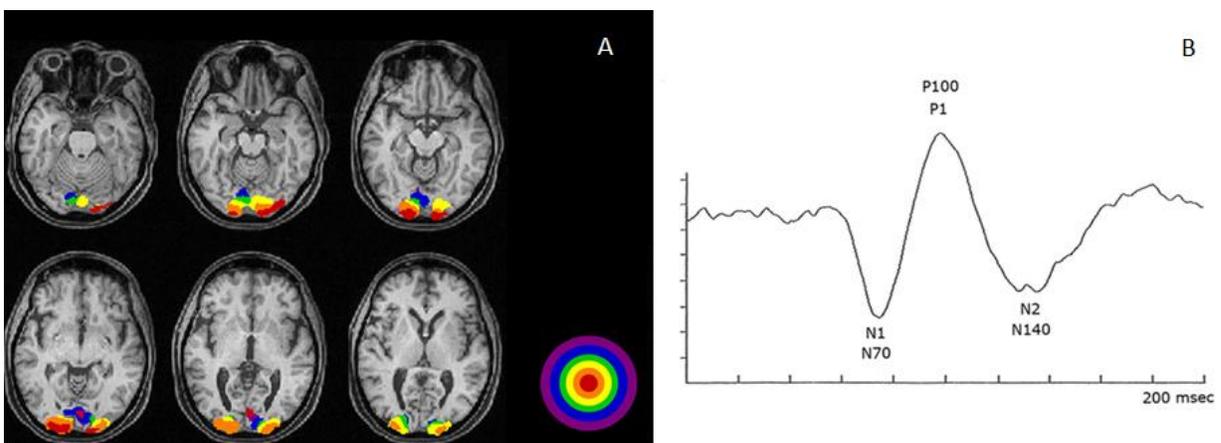


Figura 7. Potencial evocado visual.
Tomado de [57].

2.3.3.2 ONDA P300

La onda P300 es una componente del ERP asociado a procesamiento cognitivo para la evaluación y categorización de un determinado evento. Cuando se registra en EEG se observa como una deflexión positiva de voltaje con una latencia de respuesta desde los 250 a los 500 milisegundos desde que el estímulo fue presentado, tal como se observa en la figura 6 [58].

2.3.4 VENTAJAS Y DESVENTAJAS DE LA ELECTROENCEFALOGRAFÍA

La principal limitación que presenta la electroencefalografía es la baja resolución espacial que posee, debido a que, entre otras cosas, el EEG es más sensible a detectar sinapsis en las capas superficiales de la corteza cerebral y en las crestas de circunvoluciones colindantes directamente radiales al cráneo [59]. Por lo que las estructuras que están más profundas en la corteza tienen mucho menos contribución a la señal EEG que se está midiendo. Por otro lado, las señales EEG registradas corresponden a una combinación de múltiples señales provenientes de miles de neuronas en actividad, por lo que una gran población de células en la actividad sincrónica es necesaria para causar una desviación significativa en las grabaciones. Existen muchas teorías sobre que las redes neuronales del cerebro realizan "backpropagation", proceso en el cual se generaría un máximo de voltaje y este es retroalimentado al otro extremo de la neurona, provocando un dipolo que puede ser grabado por los electrodos EEG [59].

El EEG proporciona información con un sesgo grande para la descripción de la actividad cerebral global, considerando que no se puede determinar con precisión el origen intracraneal de las señales.

El EEG tiene varios puntos fuertes como una herramienta para explorar la actividad cerebral. El primero es su buena resolución temporal debido a que puede detectar los cambios en el orden de los milisegundos, lo cual es conveniente teniendo en cuenta que un potencial de acción tarda entre 0.5 a 130 milisegundos para propagarse a través de una neurona [60]. Existen otros métodos para medir la actividad funcional del cerebro, tales como la tomografía de emisión de positrones (PET) y la resonancia magnética nuclear funcional (fMRI), que tienen una resolución de tiempo del orden de segundos.

El EEG mide la actividad eléctrica del cerebro directamente, mientras que el fMRI mide cambios en el flujo sanguíneo, y el PET mide cambios en la actividad metabólica, que son marcadores indirectos de la actividad eléctrica del cerebro.

Por otro lado, el EEG refleja principalmente la actividad sináptica causada por los potenciales post-sinápticos de las neuronas corticales. Entonces las corrientes iónicas previas que producen los potenciales de acción rápida no contribuyen en gran medida a los registros del EEG [61]. Cabe mencionar además que los potenciales eléctricos medidos en el EEG son generados en gran parte por los cambios iónicos a nivel extracelular. Para medir los cambios iónicos a nivel intracelular es mejor utilizar magnetoencefalografía (MEG) [62].

2.4 ESTADO DEL ARTE DE LA CARACTERIZACIÓN DE EMOCIONES EN EEG

La respuesta en el EEG respecto a las dimensiones de valencia y excitación de las emociones ha sido reportada previamente. Las diferencias en las emociones percibidas por los usuarios han sido descritas en zonas específicas del cerebro, como también para patrones de onda en bandas de frecuencia determinadas. Los procesos relacionados con el reconocimiento de emociones han sido atribuidos a los hemisferios del cerebro, donde se asocia que las regiones frontales izquierda y derecha estarían asociados a respuestas emocionales positivas y negativas respectivamente [63] [64].

Se registró que la disminución en la potencia de la banda alfa (8-12 Hz) disminuía en la región frontal izquierda ante el procesamiento positivo del cerebro, mientras que la potencia de la banda alfa disminuye en hemisferio derecho para emociones negativas [65]. Este tipo de respuestas ha sido reportado para diversos tipos de estímulos, por lo que se considera que tal asimetría en la banda alfa tiene directa relación con el nivel de valencia del estímulo [66] [67] [68] [69].

Otros estudios también han encontrado correlaciones de los niveles de valencia con otras regiones del cerebro y otras bandas de frecuencia, pero de una forma menos robusta. Para el caso de la banda theta (4-7 Hz), se encontraron similitudes en la respuesta respecto a lo indicado anteriormente para la banda alfa, tanto para contenido fotográfico [70] como para oraciones [71].

También se ha reportado diferencias en la respuesta emocional en la banda gamma (>32 Hz). Ante estímulos basados en contenido fotográfico se encontraron diferencias en los lóbulos temporales (figura 8) que se correlacionaban con el nivel de valencia de las fotografías, donde una alta valencia tendía a generar mayor actividad gamma en la región temporal izquierda y menor actividad en la región temporal derecha [40]. Se ha observado también que en general la actividad en la banda gamma aumenta

para estímulos aversivos, los cuales además de tener valencia baja, tienen alta excitación [72].

Otras regiones del cerebro también han presentado correlaciones en su actividad respecto a los estímulos presentados. La zona fronto-medial (figura 8) se ha asociado con procesamiento emocional y atención. En particular se registró que la potencia de la banda theta aumentaba para estímulos musicales positivos en la región fronto-medial [73] y durante meditación [70].

Los electrodos de la línea media de la corteza cerebral han sido reportados en algunos estudios como relevantes en la distinción de estímulos negativos. En la banda theta baja se encontró que la potencia en tales canales aumentaba [74], como también en la banda delta (0-3 Hz) donde se encontró mayor actividad ante estímulos aversivos [75].

Los estímulos con contenido de alta excitación en general producen un aumento en la actividad neuronal global, pero si se analiza la actividad en bandas de frecuencia se puede observar que baja la potencia en la banda alfa [76]. En las regiones posteriores de la corteza cerebral se ha registrado que ante estímulos de alta excitación, aumenta la potencia en bandas de frecuencia bajas como las bandas delta [75] y theta [77], disminuye la potencia en la banda alfa y aumenta en la banda gamma [78].

En cuanto a la banda beta, existe una menor cantidad de hallazgos para la caracterización de emociones. Sin embargo se reportó para en un sistema de reconocimiento de emociones que la banda beta (16-32 Hz) es la que entrega una mayor precisión utilizando el espectro de frecuencia de tal banda de forma general ante estímulos basados en videoclips que inducían cinco tipos de emociones [79].

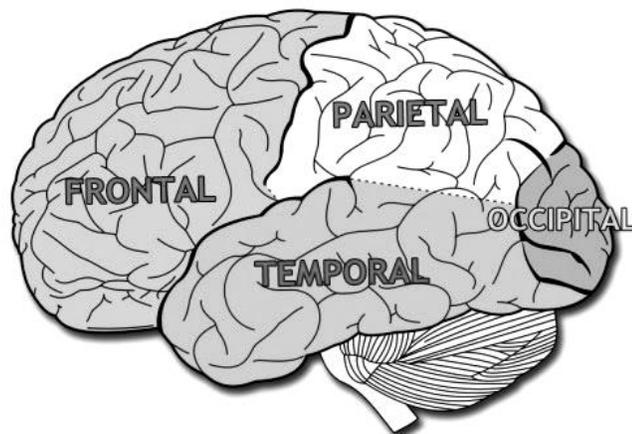


Figura 8. Lóbulos del cerebro.
Tomada de [80].

El análisis de la respuesta emocional también puede ser realizado sobre los ERP en términos de sincronización y desincronización de la respuesta entre distintas zonas del cerebro, como también la latencia y amplitud de la respuesta bajo distintos estímulos emocionales [81] [82].

2.5 MÉTODOS USADOS EN ESTE TRABAJO PARA EL PROCESAMIENTO DE SEÑALES Y EXTRACCIÓN DE CARACTERÍSTICAS

A continuación se presentan los métodos utilizados para el procesamiento de los datos.

2.5.1 FILTROS DE FRECUENCIA

En términos generales, los filtros de frecuencia son metodologías que permiten descartar las componentes de determinadas frecuencias en las series de tiempo.

El principal propósito de aplicación de este tipo de métodos es eliminar el ruido, como también extraer una banda de frecuencias de interés para ser analizada. En particular, en este estudio se utilizan filtros de frecuencia para ambas finalidades.

Los filtros poseen dos tipos de bandas, las bandas de paso y las bandas de rechazo. Las bandas de paso (passband) corresponden a los intervalos de frecuencia en que la ganancia del filtro es alta, de modo que tales frecuencias no sean atenuadas por el filtro. Por el otro lado, en las bandas de rechazo (stopband) la ganancia del filtro es baja, por lo que las frecuencias asociadas son atenuadas por el filtro. En la figura 9 se muestra un ejemplo, donde la banda de paso está entre los 1-30 Hz, las frecuencias menores a 1 Hz y mayores a 30 Hz corresponden a las bandas de rechazo.

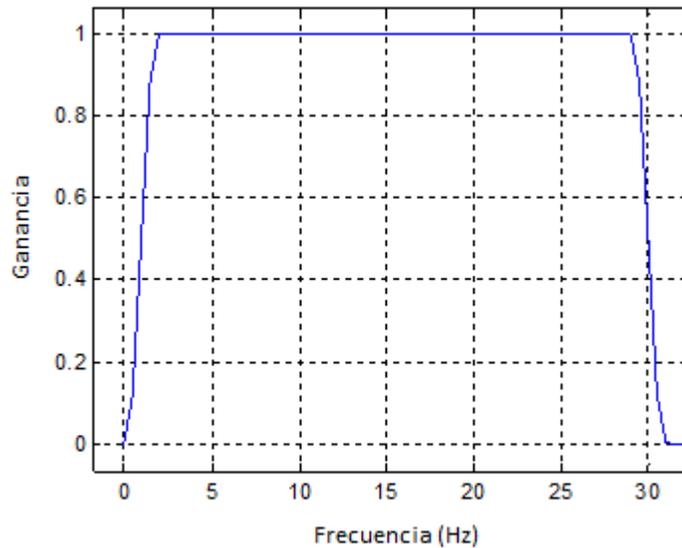


Figura 9. Ejemplo de filtro pasa banda.

El filtro a utilizar en este trabajo es de tipo digital IIR (infinite impulse response) debido a la baja carga computacional que posee, dado que pueden ser implementados con un menor orden de filtro [83]. En particular, se utiliza un filtro Butterworth, los cuales son ampliamente utilizados tanto en aplicaciones EEG como en otras por sus buenos desempeños, debido a que no hay una alteración significativa en las componentes de la banda de paso por lo que no se estaría generando ruido o artefactos [84].

La función de transferencia en función de la frecuencia de un filtro de Butterworth está dada por la siguiente ecuación:

$$|H(\omega)|^2 = \frac{G_o^2}{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}} \quad (1)$$

Donde ω_c es la frecuencia de corte del filtro, n es el orden del filtro, y G_o es la ganancia para $\omega = 0$.

2.5.2 ANÁLISIS DE COMPONENTES INDEPENDIENTES

Análisis de componentes independientes (ICA) es un método que separa una señal multi-variable en componentes aditivas, con el supuesto de que tales señales son estadísticamente independientes entre ellas y que además los valores de las componentes poseen una distribución no gaussiana [85].

Matemáticamente, lo que hace la mayoría de los algoritmos ICA es tomar una señal multi-variable $x = (x_1, x_2, \dots, x_m)$ y obtener una señal de salida de dimensión igual o inferior $s = (s_1, s_2, \dots, s_n)$. Tal transformación se hace computando la matriz W que cumple la relación $s = W x$ (ver ecuación 2 en su forma matricial) y que maximiza la independencia entre las componentes de s . Por lo tanto, cada una de las componentes s_i ($i = 1, \dots, n$) se representa por una combinación lineal de las componentes originales x_j ($j = 1, \dots, m$), es decir: $s_i = w_{i,1} \cdot x_1 + \dots + w_{i,m} \cdot x_m$ [85].

$$(s_1, s_2, \dots, s_n)' = \begin{pmatrix} w_{1,1} & \dots & w_{m,1} \\ \vdots & \ddots & \vdots \\ w_{1,n} & \dots & w_{m,n} \end{pmatrix} (x_1, x_2, \dots, x_m)' \quad (2)$$

La independencia estadística en ICA puede estar dada por alguno de los siguientes criterios:

1. Minimización de la información mutua: La información mutua mide la información compartida entre dos o más variables comparadas de a pares, en otras palabras, mide la incertidumbre sobre una variable en base al conocimiento de otra. Por lo tanto, si se conoce X pero con esto no disminuye la incerteza sobre Y , entonces la información mutua entre X e Y es igual a cero [85].
2. Maximización de la no-gaussianidad: Otra forma de estimar la independencia entre componentes es forzar que las componentes buscadas no sigan una distribución normal. Una forma de medirlo es a través de la Negentropía, que mide la distancia desde la normalidad de una variable [86].

En este trabajo se utiliza un algoritmo ICA que minimiza la información mutua conocido como Run ICA, implementado en Fieldtrip [87], para la extracción de componentes correspondientes a artefactos oculares. A partir de los 32 canales del EEG se buscan 15 componentes independientes.

2.5.3 CLASIFICACIÓN Y APRENDIZAJE SUPERVISADO

La clasificación de patrones es ampliamente utilizada dada su gran diversidad de aplicaciones en la toma de decisiones. En el problema de clasificar objetos se buscan características que predigan la clase a la que pertenece. Para ello se busca encontrar una función que utilice como entrada un vector de características y como salida la clase de pertenencia del objeto.

Por ejemplo, para un problema de clasificación binaria, los objetos están definidos por el par (\vec{x}_i, y_i) donde $\vec{x}_i \in \mathbb{R}^m$ es el vector que contiene m características ($\vec{x}_i = (x_1, x_2, \dots, x_m)$) e $y_i \in \{-1, 1\}$ que define la clase a la que pertenece el objeto [88].

En base a un proceso de aprendizaje supervisado, donde se le presentan al algoritmo una serie de objetos de clase conocida, se ajusta una función que emule una clasificación de todas las muestras.

La construcción y prueba del modelo de clasificación se realiza dividiendo primero los datos en los siguientes conjuntos [88]:

1. Entrenamiento: Con este conjunto se construye el modelo predictivo y se ajustan los parámetros en un modelo adaptativo. Con este conjunto se realiza una validación cruzada dejando un sujeto fuera (leave one out crossvalidation) con el objetivo de evitar el sobreajuste del modelo a un conjunto finito de datos de entrenamiento.
2. Prueba: Este conjunto tiene la porción restante de los datos y no tiene influencia en la construcción del modelo. Se utiliza para estimar el error de generalización y medir la efectividad de la predicción, al comparar la predicción obtenida con el modelo generado y la clase de pertenencia del objeto.

La mayoría de los métodos predictivos construyen sus modelos de clasificación en base al principio de minimización del riesgo empírico, que busca encontrar el mínimo error de estimación sobre los datos de entrenamiento. El problema que tiene tal enfoque es que puede ocurrir un sobreajuste de los datos de entrenamiento, debido a que la función de clasificación fue aprendida en base al ajuste de los datos con los que se construyó y podría no ser una buena generalización para nuevos objetos. El modelamiento del riesgo estructural surge por la necesidad de construir modelos con la capacidad de generalización y así prevenir el problema del sobreajuste. El riesgo estructural tiene dos componentes, la primera es el riesgo empírico y la segunda la capacidad de generalización. Para el ajuste se propone dar una cota superior al riesgo total esperado, medida que se espera sea minimizada lo más posible [89].

2.5.4 MÁQUINAS DE SOPORTE VECTORIAL

Las máquinas de soporte vectorial (SVM, de su sigla en inglés *Support Vector Machines*) son algoritmos que buscan encontrar un hiperplano separador que maximice el margen entre los hiperplanos que se encuentran al borde de cada región a separar. Las regiones a separar corresponden al espacio multidimensional que describe cada una de las clases definidas [88].

Al considerar por ejemplo el problema de separación de dos clases en un espacio de dos dimensiones se puede presentar dos casos. Primero el caso en que las muestras son linealmente separables (figura 10A), donde todas las muestras que corresponden a una misma clase quedan fuera del margen definido por el hiperplano separador, y por consiguiente el error obtenido es cero. Por otro lado, en el caso en que las muestras sean linealmente no separables (figura 10B) se presenta una serie de muestras que se encuentran dentro del margen definido por el hiperplano [89].

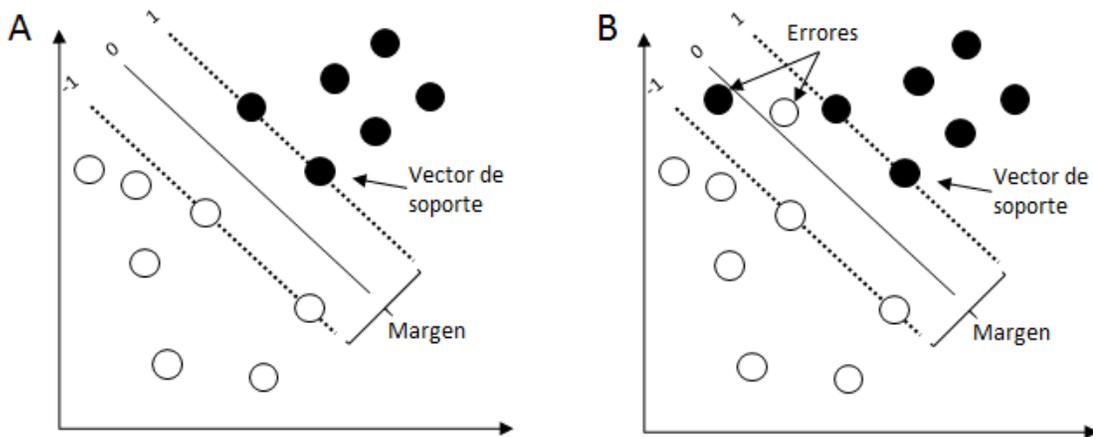


Figura 10. Clasificación binaria con SVM
(A) Caso linealmente separable. (B) Caso linealmente no separable

Considerando que frecuentemente los datos no son linealmente separables, el error resultante debe ser minimizado. La expresión a optimizar por el algoritmo está dada en la siguiente ecuación:

$$\text{Min}_{\vec{w}, b, \xi} \left\{ \frac{1}{2} \|\vec{w}\|^2 + C \sum \xi_i \right\} \quad (3)$$

Sujeto a:

$$y_i (\vec{x}_i \cdot \vec{w} + b) + \xi_i - 1 \geq 0, \quad \forall i$$

$$\xi_i \geq 0, \quad \forall i$$

Donde las variables de decisión son: \vec{w} vector normal al hiperplano separador, b la distancia desde el origen al hiperplano separador, ξ_i variable de holgura que permite que una muestra esté dentro del margen.

Los parámetros de entrada son: \vec{x}_i vector de atributos de un objeto i , y_i clase de pertenencia del objeto i , C penalización de los errores de clasificación.

Las restricciones permiten a cada objeto i estar dentro del margen, permitiendo una holgura. $\xi_i \geq 0$ restringe las variables de holgura a valores mayor o igual a cero, y menor que 1.

Con respecto a la función objetivo a minimizar, la expresión $\frac{1}{2} \|\vec{w}\|^2$ es equivalente a maximizar el margen de separación de clases $2/\|\vec{w}\|$ (donde $\|\vec{w}\|$ es la norma euclidiana de \vec{w}). La minimización de la expresión $C \sum \xi_i$ reduce los casos con holgura ≥ 0 .

Se introduce una transformación del espacio de características con el fin de construir un modelo en los casos que se presentan más muestras respecto al número de dimensiones del espacio de características. Para lo cual se describe a continuación la formulación dual del SVM. Primero se plantea el Lagrangeano de la formulación primal de SVM presentada en la ecuación 3 y posteriormente se verifican las condiciones KKT (Karush - Kuhn - Tucker) [90].

El Lagrangeano (ecuación 4) de la formulación primal de SVM (ecuación 3) es el siguiente:

$$L = \frac{1}{2} \|\vec{w}\|^2 + C \sum \xi_i - \sum \alpha_i \{y_i (\vec{x}_i \cdot \vec{w} + b) + \xi_i - 1\} - \sum \mu_i \xi_i \quad (4)$$

Donde α_i, μ_i son los multiplicadores de Lagrange. Las condiciones KKT de la formulación primal son las siguientes:

$$\frac{\partial L}{\partial w_j} = w_j - \sum \alpha_i y_i x_{ij} = 0 \quad (5)$$

$$\frac{\partial L}{\partial b} = - \sum \alpha_i y_i = 0 \quad (6)$$

$$\frac{\partial L}{\partial \xi_i} = C - \alpha_i - \mu_i = 0 \quad (7)$$

$$y_i (\vec{x}_i \cdot \vec{w} + b) + \xi_i - 1 \geq 0 \quad (8)$$

$$\alpha_i, \xi_i, \mu_i \geq 0 \quad (9)$$

$$\alpha_i \{y_i (\vec{x}_i \cdot \vec{w} + b) + \xi_i - 1\} = 0 \quad (10)$$

$$\xi_i \mu_i = 0 \quad (11)$$

Resolviendo las condiciones de las ecuaciones 5 a la 11 se obtiene lo siguiente:

$$w_j = \sum \alpha_i y_i x_{ij} \quad (12)$$

$$\sum \alpha_i y_i = 0 \quad (13)$$

$$0 < \alpha_i < C \quad (14)$$

$$\mu_i > 0 \quad (15)$$

$$\xi_i \geq 0 \quad (16)$$

$$b = y_i - \vec{x}_i \cdot \vec{w} \quad (17)$$

Con estas relaciones, el problema dual queda de la siguiente forma:

$$\begin{aligned} \text{Max}_{\alpha_i} \left\{ \sum \alpha_i - \sum \alpha_i \alpha_s y_i y_s x_i x_s \right\} \\ \text{Sujeto a:} \\ 0 < \alpha_i < C \\ \sum \alpha_i y_i = 0 \end{aligned} \quad (18)$$

Dado que el problema de SVM es un problema de optimización convexo, las condiciones de KKT son necesarias y suficientes para asegurar una solución del problema primal de SVM que cumpla las condiciones KKT de igual manera. Entonces resolver el problema dual de SVM es equivalente a resolver el problema primal.

Cuando la separación lineal de clases no es posible, como ocurre en la figura 10b, se puede realizar una transformación del espacio de origen. Para esto se calculan los productos punto entre vectores de características, utilizando las funciones de Kernel:

$$K(x, z) = \langle \Phi(x), \Phi(z) \rangle \quad \forall x, z \in X \quad (19)$$

Donde $\langle \cdot, \cdot \rangle$ se define como producto punto, Φ es una función de proyección desde el espacio de origen X hacia el espacio de atributos F

(ecuación 20), en el cual se buscan relaciones lineales en este nuevo espacio (figura 11).

$$\Phi: x \mapsto \Phi(x) \in F \quad (20)$$

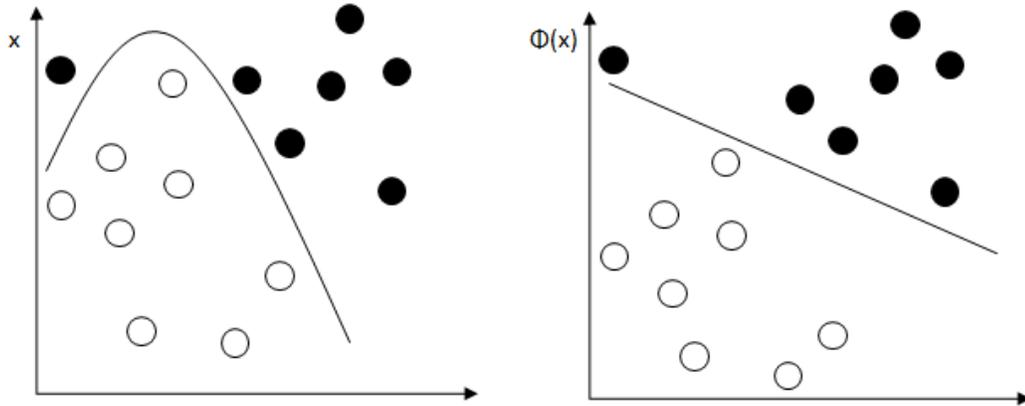


Figura 11. Transformación del espacio original a uno de atributos donde las muestras sean linealmente separable.

Para que una función sea definida como Mercer kernel debe cumplir con que la matriz de kernel (ecuación 21) sea simétrica y semi-definida positiva (todos sus valores propios son mayores o iguales a cero). La matriz de kernel se expresa como sigue:

$$\begin{pmatrix} k(x_1, x_1) & \cdots & k(x_1, x_l) \\ \vdots & \ddots & \vdots \\ k(x_l, x_1) & \cdots & k(x_l, x_l) \end{pmatrix} \quad (21)$$

Las funciones kernel que existen son diversas, de las cuales las más usadas son:

- Lineal: $K(x, z) = \langle x, z \rangle$
- Polinomial de grado d : $K(x, z) = (\langle x, z \rangle + 1)^d, d \in \mathbb{N}$
- Gaussiano: $K(x, z) = e^{-\frac{\|x-z\|^2}{2\sigma}}, \sigma > 0$

La formulación dual de SVM utilizando una función kernel es la siguiente:

$$\begin{aligned} & \text{Max}_{\alpha_i} \{ \sum \alpha_i - \sum \alpha_i \alpha_s y_i y_s K(x_i, x_s) \} & (22) \\ & \text{Sujeto a:} \\ & 0 < \alpha_i < C \\ & \sum \alpha_i y_i = 0 \end{aligned}$$

Dentro de las ventajas que se pueden mencionar para SVM es que existe una dependencia explícita en los vectores de los márgenes, lo que permite generalizar de mejor forma frente a nuevos objetos, dado que considera el principio de Minimización del Riesgo Estructural. Los vectores de soporte se construyen en base a una función convexa, de modo que se asegura la obtención de un óptimo global y permite la construcción de su formulación dual. Otra gran ventaja es la capacidad de modelar fenómenos no lineales mediante el uso de una transformación del espacio de origen a uno de mayor dimensión [89].

Por el otro lado, SVM también presenta limitaciones. Al trabajar con datos numéricos es necesario transformar los atributos nominales a un formato numérico. No existe una función kernel que sea mejor que todas. El uso de distintas funciones de kernel puede determinar diferentes soluciones, por lo que esto se debe determinar para resolver cada problema en particular [89].

2.5.5 RANDOM FORESTS

Random Forests o bosques aleatorios es una metodología basada en una serie de árboles de decisión, donde cada uno de estos es capaz de generar una respuesta ante un conjunto de valores de entrada [91]. En un problema de clasificación la respuesta es la clase a la que es miembro el objeto presentado. En un problema de regresión las respuestas se promedian para obtener un estimado de la variable dependiente [91].

Random Forests inicia con cada uno de sus árboles de decisión, donde los valores de entrada se ingresan a la raíz del árbol y mientras van avanzando los datos por la ramas del árbol, se van clasificando en conjuntos cada vez más pequeños. En un árbol de decisión cada nodo interno está etiquetado con una característica de entrada y los arcos que vienen de un nodo son nombrados con todos los valores posibles de la característica. Finalmente, cada hoja del árbol es etiquetada con una clase o una probabilidad asociada respecto a las clases. La figura 12 muestra un ejemplo de árbol de decisión para clasificar frutas.

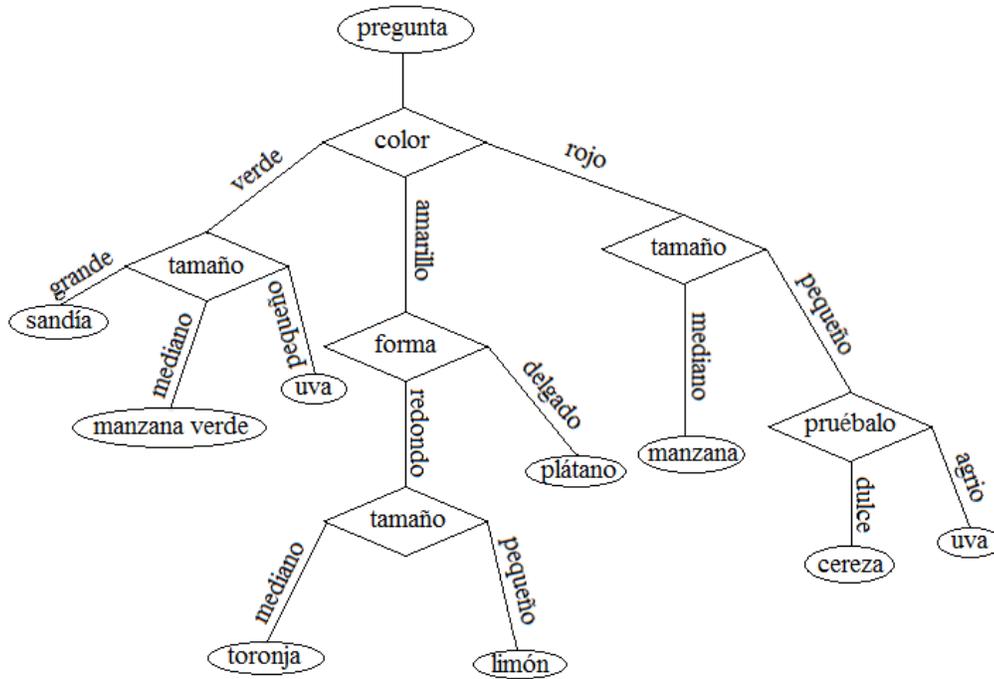


Figura 12. Ejemplo de un árbol de decisión para clasificar frutas.
Tomado de [92].

Un árbol se entrena separando el conjunto de objetos en subconjuntos basados en el valor de alguna de sus características. El proceso se repite en cada subconjunto hasta que todo el subconjunto en algún nodo tiene el mismo valor que la variable objetivo, o bien cuando el conjunto ya no agrega valor a las predicciones.

Debido a que los árboles de decisión son fáciles de calcular, pero no clasifican tan bien, se les llama clasificadores débiles. Sin embargo, al construir un clasificador a partir de varios clasificadores débiles se obtiene un clasificador fuerte. Para hacer el ensamble de los clasificadores débiles se tiene diversas estrategias, donde la más usada es el Bagging [93].

Bagging es una técnica para entrenar cada clasificador débil con un conjunto de datos diferente con el fin de diversificar la respuesta de cada uno. Cada árbol por separado se sobreentrena por el hecho de recibir pocas entradas y se construyen a su medida. Sin embargo el bosque completo es un buen estimador.

La decisión de cada árbol se obtiene examinando cada variable de entrada y eligiendo el umbral de separación. Random Forests selecciona un conjunto aleatorio de variables de entrada para cada corte. El número de variables a considerar en cada árbol por defecto es la raíz cuadrada del total de entradas disponibles. Este método hace que los árboles encuentren formas

alternativas de predecir la variable objetivo. Además evita las correlaciones entre los árboles, con el fin de reducir la varianza del error.

Una vez realizado el ensamble se introducen variables desconocidas a través de cada árbol y se obtiene una clase o nodo final en el árbol.

Dentro de las ventajas que presenta Random Forests respecto a otros clasificadores como SVM es que el algoritmo puede lidiar con una gran cantidad de muestras, y con una gran cantidad de características para cada uno, es decir, es computacionalmente más escalable. El método además es muy robusto, por lo que si dentro de las entradas se tiene un objeto con características atípicas, no debería de verse muy afectado el modelo [94].

En cuanto a las desventajas se ha observado que Random Forests se sobreajusta en ciertos grupos de datos con tareas de clasificación muy ruidosas [93]. Cuando los objetos poseen grupos de características que se encuentran correlacionados, se correlacionan además los árboles que utilizan tales características. Tal efecto incrementa la tasa de error final y además se produce una mala estimación de la relevancia de las características [95]. El algoritmo no resuelve del todo bien problemas en donde los datos incluyen características que contienen varias categorías, debido a que Random Forests tiende a parcializar a favor de las características con más niveles [96].

3 METODOLOGÍA

3.1 ADQUISICIÓN DE LOS DATOS

La base de datos proviene del Grupo de Investigación en Neurociencia Computacional liderado por el profesor Marc Van Hulle del Laboratorio de Neurociencia Computacional del Departamento de Neurociencias de la Universidad Católica de Lovaina (KU Leuven) en Bélgica.

El equipamiento utilizado es un sistema EEG Biosemi de 32 canales, como el que se muestra en la figura 13. La adquisición de los datos fue realizada a nueve sujetos bajo estímulos visuales con una frecuencia de muestreo de 2 kHz.



Figura 13. Sistema de electroencefalografía Biosemi.
Tomado de [97].

Los estímulos visuales consisten en imágenes clasificadas por el Sistema IAPS (International Affective Picture System). Específicamente son 90 imágenes, donde 30 son marcadas como positivas, 30 como negativas y 30 como neutrales de acuerdo a sus valores de valencia y excitación, mostrados en la figura 14.

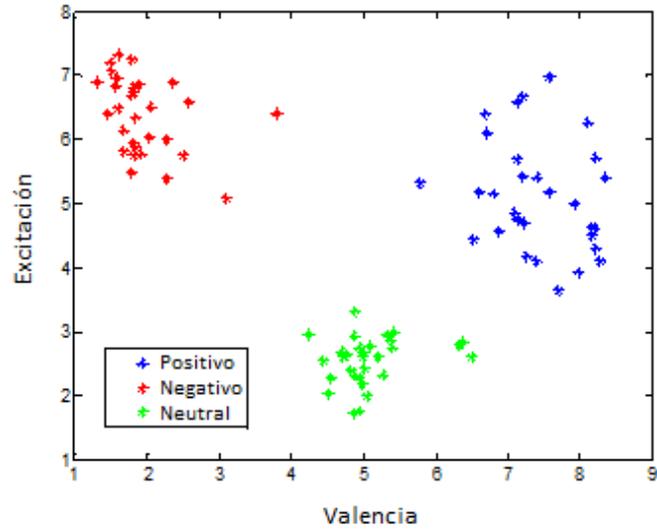


Figura 14. Valores de valencia y excitación para las imágenes utilizadas

El procedimiento experimental, ilustrado en la figura 15, consiste en presentar cada estímulo de forma aleatoria por aproximadamente tres segundos. Consecutivamente tras cada imagen se presenta otra imagen con los píxeles desordenados por tres segundos. El motivo de presentar las imágenes así es que la respuesta neuronal del usuario para un estímulo dado no sea afectada por el estímulo anterior.

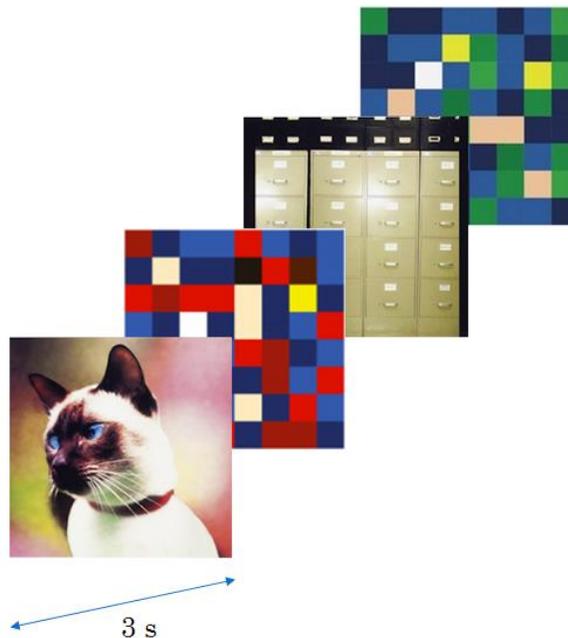


Figura 15. Procedimiento experimental de estimulación visual. Imágenes tomadas de [98].

Tal procedimiento se realiza para un total de 30 imágenes positivas, 30 imágenes negativas, 30 imágenes neutras y 90 imágenes con los píxeles desordenados. La duración total de la presentación de imágenes tiene una duración aproximada de 15 minutos.

3.2 PRE-PROCESAMIENTO

El pre-procesamiento de los datos tiene la finalidad de eliminar el ruido presente en las señales registradas por el EEG. El pre-procesamiento completo de los datos fue realizado con el toolbox Fieldtrip para Matlab [87].

Primero se aplica a las señales un filtro de frecuencia pasa banda. Específicamente consiste en un filtro de frecuencia IIR (Infinite Impulse Response) Butterworth de tercer orden, para la banda 1 – 40 Hz como se muestra en la figura 16.

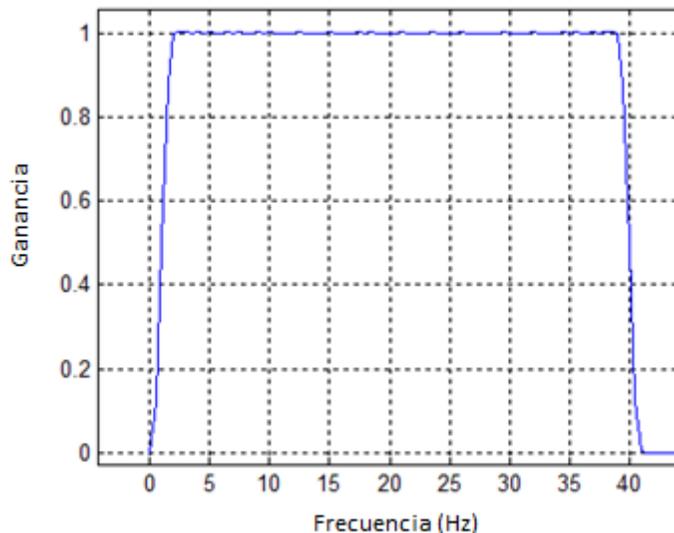


Figura 16. Banda de paso del filtro utilizado (1-40 Hz).

Luego las señales son re-muestradas de 2kHz a 256 Hz y re-referenciadas al canal central Cz. El re-muestreo se realiza para disminuir el costo computacional del posterior procesamiento de las señales. El re-referenciado se realiza para eliminar el ruido que se encuentra correlacionado en todos los canales del sistema, tal como se muestra en la figura 17.

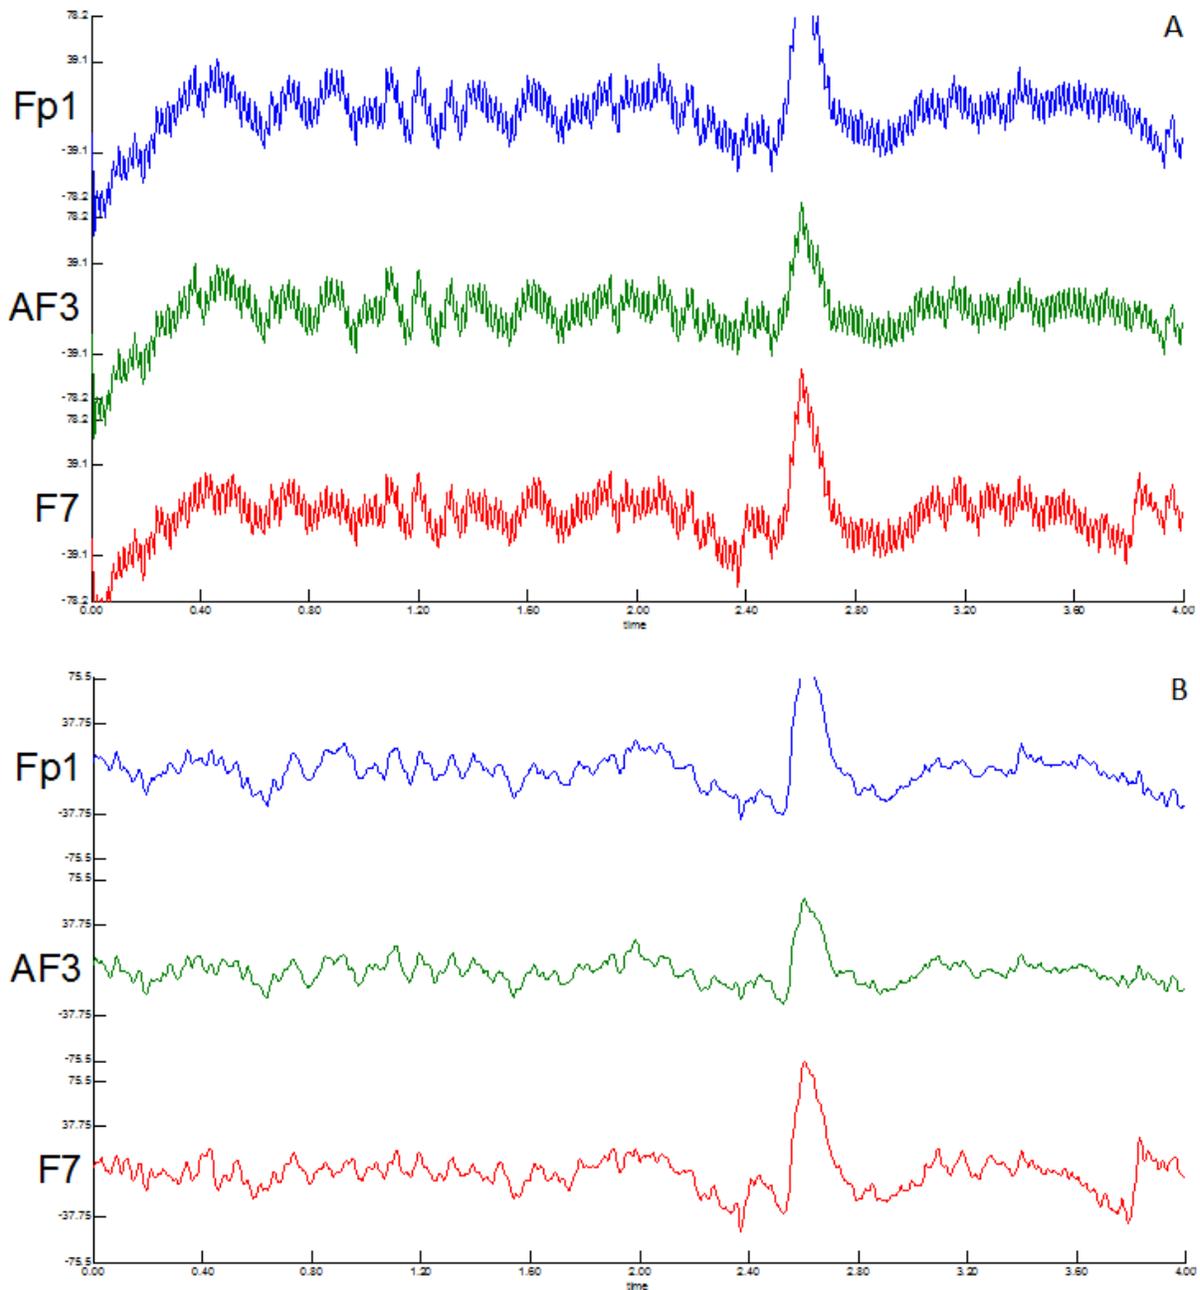


Figura 17. Efecto del re-referenciado de los canales.
 (A) Antes de re-referenciar. (B) Después de re-referenciar

3.3 DETECCIÓN Y REPARACIÓN DE CANALES DEFECTUOSOS

Para esta etapa se utilizó la herramienta de detección y reparación Automated EEG Repair Tool [99]. En la figura 18 se presenta un ejemplo de un canal defectuoso. En el gráfico se presentan todos los canales de un EEG superpuestos uno sobre otro. Se puede notar que el canal marcado con color verde que posee en cierto intervalo de tiempo amplitudes mucho más altas

que el resto de los canales. Por lo que a simple vista, ese canal es defectuoso y debe ser extraído para el posterior análisis de los datos.

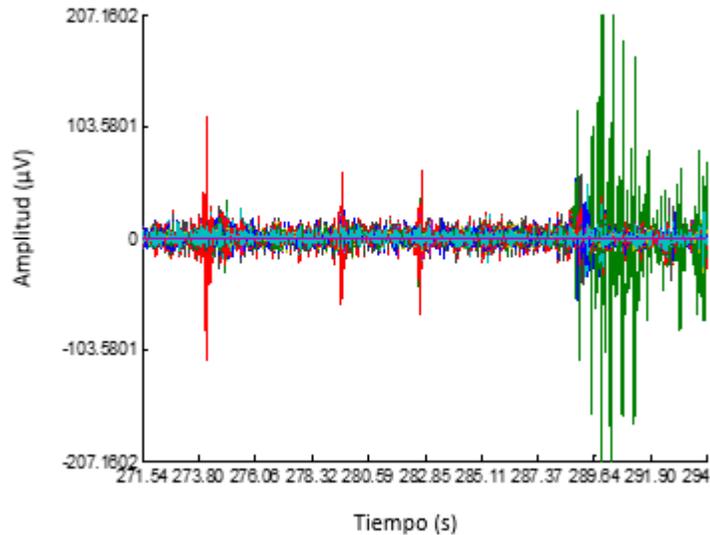


Figura 18. Ejemplo de canales defectuosos.

El siguiente procedimiento es realizado exclusivamente para detectar canales defectuosos en cada ensayo, es decir, las señales no son modificadas.

1. Si algún valor absoluto en cualquier punto está por sobre los 300 μV , el canal es marcado como contaminado, solo para ese ensayo.
2. Cada canal es normalizado con la siguiente expresión:

$$X_s = \frac{X - \mu}{\sigma}$$

Donde X_s es la señal resultante, X es la señal original, μ es la media del canal y σ es la desviación estándar del canal, ambos para un mismo ensayo. Por lo tanto, cada muestra en el canal es representada por su valor estándar.

3. Para cada canal normalizado en unidades de varianza, se calcula la distancia euclidiana de la media de la matriz de ensayos normalizados. Esto se traduce en un número que describe la distancia total del canal respecto a la media de la matriz completa de ensayos
4. Para cada ensayo, se estima la densidad de probabilidad de las muestras en el canal. Para el cálculo de la densidad de probabilidad se toman 100 puntos que cubren el rango completo de la señal de entrada. Se presume que las distancias euclidianas de los canales limpios normalizados siguen una curva de Gauss, es decir, las distancias de los

canales limpios respecto a la media siguen una distribución normal. Alternativamente, se presume que la distancia desde la media de los canales defectuosos se desvían de la distribución de Gauss que siguen los canales limpios. Esto se debe al hecho de que los datos deben ser registrados cuidadosamente con respecto a la impedancia de los electrodos.

5. Para estimar una curva de Gauss, se detecta el máximo de la densidad y la curva del lado izquierdo del máximo es reflejada en el lado derecho (figura 19). Para determinar cuáles canales están contaminados, se marcan los canales que estén más lejos que el fin de la curva reflejada.

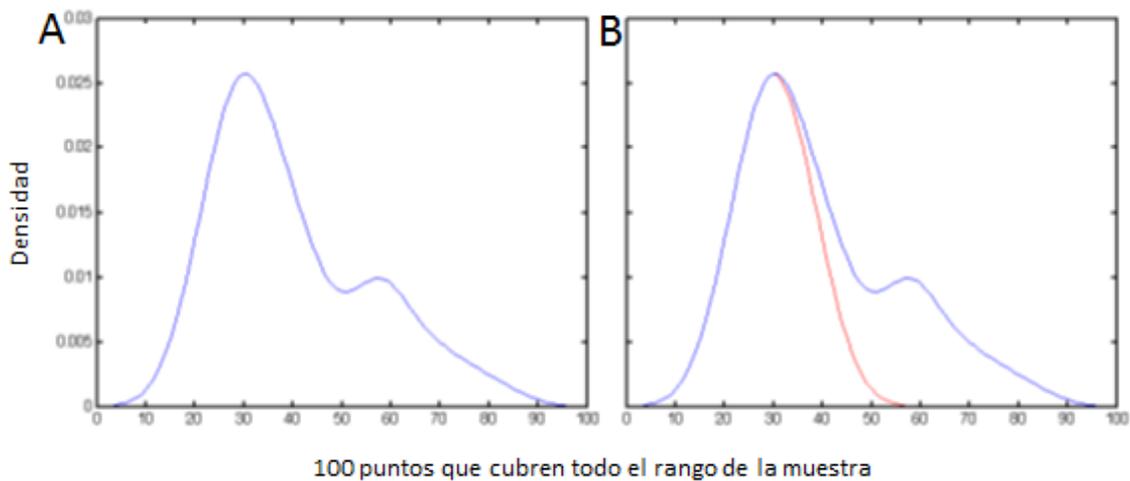


Figura 19. Densidad de probabilidad de un ensayo.

(A) Estimación de la densidad de probabilidad de un canal para un ensayo.

(B) Ilustración de una curva gaussiana en base a la reflexión del lado izquierdo del máximo local.

Para reparar los canales defectuosos se hace una reconstrucción de estos mismos con el promedio de sus vecinos, ponderados por su respectiva distancia al canal defectuoso. Primero se define la estructura de canales vecinos de cada canal y cada ensayo, debido a que no se puede reparar múltiples canales defectuosos que estén cerca entre sí. Para esto se modifica la estructura de vecinos en cada ensayo, para que así ningún canal que necesita reparación tenga asignado vecinos que también deban ser reparados.

3.4 DETECCIÓN Y EXTRACCIÓN DE ARTEFACTOS OCULARES

El Análisis de Componentes Independientes (ICA) es un método para separar señales con múltiples canales en subcomponentes aditivas [86]. El método busca componentes que entre si sean estadísticamente independientes y además que sean no gaussianas. El algoritmo RUN ICA implementado en Fieldtrip [87] fue usado en esta etapa.

El número de componentes independientes a encontrar en todos los sujetos es quince, considerando una estimación bajo el supuesto de que cada lóbulo del cerebro presenta un componente, sumado a la posible presencia de artefactos. En general esta cantidad de componentes mostró un buen desempeño en los sujetos disponibles para detectar artefactos oculares.

Para cada componente encontrada se obtiene además su distribución espacial a través del cuero cabelludo. Las alteraciones generadas por movimientos de los ojos pueden ser visualizadas en registros de EEG y estas se encuentran concentradas principalmente en los canales ubicados en la zona frontal anterior y frontal polar, tal como se puede observar en la figura 20.

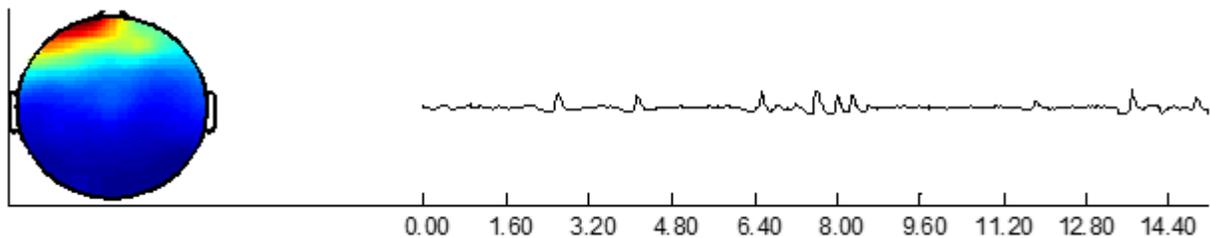


Figura 20. Componente obtenida a través de ICA que contiene artefactos oculares

Las componentes que corresponden a los artefactos oculares son marcadas bajo tres criterios:

1. La topografía de la componente debe estar concentrada en los canales ubicados en el lóbulo frontal.
2. Debe visualizarse de forma clara y limpia en la componente las oscilaciones de voltaje correspondiente a movimientos oculares o parpadeos.
3. La distribución de la componente en el espectro de frecuencia debe estar principalmente concentrado en bajas frecuencias, tal como se muestra en la figura 21.

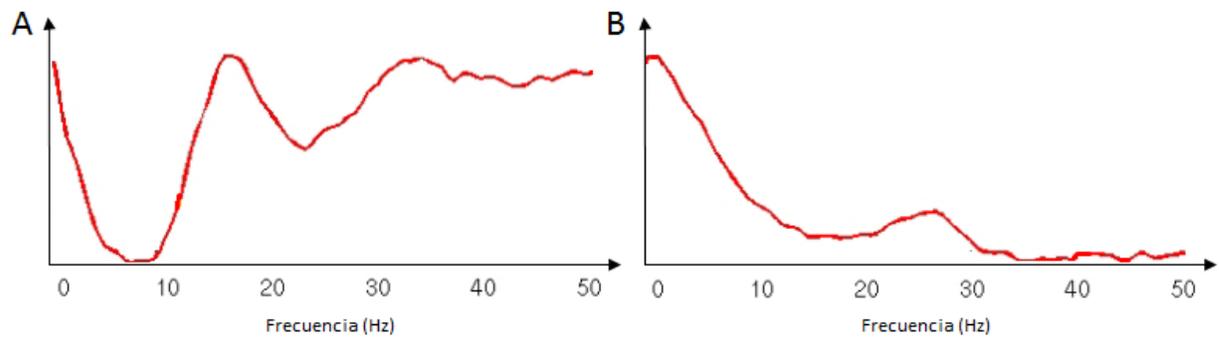


Figura 21. Espectro de potencia de una componente con artefactos no oculares (A) y una componente con artefactos oculares (B).

Finalmente los 32 canales son reconstruidos utilizando la combinación lineal definida por el algoritmo ICA de las componentes independientes encontradas. Para esta etapa se descartan las componentes que corresponden a los artefactos oculares.

En la figura 22 se presenta el canal FP_1 antes y después del proceso de extracción de las componentes oculares. En el gráfico superior se observa la señal que posee un máximo local cercano a los 121.6 segundos, que correspondería a un parpadeo. En el gráfico inferior se ve al mismo canal, pero sin las oscilaciones que corresponden a los parpadeos, producto de la reconstrucción.

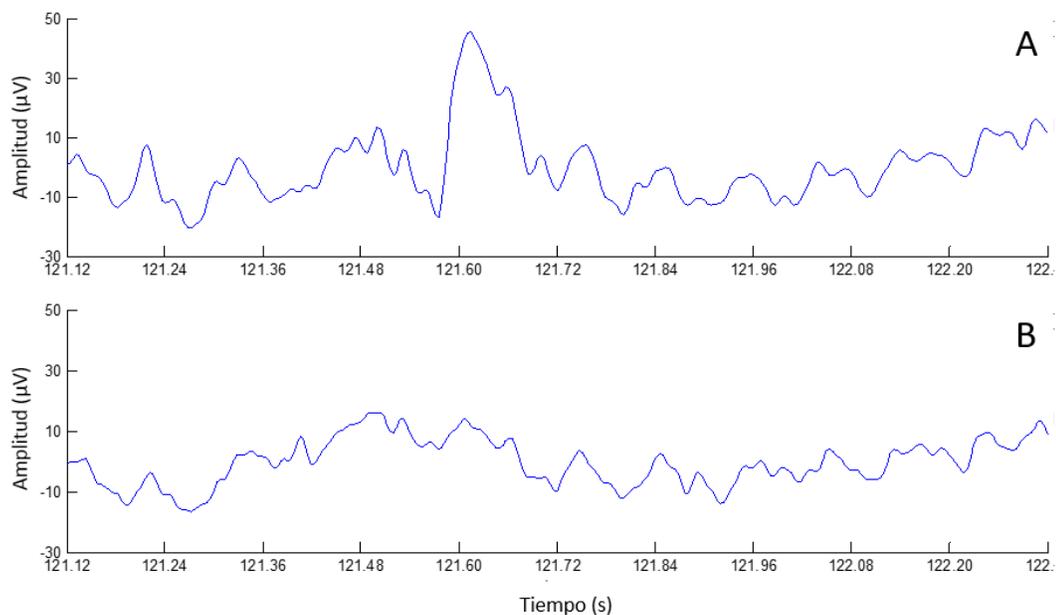


Figura 22. Reconstrucción del canal FP_1 sin componentes oculares. (A) Señal antes de extracción de artefactos. (B) Señal después de extracción de artefactos.

3.5 EXTRACCIÓN DE ÉPOCAS Y PROMEDIACIÓN

Las señales son marcadas en los instantes de tiempo en que se presenta el estímulo visual. Todas las épocas de un sujeto que corresponden al mismo estado emocional son promediadas entre el inicio hasta un segundo después de la marca realizada. Esto se hace para cada canal y para cada sujeto. Por lo tanto para cada uno de los nueve sujetos se obtienen un registro de 32 canales para la emoción positiva, otro para la negativa y uno para la neutral.

Este procedimiento es realizado para destacar los patrones de onda correspondientes a la respuesta emocional, considerando que el desfase de un potencial evocado visual entre diferentes sujetos y estímulos no es mayor a los 15 ms [57]. Si este paso y los anteriores son realizados de forma correcta, es de esperar un máximo local en alguno de los canales del lóbulo occipital a los 100 milisegundos, lo cual corresponde a un potencial evocado visual (figura 23).

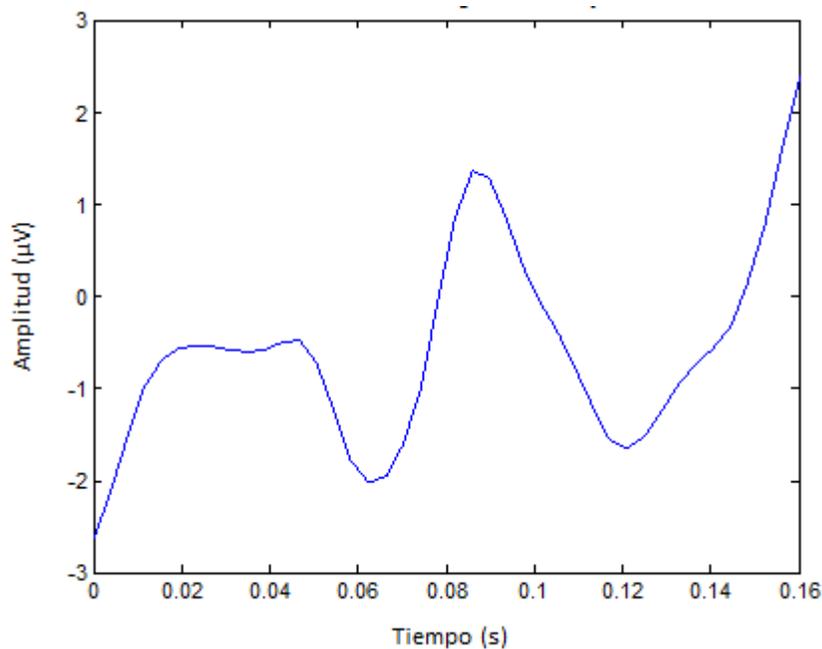


Figura 23. Potencial evocado visual en el canal O1

Consecutivamente, las señales son normalizadas para cada canal de forma individual. Donde un valor cero corresponde a la línea base de la señal, y un valor igual a uno corresponde a los valores que se encuentran a una desviación estándar por sobre la línea base [100].

El objetivo de normalizar las señales es escalar el conjunto de datos para que sean comparables entre sujetos, debido a que la amplitud de las señales

es diferente desde su medición. En la figura 24 se observa el mismo potencial evocado visual después de que se normalizó, se puede apreciar que solo cambia la escala de la señal, pero no su forma.

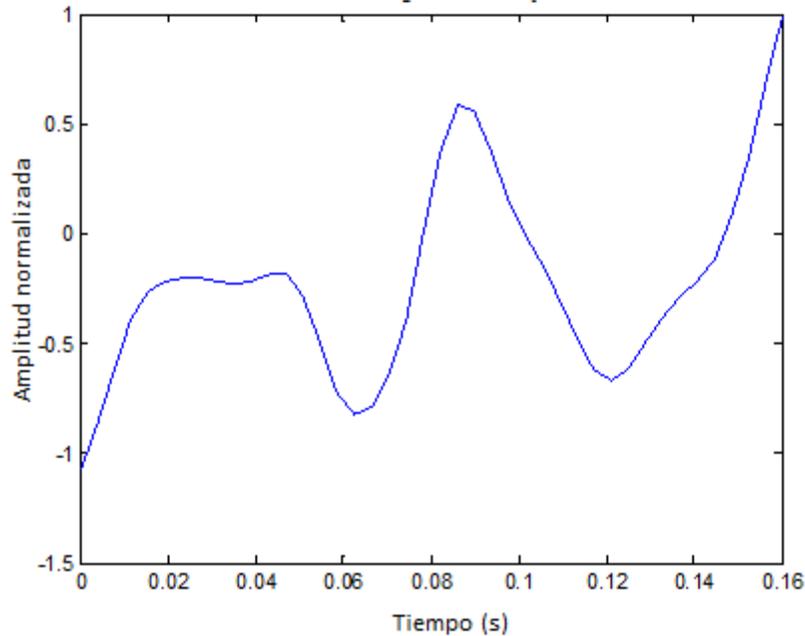


Figura 24. Efecto de normalizar un potencial evocado visual

3.6 EXTRACCIÓN DE BANDAS DE FRECUENCIA

Todas las señales son separadas en nueve bandas de frecuencia, mostradas en la tabla 1, las cuales están basadas en [78] con pequeñas diferencias.

Tabla 1. Bandas de frecuencia

Nombre de la banda	Rango de frecuencia [Hz]
δ (delta)	1 - 4
θ_1 (theta bajo)	4 - 6
θ_2 (theta alto)	6 - 8
α_1 (alfa bajo)	8 - 10
α_2 (alfa alto)	10 - 12
β_1 (beta bajo)	12 - 18
β_2 (beta medio)	18 - 22
β_3 (beta alto)	22 - 30
γ (gamma)	30 - 40

Cada una de las señales del conjunto de datos es descompuesta como se muestra en la figura 25 de acuerdo al procedimiento explicado en la sección 2.5.1, donde se tomó la señal pre-procesada y se le aplicó un filtro pasa banda a cada canal para cada una de las bandas de frecuencia indicadas.

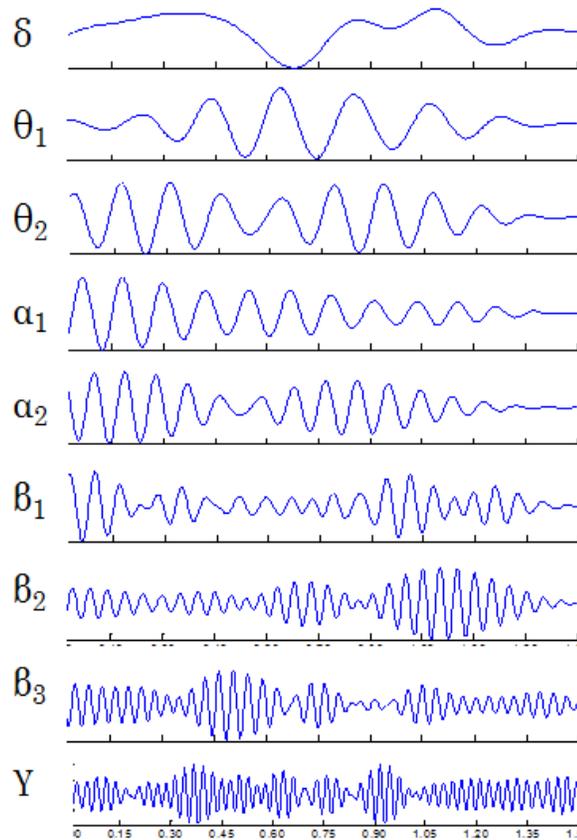


Figura 25. Bandas de frecuencia de una señal

3.7 SELECCIÓN DE CARACTERÍSTICAS

Se realizó un análisis multi-variable a seis de los nueve sujetos para seleccionar las características relevantes en la discriminación de estados emocionales. Los tres sujetos restantes son utilizados como conjunto de prueba para calcular la significancia estadística de separación de las características seleccionadas previamente.

El análisis multi-variable es realizado a través del algoritmo de separación lineal de Máquinas de Soporte Vectorial (SVM) implementado en Fieldtrip [87]. Para seleccionar las entradas al SVM se tiene una ventana deslizante de 10 muestras temporales (40 milisegundos aproximadamente) que recorre todos los canales desde el instante en que se presentó el estímulo

hasta un segundo después para una misma banda de frecuencia, tal como se muestra en la figura 26. Por lo que finalmente, para cada entrenamiento se ingresan 320 entradas (10 muestras de la ventana de tiempo para cada uno de los 32 canales).

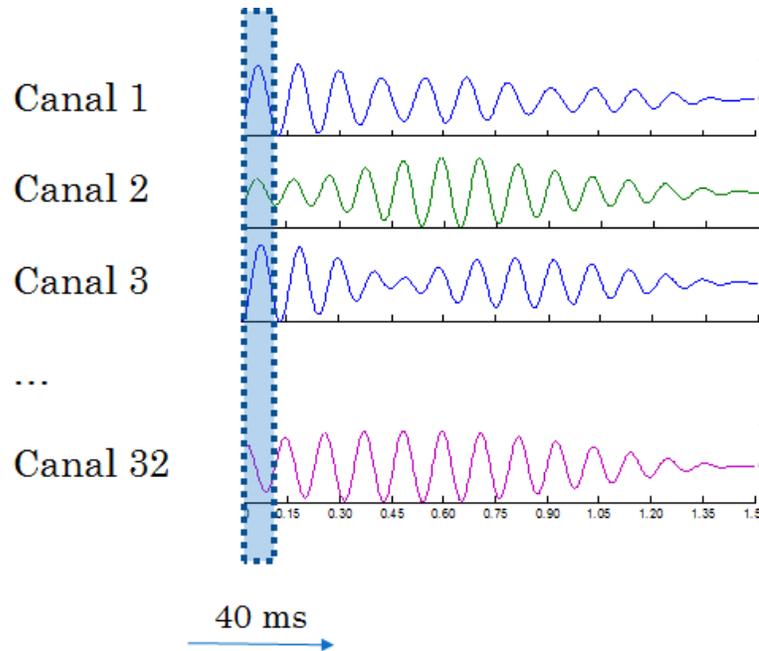


Figura 26. Ejemplo de las entradas usadas a través del tiempo para el SVM en la banda alfa baja

El análisis descrito es realizado entre pares de emociones (positivo-negativo, positivo-neutral y negativo-neutral) con el objetivo de encontrar las características que permiten discriminar entre distintos niveles de valencia y excitación. El paso de deslizamiento de la ventana de tiempo es de una muestra, por lo que el resultado obtenido es un continuo para el valor de precisión en cada instante de tiempo.

En la figura 27 se muestra un ejemplo, donde fue analizada la banda de frecuencia β_2 comparando los estados emocionales positivo y negativo. Cada punto del gráfico corresponde a la precisión obtenida en el conjunto de entrenamiento, luego de realizar una validación cruzada, para clasificar los dos estados emocionales utilizando como entradas la información de los 32 canales del EEG en el intervalo de tiempo de 40 milisegundos, centrado en el correspondiente instante de tiempo presentado en el eje X del gráfico.

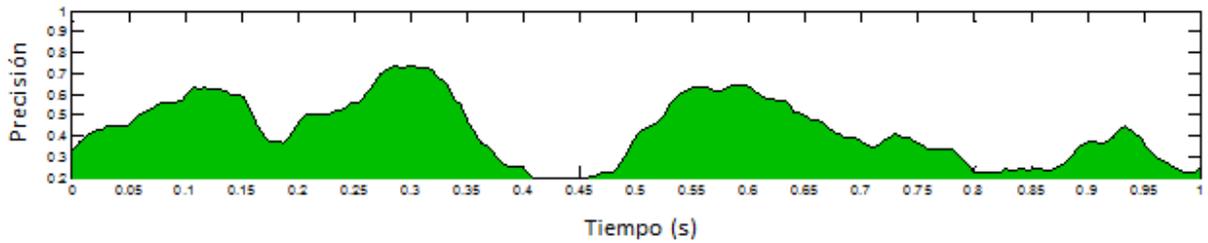


Figura 27. Precisión obtenida a través del tiempo después de la presentación del estímulo

El valor de precisión obtenido corresponde al resultado de una validación cruzada dejando en cada ocasión a uno de los seis sujetos fuera (leave-one-out crossvalidation), donde se entrenó seis veces al SVM y en cada ocasión se dejó a uno de los sujetos fuera para utilizarlo como sujeto de validación del modelo. Por lo tanto la precisión obtenida es un valor promedio de los seis procedimientos realizados.

Para cada entrenamiento, SVM entrega el peso sináptico por el cual es multiplicado cada uno de los canales para el instante de tiempo analizado, tal información es útil para conocer cuáles canales fueron de mayor relevancia en la clasificación. Los modelos obtenidos que describen la participación de los 32 canales en la clasificación son combinados promediando los valores absolutos de los pesos sinápticos asociados a cada canal para saber cuáles tuvieron mayor participación en todos los modelos y así determinar cuáles tienen mayor relevancia en la distinción de emociones. En la figura 28 se observa la distribución de canales en el cuero cabelludo con los valores absolutos de sus respectivos pesos sinápticos, indicado en la barra de colores, donde el color rojo indica mayor relevancia en la clasificación.

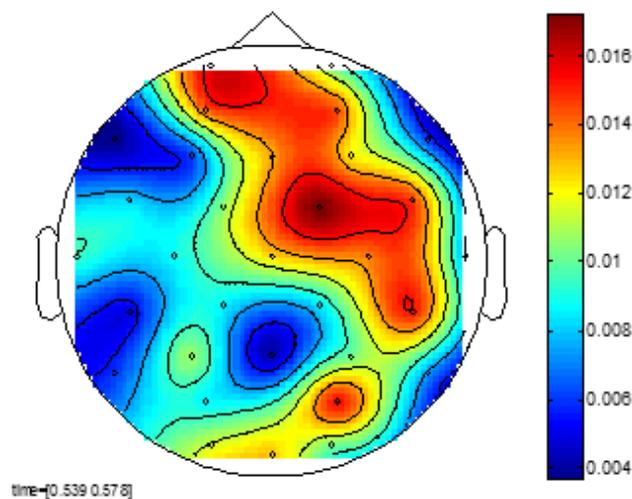


Figura 28. Modelo promedio para estimar la relevancia de los canales en la clasificación.

Por lo tanto, las características están asociadas a un instante de tiempo, una banda de frecuencia y un canal. Las características seleccionadas fueron escogidas en base a los 27 gráficos obtenidos como el de la figura 27, y analizando la relevancia de los canales en la clasificación. El procedimiento seguido es el siguiente:

1. Se escogen todos los máximos locales que superan el 70% de precisión en la clasificación luego de aplicar leave-one-out crossvalidation. Se utilizó el umbral 70% para tener al menos un total de 50 características luego de analizar todas las curvas. Por ejemplo, en la figura 27 se selecciona en la banda β_2 el máximo que se encuentra alrededor de los 300 ms.
2. Para los máximos seleccionados, se observa el gráfico de relevancia en la clasificación (figura 28), y se selecciona el principal canal en base a la barra de colores.
3. Finalmente la característica extraída corresponde al promedio de la amplitud de la serie de tiempo para la ventana de 40 milisegundos, para la banda de frecuencia estudiada.

3.8 PRUEBA DE LOS MODELOS CONSTRUIDOS

El proceso de prueba es realizado con los tres sujetos que no fueron utilizados en la etapa de selección de características. En esta etapa se toman las características con mejor separación de las clases para construir un nuevo clasificador y construir un nuevo modelo para ser evaluado en el conjunto de prueba.

Del total de características se hace una nueva selección realizando un t-test entre grupos de dos emociones, para así seleccionar las características que entreguen un p-valor menor al 5%. Tales características son ingresadas a los clasificadores SVM y Random Forests.

Los parámetros de SVM son utilizados en su valor por defecto en el toolbox LIBSVM [101]. En Random Forests se utiliza el toolbox de Breiman [102], donde los parámetros del algoritmo son: 2 características asociadas a la respuesta emocional para cada uno de los 500 clasificadores débiles (valor por defecto).

4 RESULTADOS

En el presente capítulo se presentan los resultados obtenidos para la extracción de características, la selección realizada y su testeo sobre los registros de EEG de los sujetos ante la respuesta emocional al ser expuestos a estímulos visuales con contenido afectivo.

Tal como se mencionó en el capítulo 3, la metodología de este trabajo consiste en extraer características para construir un modelo y luego testear tal modelo en un nuevo conjunto de sujetos.

La finalidad de este análisis se enmarca en el objetivo de diseñar una metodología de extracción de características para determinar cuáles son de mayor relevancia en la distinción de la respuesta emocional ante imágenes de tipo positivo, negativo y neutral.

4.1 EXTRACCIÓN DE CARACTERÍSTICAS

El procedimiento de extracción de características consistió en comparar entre pares de emociones, es decir, entre positivo-negativo, positivo-neutral y negativo-neutral, para cada una de las bandas descritas en la metodología.

A continuación se presentan los resultados obtenidos para cada una de las bandas de frecuencia. Cabe mencionar que las características seleccionadas corresponden a todas aquellas que lograron entre 70-100% de clasificación en la validación cruzada entre pares de emociones utilizando los 32 canales del EEG en un determinado instante de tiempo. Esta precisión corresponde al promedio de seis validaciones cruzadas en que cada vez se dejaba un sujeto fuera del conjunto de entrenamiento para ser utilizado como validación del modelo generado.

4.1.1 BANDA DELTA

En este estudio, esta banda de frecuencia logró distinguir estímulos positivos de los negativos a los 100 milisegundos en el lóbulo occipital, asociado a la corteza visual del cerebro (tabla 2). Esto indica que la onda P100 generada en la corteza visual del cerebro (zona occipital) tendría diferencias de potencia en la banda delta respecto al nivel de valencia del estímulo.

Tabla 2. Características de la banda delta

Número de la característica	Banda de frecuencia	Intervalo de tiempo post-estímulo (± 20 ms)	Canal principal	Grupos comparados	Precisión
1	δ	100 ms	O1	Positivo-Negativo	83.3%

4.1.2 BANDA THETA

La banda theta alta distingue en un 83.3% la respuesta emocional positiva de la negativa en la zona frontal y central del cerebro (tabla 3), coincidiendo con estudios previos donde se discriminó en la banda theta sobre los electrodos que se encontraban en la zona central de la cabellera, en respuesta a estímulos que inducían enfado a través de películas [71]. Tales resultados apoyan la noción de un efecto relacionado con la atención del usuario [74]. Con respecto a latencia de la respuesta emocional, la mayoría de las características presentadas en la tabla 3 corresponden a una mayor discriminación desde los 500 ms desde que se presentó el estímulo, lo que indicaría que la banda theta estaría mayoritariamente relacionada con procesos de procesamiento emocional tardío principalmente.

Tabla 3. Características de la banda theta

Número de la característica	Banda de frecuencia	Intervalo de tiempo post-estímulo (± 20 ms)	Canal principal	Grupos comparados	Precisión
2	θ_2	100 ms	FZ	Positivo-Negativo	75%
3	θ_2	600 ms	FC1	Positivo-Negativo	75%
4	θ_2	680 ms	FC1	Positivo-Negativo	83.3%
5	θ_2	760 ms	FC1	Positivo-Negativo	75%
6	θ_2	840 ms	FC1	Positivo-Negativo	75%
7	θ_2	500 ms	CP1	Positivo-Neutral	83.3%
8	θ_2	680 ms	CP1	Positivo-Neutral	83.3%
9	θ_2	800 ms	F8	Negativo-Neutral	83.3%

4.1.3 BANDA ALFA

En los resultados obtenidos, la banda alfa tuvo una alta relevancia distinguiendo los estados emocionales. Particularmente, la banda alfa en el lóbulo derecho tuvo una precisión del 100% discriminando entre emociones

positivas y negativas, como también entre emociones positivas y neutrales (tabla 4).

En la figura 29 se observa el promedio del valor absoluto del peso de cada canal para los seis modelos obtenidos luego de la validación cruzada. Este cálculo sirve para tener una noción de la relevancia de los canales en la separación de emociones. Se observa que el modelo presenta una asimetría hemisférica, con una alta relevancia en el lóbulo frontal derecho.

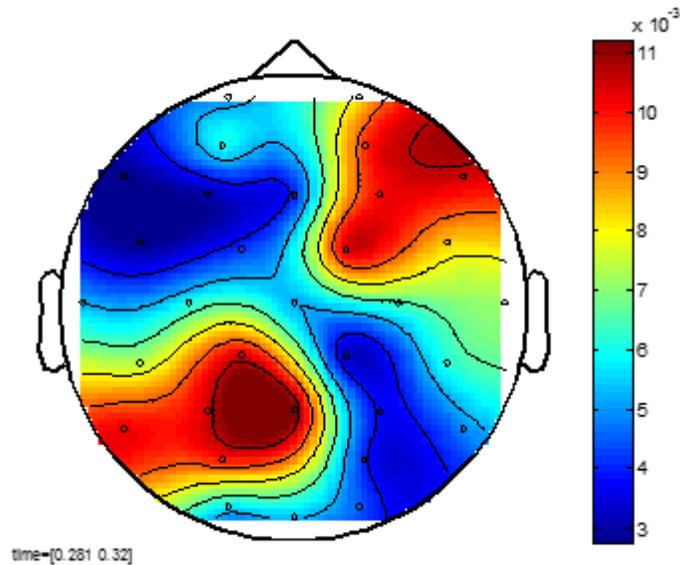


Figura 29. Modelo promedio de la relevancia en la clasificación de cada canal. El ejemplo corresponde a la discriminación entre emoción positiva y negativa en la banda alfa a los 300 milisegundos.

Tabla 4. Características de la banda alfa

Número de la característica	Banda de frecuencia	Intervalo de tiempo post-estimulo (± 20 ms)	Canal principal	Grupos comparados	Precisión
10	α_1	100 ms	FC2	Positivo-Negativo	83.3%
11	α_1	200 ms	FC2	Positivo-Negativo	83.3%
12	α_1	300 ms	FC2	Positivo-Negativo	100%
13	α_1	300 ms	PZ	Positivo-Negativo	100%
14	α_1	400 ms	FC2	Positivo-Negativo	91.6%
15	α_1	400 ms	PZ	Positivo-Negativo	91.6%
16	α_1	600 ms	P8	Positivo-Negativo	83.3%
17	α_1	700 ms	C4	Positivo-Negativo	83.3%
18	α_1	900 ms	FC2	Positivo-Negativo	83.3%
19	α_1	1 s	FC2	Positivo-Negativo	83.3%
20	α_1	740 ms	FP1	Positivo-Neutral	75%
21	α_1	840 ms	F8	Positivo-Neutral	75%
22	α_1	1 s	F8	Positivo-Neutral	75%

23	α_1	100 ms	T8	Negativo-Neutral	75%
24	α_1	500 ms	PO4	Negativo-Neutral	75%
25	α_2	100 ms	FC2	Positivo-Negativo	83.3%
26	α_2	200 ms	FC2	Positivo-Negativo	83.3%
27	α_2	100 ms	C3	Positivo-Neutral	83.3%
28	α_2	100 ms	C4	Positivo-Neutral	83.3%
29	α_2	200 ms	C3	Positivo-Neutral	75%
30	α_2	200 ms	C4	Positivo-Neutral	75%
31	α_2	840 ms	PO1	Positivo-Neutral	75%
32	α_2	1 s	FZ	Positivo-Neutral	75%
33	α_2	400 ms	FC2	Negativo-Neutral	75%

4.1.4 BANDA BETA

Si bien no hay un gran consenso respecto a la relevancia de la banda beta en el proceso de las emociones, se reportó que una gran cantidad de características de esta banda lograban sobre un 70% de separación en los sujetos del conjunto de entrenamiento. Se observa en la tabla 5 que se distinguió entre estados emocionales desde los 100 hasta los 1000 ms desde que se presentó el estímulo, además de que canales de diversos lóbulos del cerebro tendrían relevancia en la separación de clases. No es claro el aporte en la distinción de emociones en la banda beta debido a la alta dispersión espacial de sus resultados.

Tabla 5. Características de la banda beta

Número de la característica	Banda de frecuencia	Intervalo de tiempo post-estímulo (± 20 ms)	Canal principal	Grupos comparados	Precisión
34	β_1	100 ms	C3	Positivo-Negativo	75%
35	β_1	300 ms	PZ	Positivo-Negativo	83.3%
36	β_1	100 ms	FC6	Negativo-Neutral	91.6%
37	β_1	200 ms	FP1	Negativo-Neutral	91.6%
38	β_1	250 ms	FC1	Negativo-Neutral	91.6%
39	β_1	800 ms	PZ	Negativo-Neutral	83.3%
40	β_2	600 ms	CP5	Positivo-Negativo	75%
41	β_2	850 ms	PZ	Positivo-Negativo	75%
42	β_2	1 s	PZ	Positivo-Negativo	91.6%
43	β_2	1 s	P4	Positivo-Negativo	91.6%
44	β_2	700 ms	F8	Positivo-Neutral	75%
45	β_2	500 ms	FC6	Negativo-Neutral	75%
46	β_2	900 ms	C4	Negativo-Neutral	75%
47	β_3	650 ms	C4	Positivo-Neutral	83.3%
48	β_3	830 ms	AF4	Positivo-Neutral	83.3%
49	β_3	1 s	P7	Positivo-Neutral	75%
50	β_3	100 ms	C3	Negativo-Neutral	83.3%
51	β_3	670 ms	AF4	Negativo-Neutral	75%
52	β_3	1 s	C4	Negativo-Neutral	100%

4.1.5 BANDA GAMMA

En la tabla 6 se muestra que la banda gamma tuvo una alta relevancia separando las distintas clases llegando al 91.6%, incluyendo canales ubicados en la zona occipital asociados a potenciales visuales y los lóbulos temporales que están asociados a las proyecciones que posee la amígdala hacia la corteza. En cuanto al instante de tiempo en que aparece la diferenciación después de la presentación del estímulo se observan diferencias desde los 100 hasta los 900 ms

Tabla 6. Características de la banda gamma

Número de la característica	Banda de frecuencia	Intervalo de tiempo post-estímulo (± 20 ms)	Canal principal	Grupos comparados	Precisión
53	γ	100 ms	F3	Positivo-Negativo	75%
54	γ	550 ms	T8	Positivo-Negativo	75%
55	γ	720 ms	P8	Positivo-Negativo	75%
56	γ	950 ms	CP2	Positivo-Negativo	75%
57	γ	150 ms	FZ	Positivo-Neutral	75%
58	γ	250 ms	P7	Positivo-Neutral	75%
59	γ	420 ms	F7	Positivo-Neutral	83.3%
60	γ	700 ms	T7	Positivo-Neutral	91.6%
61	γ	840 ms	CP6	Positivo-Neutral	75%
62	γ	180 ms	OZ	Negativo-Neutral	91.6%
63	γ	420 ms	O1	Negativo-Neutral	91.6%
64	γ	900 ms	OZ	Negativo-Neutral	83.3%

4.2 SELECCIÓN DE CARACTERÍSTICAS Y SEPARABILIDAD EN EL CONJUNTO DE PRUEBA

4.2.1 SELECCIÓN DE LAS MEJORES CARACTERÍSTICAS EN BASE AL CONJUNTO DE ENTRENAMIENTO

Los p-valores de t-test fueron calculados para cada característica en los sujetos del conjunto de entrenamiento para luego construir un modelo y comparar su separabilidad en el conjunto de prueba.

En la figura 30 se muestran las características con menor p-valor ($p < 0.05$) para separar las emociones positivas de las negativas. Las características con mejor separabilidad son:

- La actividad en la banda delta a los 100 milisegundos en el lóbulo occipital izquierdo (característica 1 en la tabla 2).

- La actividad en la banda alfa baja entre los 300-400 milisegundos en el lóbulo frontal derecho y en la zona parietal central (características 12, 13, 14 y 15 en la tabla 4).
- La actividad en la banda alfa alta desde los 400 milisegundos en la zona frontal-central (característica 32 en la tabla 4).
- La actividad en la banda beta alta entre los 600-800 milisegundos en el hemisferio frontal-central derecho (características 34, 47 y 48 en la tabla 5).
- La actividad en la banda gamma a los 500 milisegundos en el lóbulo parietal derecho y a los 900 milisegundos en el lóbulo occipital (características 54 y 65 en la tabla 6).

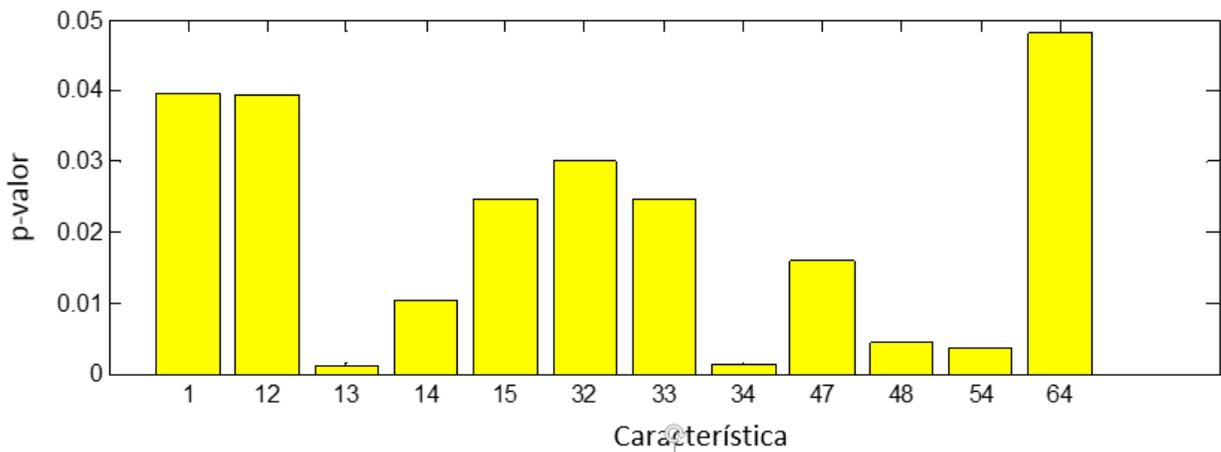


Figura 30. P-valor de las características con mayor separabilidad entre emociones positivas y negativas en el conjunto de entrenamiento.

La actividad en la banda delta permite distinguir entre emociones positivas y negativas tal como fue reportado en estudios anteriores. La banda alfa en el lóbulo frontal nuevamente muestra tener altas disimilitudes entre las emociones. La banda beta es la que menor p-valor presenta, lo cual no ha sido reportado anteriormente. La banda gamma también presenta disimilitudes en dos zonas del cerebro que no han sido nombradas anteriormente para este rango: el lóbulo occipital y parietal.

Las características con mejor separabilidad entre emociones positivas y neutrales (figura 31) son:

- La actividad en la banda theta alta a los 500 milisegundos en la zona central-parietal izquierda (característica 7 en la tabla 3).

- La actividad en la banda alfa baja entre los 300-500 milisegundos en el lóbulo frontal-parietal derecho (características 13, 15 y 24 en la tabla 4).
- La actividad en la banda alfa alta desde los 100 milisegundos en la zona central izquierda (característica 27 en la tabla 4).
- La actividad en la banda beta a los 100 milisegundos en la zona central izquierda, y a los 800 milisegundos en el lóbulo frontal derecho (características 34, 48 y 50 en la tabla 5).
- La actividad en la banda gamma a los 150 milisegundos en la zona frontal (característica 57 en la tabla 6).

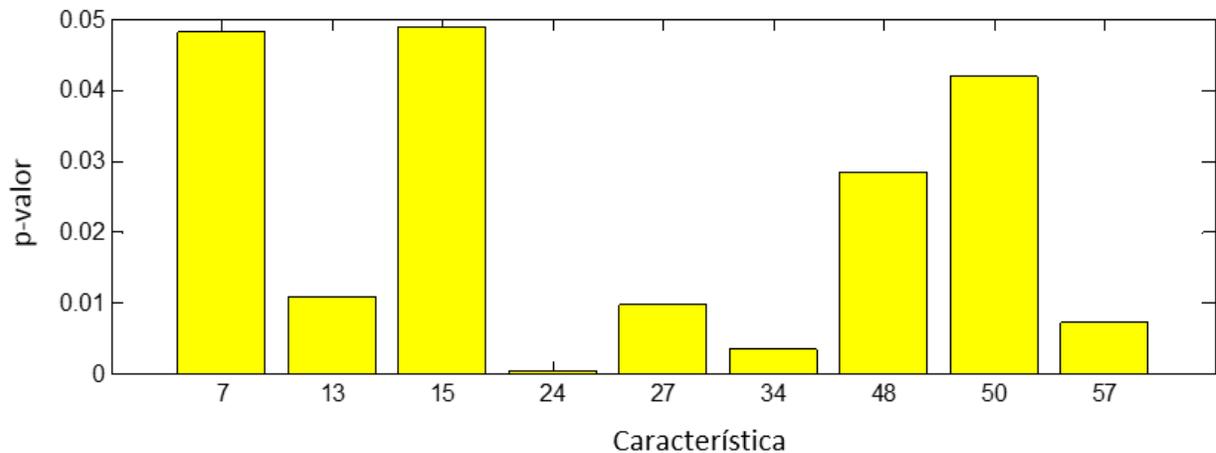


Figura 31. P-valor de las características con mayor separabilidad entre emociones positivas y neutrales en el conjunto de entrenamiento.

Entre emociones positivas y neutrales la característica que más discrimina es la actividad alfa, pero esta vez alrededor de los 100 ms. La banda beta y gamma también muestran tener alta separabilidad.

Las características con mejor separabilidad para emociones negativas y neutrales (figura 32) son:

- La actividad en la banda theta alta a los 500 milisegundos en la zona central-parietal izquierda (característica 7 en la tabla 3).
- La actividad en la banda alfa baja entre los 300-400 milisegundos en el lóbulo frontal derecho (características 12 y 14 en la tabla 4).
- La actividad en la banda alfa alta desde los 200 milisegundos en la zona central izquierda (característica 29 en la tabla 4).
- La actividad en la banda beta baja a los 100 milisegundos en la zona frontal-central derecha, beta media a 1 segundo en el lóbulo

parietal derecho y beta alta a los 100 milisegundos en la zona central izquierda (características 36, 43 y 50 en la tabla 5).

- La actividad en la banda gamma a los 900 milisegundos en el lóbulo occipital (característica 64 en la tabla 6).

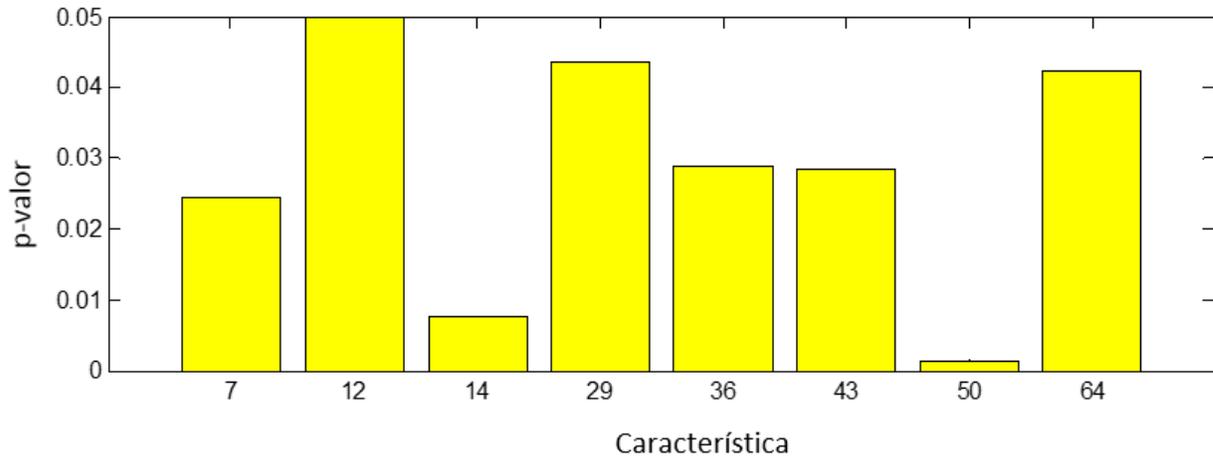


Figura 32. P-valor de las características con mayor separabilidad entre emociones positivas y negativas en el conjunto de entrenamiento.

En este caso la banda beta es la que menor p-valor posee, seguido de las características de la banda alfa incluyendo también la banda theta y gamma al igual que los casos anteriores.

En general para los tres casos se presentan p-valores bajos para la banda beta, lo que muestra un posible hallazgo para la discriminación de estados emocionales. A la vez se confirma la alta participación de la banda alfa y la contribución de las bandas delta, theta y gamma en menor medida.

4.3 CONSTRUCCIÓN DE MODELOS DE CLASIFICACIÓN DE EMOCIONES

Bajo el supuesto de que una característica por si sola podría no separar de forma perfecta las disimilitudes entre estados emocionales en una nueva batería de sujetos a analizar, se construye bajo diferentes técnicas modelos de separación de emociones en base al conjunto de entrenamiento para luego ser evaluados en el conjunto de prueba.

Para esto se introducen 20 de las 64 características a diferentes clasificadores, en base a los p-valores menores presentados en la sección anterior (ver figuras 34, 35 y 36). Los modelos son construidos para separar

esta vez entre los tres estados emocionales y también entre pares de estados como se ha hecho en la sección anterior.

4.3.1 MODELOS BASADOS EN MÁQUINAS DE SOPORTE VECTORIAL

Utilizando el conjunto de entrenamiento y las 20 características que mejor separaban las emociones, se construye un clasificador para las tres emociones que separan en un 100% los ejemplos del conjunto entrenamiento, para luego evaluar su desempeño en el conjunto de prueba.

El conjunto de prueba consiste en tres sujetos que fueron sometidos a los tres estados emocionales. Por lo tanto se tiene que clasificar un total de nueve estados emocionales. En la tabla 7 se observa el resultado obtenido usando SVM con diferentes funciones kernel. Los parámetros para cada SVM son los siguientes: el método SMO (de la sigla en inglés *Sequential Minimal Optimization*) para encontrar el hiperplano separador, parámetro C que es igual a 1, el umbral de tolerancia para las condiciones KKT es 10^{-3} y el parámetro ν igual a 0.1.

Tabla 7. Precisión obtenida para distintos modelos de SVM en los tres sujetos de prueba.

Tipo de kernel		Lineal	Polinomial de grado 2	Polinomial de grado 3	Gaussiano
Resumen precisión		5/9	6/9	6/9	6/9
Detalle por sujeto					
Sujeto 1	Positivo	✓	✓	✓	✓
	Negativo	✓	✓	✓	✓
	Neutral	×	✓	✓	✓
Sujeto 2	Positivo	✓	✓	✓	✓
	Negativo	✓	✓	✓	✓
	Neutral	✓	✓	✓	✓
Sujeto 3	Positivo	×	×	×	×
	Negativo	×	×	×	×
	Neutral	×	×	×	×

Se observa que en todos los casos el sujeto 3 no puede ser identificado en sus estados emocionales. No se observa un cambio significativo al cambiar el kernel del clasificador SVM, salvo en el caso lineal donde la emoción neutral del sujeto 1 no pudo ser identificada correctamente.

En la tabla 8 se presentan las características por orden de mayor a menor significancia para separar los tres estados emocionales de acuerdo al peso sináptico asociado a cada característica en el SVM lineal.

Tabla 8. Principales características usadas en SVM lineal para distinguir tres estados emocionales

Relevancia	Tiempo	Banda	Canal
1	100 ms	δ	O ₁
2	500 ms	θ_2	CP ₁
3	100 ms	β_1	FC ₆
4	300 ms	α_1	FC ₂
5	400 ms	α_1	FC ₂
6	100 ms	β_1	C ₃
7	400 ms	α_2	FC ₂
8	400 ms	α_1	PZ

4.3.2 MODELO BASADO EN RANDOM FORESTS

En la tabla 8 se presentan los resultados obtenidos al clasificar las emociones con un clasificador basado en Random Forests utilizando 500 clasificadores débiles y dos características en cada uno de ellos. El parámetro por defecto de características para cada clasificador débil en Random Forests es de la raíz del total de características a ingresar, es decir entre 4 y 5, pero la precisión obtenida con esos parámetros es de 5/9. La mayor precisión resultó ser 6/9 utilizando solo 2 características por árbol.

Se observa que el resultado final es el mismo que para la clasificación con SVM con kernel polinomial y gaussiano, pero el detalle por sujeto es diferente. Para este caso no hay una tendencia de clasificación para una emoción o sujeto en particular.

Tabla 9. Precisión obtenida utilizando bosques aleatorios

Resumen precisión		6/9
Detalle por sujeto		
Sujeto 1	Positivo	✓
	Negativo	×
	Neutral	✓
Sujeto 2	Positivo	✓
	Negativo	×
	Neutral	✓
Sujeto 3	Positivo	×
	Negativo	✓
	Neutral	✓

En la tabla 10 se presentan las características por orden de mayor a menor significancia para separar los tres estados emocionales de acuerdo al índice de Gini. Esta medida utilizada para los árboles de decisión está basada en la probabilidad de que un elemento sea clasificado correctamente utilizando una característica dada.

Tabla 10. Principales características usadas en RF para distinguir tres estados emocionales

Relevancia	Tiempo	Banda	Canal
1	830 ms	β_3	AF ₄
2	300 ms	α_1	PZ
3	400 ms	α_1	FC ₂
4	100 ms	α_2	C ₃
5	500 ms	α_1	PO ₄
6	150 ms	γ	FZ
7	100 ms	β_3	C ₃
8	100 ms	β_1	C ₃

Se observa que la banda beta a los 830 ms en el lóbulo frontal y la banda alfa a los 300 ms en el lóbulo parietal son las características más influyentes en la clasificación. No hay predominancia de un hemisferio en particular, pero sí se muestra la alta influencia del lóbulo frontal, central y parietal.

Al entrenar Random Forests para separar emociones de grupos de dos se obtiene un 100% de discriminación para las emociones positivas y negativas. En la tabla 11 se presenta la relevancia de las características donde se observa que la actividad de la banda alfa baja a los 300 milisegundos en la zona parietal es la que tiene mayor relevancia, pero se observa también una alta relevancia de la banda beta y delta.

Tabla 11. Principales características usadas en RF para distinguir entre emociones positivas y negativas

Relevancia	Tiempo	Banda	Canal
1	300 ms	α_1	PZ
2	830 ms	β_3	AF ₄
3	650 ms	β_3	C ₄
4	100 ms	β_1	C ₃
5	400 ms	α_1	PZ
6	400 ms	α_1	FC ₂
7	300 ms	α_1	FC ₂
8	100 ms	δ	O ₁

Por lo tanto se confirma con esto que la banda alfa es determinante para discriminar emociones respecto a sus diferencias en los valores de valencia principalmente. Se presentan nociones de la influencia de la banda delta y gamma, y se agrega la importancia de la banda beta para distinguir.

5 DISCUSIÓN

5.1 BASE DE DATOS

5.1.1 SUJETOS DISPONIBLES

Los resultados obtenidos muestran que la metodología propuesta permite encontrar una separabilidad que alcanza 2/3 respecto a los tres estados emocionales definidos. Aun así, tales resultados están restringidos a los sujetos disponibles a analizar, debido a que la variabilidad de la respuesta en cada sujeto es muy alta, en términos de latencia, es decir, cuánto tarda en aparecer la respuesta neuronal luego de ser presentado el estímulo. Por otro lado la intensidad de la respuesta, medida en micro-volts, es variable también para cada medición ya sea por el procedimiento experimental o por la experiencia personal del usuario que se está analizando. Y por último la forma en que la respuesta se propaga en el cerebro luego de que aparece por primera vez también puede variar entre cada sujeto debido a que el desplazamiento de un potencial de acción depende de la estructura anatómica de cada persona.

5.1.2 DEFINICIÓN DE ESTADOS EMOCIONALES

La definición de los estados emocionales está dada por umbrales para los valores asociados a la valencia y a la excitación de cada estímulo visual definido por la IAPS en base a la escala SAM [11].

En particular, la regla de definición de los estados emocionales es la siguiente:

- Positivo: valencia alta y excitación alta.
- Negativo: valencia baja y excitación alta.
- Neutral: valencia media y excitación baja.

En la tabla 12 se puede notar que hay un traslape entre los valores de valencia de los ensayos positivos y neutrales. Si se diseña una metodología de separación de emociones que correlacionaría los índices utilizados para separar el nivel de valencia, podría haber un problema metodológico considerando que se están promediando ensayos neutrales con niveles de valencia superiores a los ensayos de emoción positiva, dando lugar a resultados poco precisos si es que la metodología no es lo suficientemente robusta ante ensayos de comportamiento inusual.

Tabla 12. Rango de valencia y excitación de los estados emocionales

Emoción	Rango de valencia	Rango de excitación
Positivo	5.78 – 8.34	3.66 – 6.99
Neutral	4.23 – 6.50	1.72 – 3.22
Negativo	1.31 – 3.79	5.09 – 7.34

Por otro lado, existen teorías alternativas a las dimensiones de valencia y excitación. La teoría del acercamiento-rechazo [103] indica que existen diferentes respuestas corticales en el cerebro dependiendo de la dirección motivacional que tiene el estímulo sobre el sujeto. En particular, se asocia al hemisferio frontal izquierdo con emociones relacionadas con el acercamiento, y al hemisferio frontal derecho a los estímulos asociados a rechazo. Si bien la definición de acercamiento y rechazo parece estar muy relacionada con la definición de valencia, donde se ven similitudes en sensaciones positivas con el acercamiento y sensaciones negativas con el rechazo, se debe considerar que existe un traslape de ambas teorías. La diferencia se puede observar en ciertas emociones como la ira, que a simple vista se clasificaría como una emoción negativa. Pero en la teoría del acercamiento-rechazo estaría clasificada como acercamiento debido a que es una emoción relacionada con el interés del sujeto sobre un objeto.

Otros autores utilizan la dimensión de dominancia, relacionada con el sentido de control del sujeto [104]. El principal objetivo de esta dimensión es poder caracterizar las emociones y evitar el traslape entre la valencia-excitación y el acercamiento-rechazo. Si volvemos al ejemplo de la ira, tal emoción tendría un alto valor de dominancia, en comparación a emociones como la frustración. Cuando aquellas emociones son analizadas solamente en dimensiones de valencia y excitación no pueden ser distinguidas debido a que ambas tienen bajo valor de valencia y alto nivel de excitación.

En el análisis de las señales para su clasificación, no fue considerado el nivel de dominancia de los estímulos ni un posible traslape con la teoría del acercamiento-rechazo en alguno de los ensayos.

5.2 METODOLOGÍA PROPUESTA

5.2.1 ELECTROENCEFALOGRAFÍA

En la sección 2.3.4 se describieron algunas de las ventajas que posee la electroencefalografía frente a otras técnicas de monitoreo cerebral. Dentro de las ventajas planteadas se presenta la alta tasa de muestreo en el registro de la actividad neuronal. Sin embargo no queda en evidencia la necesidad de una

alta tasa de muestreo. Por otro lado, como se planteó en la sección 2.1.2, se ha mostrado que existe una alta correlación de los niveles de valencia con otras respuestas fisiológicas, como la actividad electromiográfica, la frecuencia cardiaca y la conductancia de la piel [10].

Ante los antecedentes presentados, los resultados podrían ser diferentes si se realiza este tipo de estudios con otra técnica de registro neuronal. Debido a que la actividad registrada podría no estar directamente relacionada con la actividad neuronal, sino que también con la frecuencia cardiaca o los cambios en la conductancia del cuero cabelludo. Considerando además que no es necesaria una alta resolución temporal, es decir no es un requerimiento una alta tasa de muestreo.

5.2.2 PRE-PROCESAMIENTO

La banda de frecuencia escogida entre 1-40 Hz fue en base a otros estudios, los cuales concentran el procesamiento emocional alrededor de la banda alfa (8-12 Hz aproximadamente). Debido a que hubo hallazgos entre los 30-40 Hz, lo que en este trabajo fue denominado como banda gamma, la banda para eliminar ruido pudo haber sido menos estricta dado que la banda gamma llega hasta los 100 Hz. Por lo que no se excluye la posibilidad que entre los 40-100 Hz puede haber alguna diferenciación entre los estados emocionales estudiados.

Por otro lado, cuando se promedió las épocas correspondientes a cada estado emocional, se consideró solo hasta un segundo después de presentado el estímulo, mientras que cada estímulo fue presentado por tres segundos. La elección del intervalo de tiempo fue en base a la hipótesis de que las diferencias entre las emociones serían encontradas alrededor de los 300 milisegundos. Pero en los resultados obtenidos se puede ver que hubo diferenciaciones hasta un segundo, por lo que también podría haber habido diferencias después de un segundo presentado el estímulo y no fueron consideradas. Aun así, es muy probable que las respuestas neuronales posteriores a un segundo sean efecto del desplazamiento de un potencial de acción que apareció tempranamente y luego se propagó en otras zonas del cerebro durante el transcurso temporal.

5.2.3 SELECCIÓN DE CARACTERÍSTICAS

La metodología propuesta para la selección de características incluye un análisis de la respuesta emocional en tres dimensiones: tiempo, frecuencia y ubicación topográfica. Se dejó de lado el análisis que suele hacerse en este

tipo de estudios como los cambios en el espectro de frecuencia, la morfología de los ERP, la latencia de las respuestas P100 y P300 o la conectividad y coherencia entre canales luego de presentado el estímulo. Por lo tanto, la selección de características puede ser mejorada incluyendo otras características como las mencionadas anteriormente.

Dada la pequeña base de datos disponible, los resultados están restringidos a los sujetos analizados. Es decir, los modelos construidos para predecir los estados emocionales podrían haber sido obtenidos por un sobre-entrenamiento de los clasificadores utilizados.

Los resultados muestran que la discriminación de las emociones puede ser mapeada a regiones específicas de la corteza cerebral, un intervalo de tiempo dado después de la presentación del estímulo y un patrón de onda dado por una banda de frecuencia. En la literatura, los procesos asociados al reconocimiento de emociones están altamente relacionados con el hemisferio derecho del cerebro, donde se ha asociado que los estados emocionales positivos y negativos estarían ligados a la actividad cerebral de las regiones izquierda y derecha del lóbulo frontal respectivamente [63]. De las 64 características encontradas, 29 de ellas corresponden a una activación mayoritaria del lóbulo frontal del cerebro, lo que confirma los principales hallazgos encontrados previamente en otros estudios.

Para la separación de emociones positivas y negativas, la característica que presenta mayor relevancia en la discriminación es la actividad en la banda alfa baja a los 300 milisegundos en la zona parietal del cuero cabelludo. Si bien, resultados para la banda alfa ya han sido encontrados por otros autores [69] [70], existen ciertas contradicciones. Las diferencias radican en que ciertos autores indican que para un mismo tipo de emoción, la actividad en la banda alfa disminuye, mientras que otros aseguran que aumenta. En este caso, dado que no se cuantifica exactamente la actividad en bandas de frecuencia en términos de potencia, estos resultados no serían contradictorios debido a que se está analizando la serie de tiempo asociada a una banda, por lo que un máximo local asociado la banda alfa en la serie de tiempo no significa necesariamente un aumento significativo en la potencia de tal banda en términos generales.

5.2.4 CONSTRUCCIÓN DE MODELOS PREDICTIVOS

La metodología propuesta y los resultados obtenidos muestran signos de que siguiendo tales pasos es más fácil reconocer grandes diferencias en la valencia de las emociones, más que la excitación. Debido a que la emoción que tuvo más errores fue la neutral. Sumado a esto, al comparar solamente

entre estados emocionales positivos y negativos con Random Forests fue obtenida una precisión de 100%.

Los errores de clasificación obtenidos con SVM están concentrados en el sujeto 3 del conjunto de prueba. El algoritmo de SVM realiza una combinación matemática de las características de entrada con a una función de decisión para clasificar en las distintas clases. Por su parte, Random Forests consiste en múltiples reglas de decisión que en su conjunto entregan un resultado. Ante un sujeto que pueda tener un comportamiento inusual, por ejemplo tener amplitudes más bajas en sus registros, se vería más afectado SVM en el resultado, debido a que alteraría la operación matemática. En cambio Random Forests solo se vería afectado en los clasificadores débiles que utilicen tal característica con comportamiento inusual. Considerando que Random Forests utiliza grandes cantidades de clasificadores débiles, el resultado final no variaría porque los clasificadores débiles no deberían estar correlacionados entre sí, por lo tanto la varianza del error tiende a ser baja. Por lo tanto la acumulación de error sobre un sujeto podría deberse principalmente a comportamientos inusuales de al menos una característica, los cuales pueden deberse a la forma en que se registró el EEG o a la distorsión en las señales que puede provocar el pre-procesamiento, como el filtrado en frecuencia, la reconstrucción de canales dañados o la extracción de artefactos oculares.

La generalización podría ser mejorada incluyendo otro tipo de características en la clasificación. El análisis sobre la morfología de las señales sería de utilidad en la distinción de emociones. En la figura 33 se observa la serie de tiempo para la banda alfa en el canal Pz para una misma ventana de tiempo, tanto para el conjunto de prueba como para el conjunto de entrenamiento. En los resultados obtenidos, el sujeto tres fue el que más errores de clasificación obtuvo, pero en la figura se puede observar que la morfología de la emoción positiva es similar en todos los sujetos, donde se observa un máximo local alrededor de los 300 ms. Sin embargo, el desfase de ese máximo en el sujeto 3 del conjunto de prueba es el mayor de todos, lo que llevó a clasificar a tal sujeto de forma errónea.

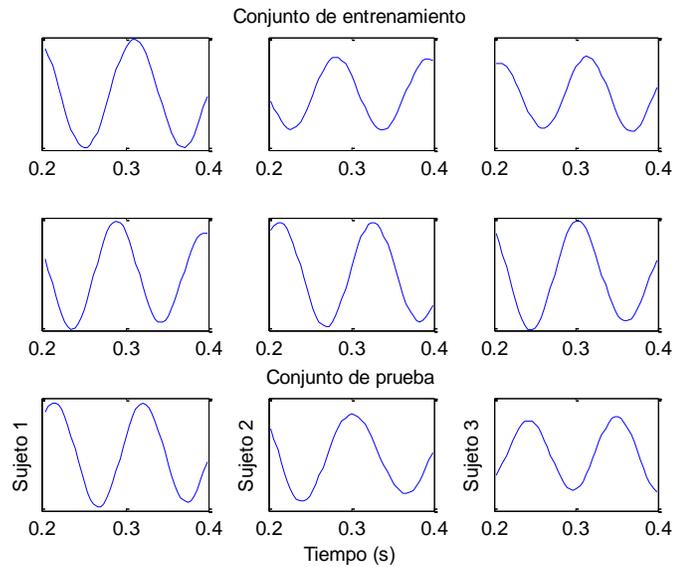


Figura 33. Disimilitudes de latencia en la banda alfa baja ante estímulos visuales positivos en el canal Pz.

Por lo tanto el incluir características asociadas a otros dominios, que incluyan este tipo de desfase no considerados en este análisis, podría mejorar considerablemente el rendimiento del sistema de clasificación.

Por otro lado, hubo características que lograron distinguir emociones en el conjunto de entrenamiento, pero en el conjunto de prueba no. En la figura 34 se muestra la actividad en la banda alfa baja a los 500 ms para emociones negativas en el canal PO_4 , donde se observa que en los seis sujetos del conjunto de entrenamiento se presenta una actividad similar. Sin embargo en el conjunto de prueba no es así, lo que llevó a un error de clasificación en Random Forests para los sujetos 1 y 2 en emociones negativas.

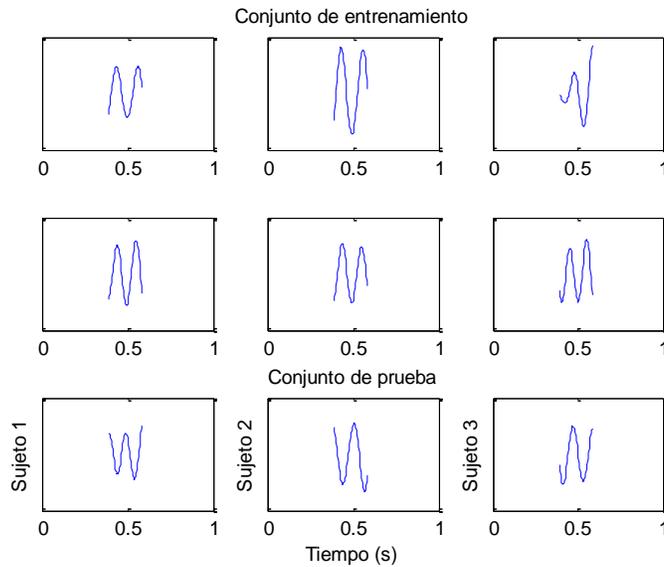


Figura 34. Disimilitudes en los ERP de la banda alfa baja ante estímulos visuales negativos en el canal PO₄.

Dada la situación presentada, se explicita la necesidad de incluir una mayor cantidad de sujetos a analizar para así reducir los errores de este tipo, donde una característica dada para distinguir emociones está presente en un número acotado de sujetos y no permite generalizar.

El principal aporte de este trabajo radica en que se extraen características de un espectro amplio de frecuencias, donde se mostró que todas las bandas tienen algún grado de separabilidad de las emociones. En comparación a otros estudios que se focalizan en una o dos bandas en particular.

5.3 RESULTADOS OBTENIDOS

Los resultados obtenidos muestran que características extraídas de todo el espectro de frecuencias ayudan a distinguir emociones. La primera disimilitud que se manifiesta es en la actividad delta a los 100 milisegundos después de presentado el estímulo en el lóbulo occipital izquierdo. En estudios anteriores se ha encontrado relaciones entre la valencia y la zona frontal y medial, lo cual no fue detectado en este estudio. Pero también se ha asociado previamente la excitación emocional a la actividad en las zonas posteriores del cerebro, donde está incluido el lóbulo occipital. Por lo tanto los resultados obtenidos en la banda delta estarían relacionados con la respuesta inmediata al estímulo emocional y qué tan energética es la respuesta. En la banda theta

se extrajeron características para discriminar las emociones neutrales de las otras. La actividad en la banda theta alta a los 500 milisegundos en la zona central-parietal izquierda fue extraída para distinguir emociones positivas de neutrales y negativas de neutrales. Los resultados obtenidos para la banda theta no son precisamente similares a los de estudios anteriores, debido a que se ha asociado previamente a la banda theta con la teoría de la valencia y la diferenciación hemisférica. Sin embargo, al igual que la banda delta, también se ha asociado a esta banda con la excitación y la actividad en la zona posterior del cerebro. La actividad en la banda alfa fue útil para distinguir entre todas las emociones, predominando en el intervalo asociado al P300. Para distinguir entre emociones positivas y negativas, se extrajo la actividad en la banda alfa baja y alta entre los 300-400 milisegundos en el lóbulo frontal derecho principalmente. Para distinguir emociones neutrales se extrajo características de la banda alfa alta en la respuesta temprana (100-200 ms) de la zona central izquierda del cerebro, como también cerca del intervalo P300 (300-500 ms) en el lóbulo frontal derecho. Los resultados indican que la actividad en la zona frontal del cerebro distingue diferencias de valencia alrededor de los 300-500 ms, y que la respuesta temprana del cerebro en la banda alfa alta podría ser útil para distinguir niveles de excitación. Tales resultados coinciden con la teoría de diferenciación hemisférica para distinguir los niveles de valencia de los estímulos. Con respecto a la excitación, ésta ha sido reportada como fluctuaciones de la actividad alfa de forma global en el cerebro. En cuanto a la banda beta, se registró que entre emociones positivas y negativas la banda beta alta en la respuesta tardía (+500 ms) ayuda a distinguir en la zona frontal-central, y en las emociones neutrales distinguen en la respuesta temprana en la zona central, lo cual no ha sido reportado anteriormente. Finalmente en la banda gamma se registraron características que distinguen las tres emociones en un rango amplio de instantes de tiempo y localizaciones en el cerebro, incluyendo los lóbulos temporales lo cuales son asociados a las emociones por sus aferencias hacia la amígdala, estructura nuclear del cerebro en el procesamiento emocional.

En resumen, los resultados obtenidos indicarían que para distinguir los niveles de valencia de las emociones es útil la información extraída de la banda alfa baja, y que puede ser complementada con la banda delta, beta y gamma. Con respecto a los niveles de excitación es útil la información de las bandas delta, theta alta, alfa alta, beta y gamma.

El enfoque metodológico de este estudio dista de los tradicionales que se enfocan en analizar el espectro de frecuencias de forma global. En este estudio se analizó las bandas de frecuencia en detalle, donde se analizó para canales individuales y en pequeñas ventanas de tiempo posteriores a la presentación del estímulo. De todas maneras la metodología puede ser mejorada si se

incluyen características asociadas a la morfología de las señales y a la coherencia entre zonas del cerebro para distintas ventanas de tiempo.

Los hallazgos de estudios anteriores que no fueron encontrados en éste caso no implican que los estudios se contradicen, sino que el análisis de las bandas de frecuencia de manera global puede dar resultados diferentes en comparación al análisis en pequeños intervalos temporales.

6 CONCLUSIONES

El presente capítulo tiene por objetivo concluir respecto a los resultados más relevantes del trabajo realizado en base a la recopilación bibliográfica y a los objetivos planteados al inicio del estudio.

La recopilación de información asociada a este trabajo, basada en la neurobiología de la respuesta emocional, el estado del arte del reconocimiento de emociones usando EEG y los métodos asociados a este trabajo, se considera suficiente para analizar los resultados obtenidos.

La metodología propuesta mostró que las características extraídas permiten discriminar entre los estados emocionales de los usuarios en el experimento. Sin embargo estas características podrían no capturar del todo el estado emocional debido a que no se consideró otros métodos que podrían ser útiles como medidas de similitud entre canales después de presentado el estímulo visual o la morfología y desplazamiento de los ERP.

Disimilitudes fueron observadas en múltiples sitios del cuero cabelludo desde el rango delta hasta la banda gamma de frecuencias. De los sujetos analizados, se obtuvo una completa clasificación entre estados emocionales positivos y negativos, y 2/3 de clasificación comparando los tres estados emocionales estudiados utilizando Random Forests y SVM.

Las características de mayor relevancia en la clasificación están asociadas a la banda alfa. Sin embargo, las otras bandas de frecuencia también son útiles en la separación de las diferentes clases.

Los resultados sugieren que registrar la actividad neuronal con mediciones del cerebro como el EEG puede mostrar signos asociados a la emoción percibida por el usuario. De todas maneras, un análisis considerando características en distintos dominios es necesario para una mayor precisión.

En cuanto a los clasificadores escogidos, no es posible realizar un análisis más profundo debido a la poca cantidad de sujetos disponibles, lo que se traduce en que no existen grandes diferencias en la precisión final obtenida. A priori, la clasificación basada en Random Forests podría ser más robusta en términos de mayor cantidad de características a utilizar y una mayor cantidad de emociones a distinguir. Además Random Forests resultó ser más robusto en términos de definir qué características son más relevantes para distinguir emociones, sin embargo fue más susceptible a la diferencia de latencia de respuesta neuronal de uno de los sujetos de prueba. Por su parte, SVM mostró ser desacertado para un sujeto en particular del conjunto de prueba, lo que indicaría una menor robustez del método ante la prueba de un registro con al menos una característica inusual.

Se propone realizar como trabajo futuro un análisis similar con una batería mayor de sujetos, considerando adicionalmente un análisis por género, edad y cultura de ellos, debido a que tal información no se encontraba disponible para este estudio. También se propone realizar un estudio de la variabilidad de la respuesta neuronal en los mismos sujetos para así analizar la capacidad de predicción del método. Además se propone agregar otro tipo de características al procedimiento asociadas a las diferencias de la potencia de cada banda de frecuencia, la correlación entre hemisferios o lóbulos en intervalos de tiempo definidos previo y post presentación del estímulo y la morfología de los ERP respecto a sus amplitudes y desplazamientos en el cuero cabelludo. Otro enfoque que podría mejorar el análisis de los datos es no comparar entre estados emocionales como los definidos en este estudio, sino que realizar una regresión entre las características extraídas y los niveles de valencia y excitación. Además agregar la dimensión de dominancia al estudio.

7 BIBLIOGRAFÍA

- [1] P. Johnson-Laird and K. J. Oatley, *Cognitive and social construction in emotions*, Nueva York: The Guilford Press, 2004.
- [2] P. Salovey and J. D. Mayer, "Emotional intelligence.," *Imagination, Cognition and Personality*, no. 9, pp. 185-211, 1989.
- [3] D. Goleman, *Emotional intelligence*, Nueva York: Bantam Books, 1995.
- [4] R. Adolphs, "Neural systems for recognizing emotion," *Current Opinion in Neurobiology*, no. 12, pp. 169-179, 2002.
- [5] D. Charles, *The expression of the emotions in man and animals*, Londres: John Murray, 1872.
- [6] M. Bruno, A. Vanhaudenhuyse, A. Thibaut, G. Moonen and S. Laureys, "From unresponsive wakefulness to minimally conscious PLUS and functional locked-in syndromes: recent advances in our understanding of disorders of consciousness," *J Neurol*, vol. 258, pp. 1373-1384, 2011.
- [7] J. Morris, "Amyotrophic Lateral Sclerosis (ALS) and Related Motor Neuron Diseases: An Overview," *Neurodiagn J*, vol. 55, pp. 180-194, 2015.
- [8] P. Bermejo and I. Izquierdo, *Tu dinero y tu cerebro. Por qué tomamos decisiones erróneas y cómo evitarlo según la neuroeconomía*, Random House, 2013.
- [9] F. Vélez and A. Ostrosky, "Neurobiología de las Emociones," *Revista Neuropsicología, Neuropsiquiatría y Neurociencias*, vol. 13, no. 1, pp. 1-13, Enero-Junio 2013.
- [10] J. Panksepp, "Neurochemical control of moods and emotions: Amino acids to neuropeptides," *The handbook of emotions. M. Lewis & Haviland*, pp. 87-107, 1993.
- [11] M. Bradley and P. Lang, *Measuring Emotion: The Self-Assessment Manikin and The Semantic Differential*, University of Florida, 1994.
- [12] M. M. Bradley and P. J. Lang, "Measuring emotion: The self-assessment manikin and the semantic differential," *Journal of Behavior Therapy and Experimental Psychiatry*, 1994.

- [13] P. Lang, M. Bradley and B. Cuthbert, International affective picture System (IAPS): Affective ratings of pictures and instruction manual. Technical Report A-8., Gainesville, FL: University of Florida, 2008.
- [14] J. Moltó, S. Montañés, R. Poy, p. Segarra, M. Pastor and T. M, "Un nuevo método para el estudio experimental de las emociones: El International Affective Picture System (IAPS). Adaptación española," *Revista de Psicología General y Aplicada*, no. 55, pp. 55-87, 1999.
- [15] A. R. Damasio, *El error de Descartes*, Editorial Andrés Bello, 1994.
- [16] J. P. Román and F. Sánchez-Navarro, "Amígdala, corteza prefrontal y especialización hemisférica en la experiencia y expresión emocional," *Anales de psicología*, vol. 20, pp. 223-240, 2004.
- [17] "Planearte Mejor," [En línea]. Disponible en: <http://www.planeartemejor.com/articulos-estres.php>. [Acceso el 16-09-2016].
- [18] Malcolm and Carpenter, *Neuroanatomía humana de*, 5 ed., S. y. Elwyn, Ed., Buenos Aires: El Ateneo, 1978.
- [19] P. Bard, "A diencephalic mechanism for the expression of rage with special reference to the sympathetic nervous system," *American Journal of Physiology*, no. 84, pp. 490-515, 1928.
- [20] W. Hess, *The functional organization of the diencephalon*, Nueva York: Grune&Stratton, 1957.
- [21] R. J. McCulloch and T. Bandler, "Afferents to a midbrain periaqueductal grey region involved in the "defense reaction" in the cat as revealed by horseradish peroxidase," *The diencephalon. Behavioral Brain Research*, vol. II, no. 13, pp. 279-285, 1984.
- [22] H. Eichenbaum, *Neurociencia cognitiva de la memoria*, Ariel Neurociencia, 2003.
- [23] H. Bucy and P. C. Klüver, "Preliminary analysis of functions of the temporal lobes in monkeys," *Archives of Neurology and Psychiatry*, no. 42, pp. 979-1000, 1939.
- [24] L. Weiskrantz, "Behavioral changes associated with ablation of the amygdaloid complex in monkeys," *Journal of Comparative and Physiological Psychology*, no. 49, pp. 381-391, 1956.

- [25] E. T. Rolls, "Neural systems involved in emotion in primates," *Emotion: Theory, research, and experience*, vol. 3, 1986.
- [26] J. P. Mishkin and M. Aggleton, "The amygdala: Sensory gateway to the emotions," *Emotion: Theory, research, and experience*, vol. 3, 1986.
- [27] E. Halgren, The amygdala contribution to emotion and memory: Current studies in humans, Y. Ben-Ari, Ed., Nueva York: Elsevier, 1981.
- [28] P. J. Lang, M. Bradley and B. Cuthbert, International affective picture system (IAPS): Technical manual and affective ratings, Gainesville, 1999.
- [29] T. W. Buchanan, D. Tranel and R. Adolphs, "Anteromedial temporal lobe damage blocks startle modulation by fear and disgust," *Behavioral Neuroscience*, no. 18, pp. 429-437, 2004.
- [30] Y. Raine and A. Yang, "Prefrontal structural and functional brain imaging findings in antisocial, violent, and psychopathic individuals: a meta-analysis," *Psychiatry Res*, 2009.
- [31] D. I. Lewis and D. A. Kaufer, Frontal lobe anatomy and cortical connectivity, B. M. y. J.L., Ed., Nueva York: Cummings, 1999.
- [32] H. Barbas, "Connections underlying the synthesis of cognition, memory, and emotion in primate prefrontal cortices," *Brain Research Bulletin*, no. 52, pp. 319-330, 2000.
- [33] A. R. Damasio, "Towards a neuropathology of emotion and mood," *Nature*, no. 386, pp. 769-770, 1997.
- [34] T. Chow and J. Cummings, The human frontal lobes. Functions and disorders, The Guilford Press ed., B. M. y. J. Cummings, Ed., Nueva York, 1999.
- [35] J. Borod, "Interhemispheric and intrahemispheric control of emotion: A focus on unilateral brain damage," *Journal of Consulting and Clinical Psychology*, no. 60, pp. 339-348, 1992.
- [36] A. Bechara, H. Damasio, A. Damasio and G. Lee, "Different contributions of the human amygdala and ventromedial prefrontal cortex to decisionmaking," *Journal of Neuroscience*, no. 19, pp. 5473-5481, 1999.

- [37] S. Paradiso, D. Johnson, N. Andreasen, D. O'Leary, G. Watkins, L. Ponto and R. Hichwa, "Cerebral blood flow changes associated with attribution of emotional valence to pleasant, unpleasant, and neutral visual stimuli in a PET study of normal subjects," *American Journal of Psychiatry*, no. 156, pp. 1618-1629, 1999.
- [38] J. Sánchez-Navarro, J. Martínez-Selva and F. Román, "Emotional response in patients with frontal brain damage: Effects of affective valence and information content," *Behavioral Neuroscience*, 2004.
- [39] R. Davidson and G. Schwartz, "Patterns of cerebral lateralization during cardiac biofeedback versus the self-regulation of emotions: Sex differences," *Psychophysiology*, no. 13, pp. 62-68, 1976.
- [40] M. Müller, A. Keil, T. Gruber and T. Elbert, "Processing of affective pictures modules righthemisphere gamma band EEG activity," *Clinical Neurophysiology*, no. 110, pp. 1913-1920, 1999.
- [41] D. Tucker and S. Dawson, "Asymmetric EEG changes as method actors generated emotions," *Biological Psychology*, no. 19, pp. 63-75, 1984.
- [42] G. Gainotti, Handbook of neuropsychology, F. B. y. J. Grafman, Ed., Amsterdam: Elsevier, 1989.
- [43] W. Heller, "Neuropsychological mechanisms of individual differences in emotion, personality, and arousal," *Neuropsychology*, no. 7, pp. 476-489, 1993.
- [44] K. Heilman, R. Watson and D. Bowers, Affective disorders associated with hemispheric disease, Nueva York: The Guilford Press, 1984.
- [45] P. Zoccolotti, C. Caltagirone, A. Pecchinenda and E. Troisi, Progress in electrodermal research, Nueva York: Plenum Press, 1993.
- [46] E. Kandela, J. Schwartz and T. Jessell, Principles of Neural Science, McGraw-Hill, 2000.
- [47] E. Silva and F. Niedermeyer, Electroencephalography, Lippincott, 2005.
- [48] S. J. Luck, "An Introduction to the Event-Related Potential Technique," *The MIT Press*, 2005.
- [49] E. Niedermeyer and F. L. Da Silva, Electroencephalography: Basic Principles, Clinical Applications, and Related Fields, L. W. & Wilkins, Ed., 2004.

- [50] V. L. Towle, J. Bolaños, D. Suarez, K. Tan, R. Grzeszczuk, D. N. Levin, R. Cakmur, S. A. Frank and J.-P. Spire, "The spatial location of EEG electrodes: Locating the best-fitting sphere relative to cortical anatomy," *Electroencephalography and Clinical Neurophysiology*, 1993.
- [51] "Ant Neuro," [En línea]. Disponible en: <https://www.ant-neuro.com/products/waveguard/electrode-layouts>. [Acceso el 16-09-2016].
- [52] C. M. Brown and P. Hagoort, "The cognitive neuroscience of language," *Oxford University Press*, p. 6, 1999.
- [53] S. Luck, "For discussion of ERP component naming conventions," in *An Introduction to the Event-Related Potential Technique*, MIT Press, 2005, p. 10–11.
- [54] S. J. Luck, *An Introduction to Event-Related Potential Technique*, The MIT Press, 2005.
- [55] K. E. Misulis and T. Fakhoury, "Spehlmann's Evoked Potential Primer," *Butterworth-heinemann*, 2001.
- [56] E. Matthews and B. Adrian, "The Berger rhythm: potential changes from the occipital lobes in man," *Brain*, vol. 57, p. 355–385, 1934.
- [57] D. J. Creel, "Visual evoked potentials," in *The organization of the retina and visual systems*, Webvision.
- [58] J. Polich, "Updating P300: An integrative theory of P3a and P3b," *Clinical Neurophysiology*, vol. 110, p. 2128–2148, 2007.
- [59] E. D. Kondylis, "Detection Of High-Frequency Oscillations By Hybrid Depth Electrodes In Standard Clinical Intracranial EEG Recordings," *Frontiers In Neurology*, vol. 5, pp. 1-10, 2014.
- [60] J. Anderson, *Cognitive Psychology and Its Implications*, Nueva York: NY Worth, 2004.
- [61] P. Nunez and R. Srinivasan, "Electric fields of the brain: The neurophysics of EEG," *Oxford University Press*, 1981.
- [62] M. Hämäläinen, R. Hari, R. J. Ilmoniemi, J. Knuutila and O. V. Lounasmaa, "Magnetoencephalography: Theory, instrumentation, and applications to noninvasive studies of the working human brain," *Reviews of Modern Physics*, vol. 65, pp. 413-497, 1993.

- [63] E. Silberman and H. Weingartner, "Hemispheric lateralization of functions related to emotion," *Brain and Cognition*, vol. 5, no. 3, pp. 322-353, 1986.
- [64] D. M. Tucker, "Lateral brain function, emotion, and conceptualization," *Psychological bulletin*, vol. 89, no. 1, pp. 19-46, 1981.
- [65] G. Pfurtscheller, "Event-related EEG/MEG synchronization and desynchronization: basic," *Clinical Neurophysiology*, vol. 110, no. 11, p. 1842-1857, 1999.
- [66] J. Allen, J. Coan and M. Nazarian, "Issues and assumptions on the road from raw signals to metrics of frontal EEG asymmetry in emotion," *Biological Psychology*, Vols. 1-2, no. 183-218, p. 67, 2004.
- [67] R. Davidson, "Affect, cognition, and hemisphere specialization," in *Emotion, cognition, and behavior*, J. K. y. R. Z. C.E. Izard, Ed., Cambridge University Press, 1985.
- [68] R. Huster, S. Stevens, A. Gerlach and F. Rist, "A spectralanalytic approach to emotional responses evoked through picture presentation," *Int. J. Psychophysiology*, vol. 72, no. 2, pp. 212-216, 2009.
- [69] L. Schmidt and L. Trainor, "Frontal brain electrical activity (EEG) distinguishes valence and intensity of musical emotions," *Cognition and Emotion*, p. 487-500, 2001.
- [70] L. Aftanas and S. Golocheikine, "uman anterior and frontal midline theta and lower alpha reflect emotionally positive state and internalized attention: high-resolution EEG investigation of meditation," *Neuroscience Letters*, vol. 310, no. 1, pp. 57-60, 2001.
- [71] E. Marosi, O. Bazán, G. Yañez, J. Bernal, T. Fernández, M. Rodríguez, J. Silva and A. Reyes, "Narrow-band spectral measurements of EEG during emotional tasks," *J. Neuroscience*, vol. 112, no. 7, pp. 871-891, 2002.
- [72] A. Keil, M. Müller, T. Gruber, C. Wienbruch, M. Stolarova and T. Elbert, "Effects of emotional arousal in the cerebral hemispheres: a study of oscillatory brain activity and event-related potentials," *Clinical Neurophysiology*, vol. 112, no. 11, p. 057-2068, 2001.

- [73] D. Sammler, M. Grigutsch, T. Fritz and S. Koelsch, "Music and emotion: electrophysiological correlates of the processing of pleasant and unpleasant music," *Psychophysiology*, vol. 44, no. 2, p. 293–304, 2007.
- [74] C. Krause, V. Viemeröc, A. Rosenqvista, L. Sillanmäkia and T. Aström, "Relative electroencephalographic desynchronization and synchronization in humans to emotional film content: an analysis of the 4–6, 6–8, 8–10 and 10–12 Hz frequency bands," *Neuroscience Letters*, vol. 286, no. 1, pp. 9-12, 2000.
- [75] M. Klados, C. Frantzidis, A. Vivas, C. Papadelis, C. Lithari, C. Pappas and P. Bamidis, "A framework combining delta event-related oscillations (EROs) and synchronisation effects (ERD/ERS) to study emotional processing," *Computational Intelligence and Neuroscience*, 2009.
- [76] R. Barry, A. Clarke, S. Johnstone and C. Brown, "EEG differences in children between eyes-closed and eyes-open resting conditions," *Clinical Neurophysiology*, vol. 120, no. 10, p. 1806–1811, 2009.
- [77] L. Aftanas, A. Varlamov, S. Pavlov, V. Makhnev and N. Reva, "Time-dependent cortical asymmetries induced by emotional arousal: EEG analysis of event-related synchronization and desynchronization in individually defined frequency bands," *Psychophysiology*, vol. 44, no. 1, pp. 67-82, 2002.
- [78] L. Aftanas, N. Reva, A. Varlamov, S. Pavlov and V. Makhnev, "Analysis of evoked EEG synchronization and desynchronization in conditions of emotional activation in humans: temporal and topographic characteristics," *Neuroscience and Behavioral Physiology*, vol. 34, no. 8, p. 859–867, 2004.
- [79] M. Murugappan and S. Murugappan, "Human Emotion Recognition Through Short Time Electroencephalogram (EEG) Signals Using Fast Fourier Transform (FFT)," in *IEEE 9th International Colloquium on Signal Processing and its Applications*, Kuala Lumpur, 2013.
- [80] H. Vandyke Carter and H. Gray, *Anatomy of the Human Body*, Nueva York: Bartleby, 1918.
- [81] M. Balconi and C. Lucchiari, "EEG correlates (event-related desynchronization) of emotional face elaboration: A temporal analysis," *Neuroscience Letters*, vol. 392, no. 1-2, pp. 118-123, 2006.
- [82] S. Paulmann and S. A. Kotz, "An ERP investigation on the temporal dynamics of emotional prosody and emotional semantics in pseudo- and

- lexical-sentence context," *Brain and Language*, vol. 105, no. 1, pp. 59-69, 2008.
- [83] E. Bertran, *Procesado digital de señales: Fundamentos para comunicaciones y control*, Barcelona: Edicions UPC, 2006.
- [84] S. Butterworth, "On the Theory of Filter Amplifiers," *Experimental Wireless and the Wireless Engineer the Wireless Engineer*, vol. 71, pp. 536-541, 1930.
- [85] S. Amari, A. Cichocki and H. H. Yang, "A new learning algorithm for blind signal separation.," *Advances in Neural Information Processing Systems*, vol. 8, pp. 757-763, 1996.
- [86] A. Hyvärinen and E. Oja, "Independent component analysis: algorithms and applications," *Neural Networks*, vol. 13, pp. 411-430, 2000.
- [87] R. Oostenveld, P. Fries, E. Maris and J. Schoffelen, "FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data," *Computational Intelligence and Neuroscience*, vol. 2011, 2011.
- [88] G. Wikstrom, *Data Classification using Support Vector Machines*, Estocolmo: Stockholm University, 2005.
- [89] V. Vapnik, *Statistical learning theory*, Nueva York: John Wiley and Sons, 1998.
- [90] J. Shawe-Taylor and N. Cristianini, *Kernel Methods for Pattern Analysis*, Cambridge University Press, 2004.
- [91] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5-32, 2001.
- [92] G. Jasso, "Identificación de ironía en textos cortos," Universidad Nacional Autónoma de México, Ciudad de México, 2016.
- [93] M. R. Segal, *Machine Learning Benchmarks and Random Forest Regression*, San Francisco: University of California, 2004.
- [94] A. Montillo, *Statistical Foundations of Data Analysis*, Temple University, 2009.

- [95] L. T. Tolosi L, "Classification with correlated features: unreliability of feature ranking and solutions," *Bioinformatics*, vol. 7, no. 14, pp. 1986-1994, 2011.
- [96] A. Altmann, L. Tolosi, O. Sander and T. Lengauer, "Permutation importance: a corrected feature importance measure," *Bioinformatics*, 2010.
- [97] C. Theys, "New Zealand Institute of Language, Brain and Behaviour," University of Canterbury, [En línea]. Disponible en: <http://www.nzilbb.canterbury.ac.nz/EEG%20Lab.html>. [Acceso en Junio 2016].
- [98] "Biennale de la photographie de Mulhouse," [En línea]. Disponible en: <http://www.biennale-photo-mulhouse.com/?p=673>.
- [99] K. J. Laak, "Automated EEG Repair Tool," Institute of Computer Science, University of Tartu, 2014.
- [100] F. Vialatte, J. Dauwels, T. Musha and A. Cichocki, "Audio representations of multi-channel EEG: a new tool for diagnosis of brain disorders," *J Neurodegener*, vol. 1, no. 3, p. 292-304, 2012.
- [101] C. Chih-Chung and L. Chih-Jen, "LIBSVM: A Library for Support Vector Machines," National Taiwan University, Taipei.
- [102] L. Breiman and A. Cutler, "randomForest: Breiman and Cutler's Random Forests for Classification and Regression," Departamento de Estadística, Universidad de California Berkeley, 2015.
- [103] R. Davidson, J. Marshall, A. Tomarken and J. Henriques, "While a phobic waits: regional brain electrical and autonomic activity in social phobics during anticipation of public speaking," *Biol Psychiatry*, vol. 47, no. 2, pp. 85-95, 2000.
- [104] H. Demaree, E. Everhart, E. Youngstrom and D. Harrison, "Brain lateralization of emotional processing: historical roots and a future incorporating dominance," *Behavioral and Cognitive Neuroscience Reviews*, vol. 4, no. 1, pp. 3-20, 2005.
- [105] M. Levav, "Neuropsicología de la emoción. Particularidades en la infancia," *Revista Argentina de Neuropsicología*, no. 5, pp. 15-24, 2005.
- [106] F. Sepulveda, "Brain-actuated Control of Robot Navigation, Advances in Robot Navigation," InTech, 2011.

