



**PREPROCESAMIENTO DE SEÑALES EEG EN LA CARACTERIZACIÓN DE
BIOMARCADORES EN REGISTROS EEG DURANTE LA EJECUCIÓN DE
RECONOCIMIENTO EMOCIONAL PARA LA BÚSQUEDA DE ALTERACIONES
EN PROCESOS DE COGNICIÓN SOCIAL RELACIONADAS CON
PATOLOGÍAS NEURODEGENERATIVAS Y NEUROPSIQUIÁTRICAS.**

David Andrés Acevedo Cardona

Director

Julián David Echeverry Correa

Proyecto de grado desarrollado en el Grupo de Investigación
en Análisis de Datos y Sociología Computacional (GIADSc)
y presentado como requisito parcial para aspirar al título de
Ingeniero Electricista

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA
PROGRAMA DE INGENIERÍA ELÉCTRICA
PEREIRA - 2022**

PREPROCESAMIENTO DE SEÑALES EEG EN LA CARACTERIZACIÓN DE
BIOMARCADORES EN REGISTROS EEG DURANTE LA EJECUCIÓN DE
RECONOCIMIENTO EMOCIONAL PARA LA BÚSQUEDA DE ALTERACIONES EN
PROCESOS DE COGNICIÓN SOCIAL RELACIONADAS CON PATOLOGÍAS
NEURODEGENERATIVAS Y NEUROPSIQUIÁTRICAS.

Dirigido por:

Julián David Echeverry Correa PhD.

Profesor Asociado

Facultad de Ingenierías

Proyecto realizado como una práctica en investigación conducente a trabajo de grado.

Pereira, 01 de agosto de 2022

Programa de Ingeniería Eléctrica

Universidad Tecnológica de Pereira

Álamos. Pereira. Colombia TEL:(+57)

(6)3137122

www.utp.edu.co

Agradecimientos:

A mi madre y hermana que representa un apoyo incondicional en todos mis proyectos, este logro es, en gran, parte de ustedes.

A mis amigos dentro y fuera de la universidad, son personas que han contribuido de diferentes maneras a mi formación como persona.

A Hugo, por su apoyo desinteresado y sincero desde que era un niño.

Este proyecto fue realizado en la Universidad Tecnológica de Pereira bajo la convocatoria de Minciencias 874-2020: CONVOCATORIA PARA EL FORTALECIMIENTO DE PROYECTOS EN EJECUCIÓN DE CTel EN CIENCIAS DE LA SALUD CON TALENTO JOVEN E IMPACTO REGIONAL y avalado por el Ministerio de salud (Minsalud). Un agradecimiento especial a la universidad y a ambos ministerios por haber confiado en mí y en mis capacidades como joven investigador.

CONTENIDO

	pág.
1. INTRODUCCIÓN.....	8
1.1. DEFINICIÓN DEL PROBLEMA	9
1.2. JUSTIFICACIÓN.....	10
1.3. OBJETIVOS.....	11
1.3.1. Objetivo General	11
1.3.2. Objetivos Específicos	11
2. ESTADO DEL ARTE	12
3. MARCO TEÓRICO	14
3.1. ¿Como funciona el Sistema nervioso?.....	14
3.1.1. El Encefalograma.	15
3.2. Técnicas de Caracterización.	16
3.2.1. Técnicas en el dominio del tiempo:	16
3.2.2. Técnicas en el dominio de la frecuencia:	16
3.2.3. Técnicas en el dominio tiempo-frecuencia:	17
3.3. Preprocesamiento de Señales EEG.	18
3.3.1. Técnicas de Preprocesamiento de Señales.	19
3.4. Artefactos en Señales EEG.	20
3.4.1. Artefactos de Tipo Fisiológico:.....	20
3.4.2. Artefactos de Tipo Técnico:	21
4. METODOLOGÍA	24
4.1. Base de Datos	24
4.2. EEGLAB.....	25
4.2.1. Extensiones/Plug-Ins.	27
4.3. Preprocesamiento de las Señales	27
4.3.1. Ajuste de Referencia y Canales.	28
4.3.2. Primera Etapa de Filtrado.	29

4.3.3.	Segmentación por Épocas.....	30
4.3.4.	Análisis de Componentes Independientes.....	31
4.3.5.	Remoción de Artefactos de Larga Duración.....	32
4.3.6.	Rechazo de Componentes Ruidosas	33
5.	EXPERIMENTOS, RESULTADOS & DISCUSIÓN.....	34
5.1.	Diferencias entre la señal cruda y preprocesada.....	34
5.1.1.	Comprobación Visual.....	34
5.1.2.	Comprobación Cuantitativa.....	38
5.2.	Análisis Emocional por Parte de los Clasificadores.....	39
6.	CONCLUSIONES Y RECOMENDACIONES.....	42
6.1.	CONCLUSIONES.....	42
6.2.	RECOMENDACIONES	43
7.	ANEXOS.....	44
7.1.	Anexo 1	44
7.2.	Anexo 2	44
8.	BIBLIOGRAFÍA.....	44

LISTA DE TABLAS

1.	Resultados del análisis emocional de señales EEG con un componente básico de preprocesamiento.	39
2.	Resultados del análisis emocional de señales EEG con un componente profundo de preprocesamiento.	40
3.	Métricas para todas las emociones vs. neutro.....	40
4.	Resultados del análisis emocional para la detección de todas las seis emociones de la base de datos.....	40

LISTA DE FIGURAS

1.	Trasmisión de un pulso eléctrico a lo largo de una neurona.....	14
2.	Ondas Cerebrales y sus EEG.....	15
3.	Etapas del análisis de señales EEG.	18
4.	Artefactos de tipo fisiológico en señales EEG.....-	20
5.	Artefactos de tipo técnico en señales EEG	22
6.	Estímulos presentados a los participantes, en orden de izquierda a derecha: alegría, tristeza, ira, miedo y asco.	25
7.	Pasos para el preprocesamiento.	26
8.	Electrodos/canales registrados en las señales EEG de los 77 sujetos de la base de datos.	27
9.	Disposición de electrodos a lo largo de la cabeza.	28
10.	Parámetros Detrend.	29
11.	Parámetros Ruido Lineal	29
12.	Parámetros de Referencia.	30
13.	Parámetros de la extracción de épocas.	30
14.	Elección del algoritmo de computación.	32
15.	Parámetros EOG Removal.	32
16.	Parámetros EMG Removal.	32
17.	Señal EEG Cruda.	35
18.	Señal EEG Filtrada.	35
19.	Señal EEG Preprocesada	35
20.	Topillo del EEG.	36
21.	Potenciales Evocados (a. Rechazado y b. Aceptado)	37

1. INTRODUCCIÓN

La cognición social estudia el conjunto de procesos neurológicos, conductuales y emocionales que ocurren como producto de las interacciones y relaciones sociales humanas. La memoria de trabajo, la atención, la planificación, la motivación, la organización de información para emitir juicios y tomar decisiones se conocen como funciones ejecutivas que han servido evolutivamente para fortalecer la cognición social. Estas funciones controlan y regulan la conducta en un contexto social, es decir, permiten emitir, modificar, corregir e inhibir respuestas y actividades en torno al desarrollo y ejecución de tareas particulares. Adicionalmente, estas funciones son pilares en el desarrollo de la personalidad, la empatía y la sensibilidad social.

En este sentido, uno de los procesos de la cognición social es la identificación y manejo de emociones. Diariamente las relaciones interpersonales recaen en la forma en la que las personas producen, perciben e interpretan las distintas respuestas a señales emocionales. Como elemento no verbal, la comunicación emocional a través de expresiones faciales constituye un tipo de estímulo de alta relevancia social y biológica; desde el punto de vista social, permiten realimentar y enriquecer la interacción con otras personas; y desde el punto de vista biológico, la respuesta a estos estímulos a nivel cerebral puede ser indicador de patologías neurodegenerativas y de trastornos mentales y del comportamiento.

En este orden de ideas, el estudio de las señales EEG resulta ser un instrumento indispensable el análisis de las enfermedades neurodegenerativas y neuropsiquiátricas, por lo tanto, se vuelve necesario desarrollar técnicas de preprocesamiento, caracterización y procesamiento para tratar las señales de electroencefalogramas (EEG). El presente proyecto muestra en detalle el preprocesamiento de dichas señales para sus etapas posteriores.

1.1. DEFINICIÓN DEL PROBLEMA

Sin duda, las emociones juegan un papel fundamental en la vida cotidiana de las personas y son una de las condiciones que más caracterizan a los seres humanos [11]. Además de esto, los científicos cognitivos contemporáneos consideran en adición a los procesos cognitivos tradicionales como la percepción, el aprendizaje, la memoria y el habla, las emociones son también uno muy importante [12]. Por esto, la habilidad de reconocer los estados emocionales de la gente que nos rodea es una parte crucial de la comunicación. No obstante, como todas las personas expresan de manera diferentes sus emociones, no es una tarea fácil juzgar y modelar emociones humanas [13]. Es por ello por lo que el reconocimiento emocional, como una tarea de investigación emergente, ha atraído una atención cada vez mayor de diferentes campos y es prometedor para muchas aplicaciones, entre las cuales se encuentra el área de computación afectiva, que se considera como el estudio y desarrollo de sistemas y dispositivos que puedan reconocer, interpretar, procesar y simular efectos emocionales. Por su parte, en la computación afectiva también se utilizan distintos tipos de sensores para obtener señales fisiológicas y de comportamiento que son activadas por emociones, y se usan modelos computacionales para analizar dichas señales y obtener modelos emocionales [14][12]. Sin embargo, una inherente ambigüedad existe en reconocer emociones utilizando imágenes faciales, gestos, o señales de habla, ya que pueden no suscitar las verdaderas emociones. Para resolver esta ambigüedad, el reconocimiento de emociones usando señales electroencefalográficas (EEG) ha ganado una gran atención de la comunidad debido a su evaluación precisa y objetiva de las emociones en comparación con expresiones faciales y técnicas basadas en gestos [11][15][16].

Teniendo en cuenta lo anterior, este estudio pretende basar su objetivo en la utilización de las señales EEG, tomadas de 77 sujetos colombianos, para el reconocimiento de seis emociones básicas (tristeza, alegría, ira, miedo, asco y neutro) con base en la extracción de características en el dominio de la frecuencia y tiempo-frecuencia, y con la implementación de diferentes conjuntos de electrodos/canales que mejor se desempeñaban según la literatura; además, se

hizo uso de un paradigma experimental mediante el cual se modificaron estos conjuntos para ampliar la información del número de canales utilizados para la etapa de reconocimiento de dichas seis emociones.

1.2. JUSTIFICACIÓN

Esta propuesta permitiría generar nuevas estrategias de evaluación e intervención, ampliar el conocimiento acerca del procesamiento de la información emocional y de los cambios neuro funcionales que ocurren en sujetos con patologías relacionadas con deficiencias en la cognición social.

Por otro lado, la metodología propuesta en este proyecto involucra el preprocesamiento y caracterización de registros EEG, análisis de relevancia y reconocimiento de patrones en señales de actividad electroencefalográfica adquiridas durante la ejecución de tareas de reconocimiento emocional a través de estímulos faciales en una muestra poblacional colombiana de sujetos sanos y en sujetos que padezcan una patología neurodegenerativa o neuropsiquiátrica con el fin de identificar biomarcadores que permitan discriminar entre estos dos grupos de estudio.

Finalmente, debido a que las señales EEG son señales eléctricas, la razón de ser de estos análisis es poder encontrar caracterizaciones únicas en las señales, que permitan seleccionarlas y clasificarlas para encontrar patrones comunes los cuales indiquen el principio de alguna patología neurodegenerativa que pueda presentar la persona que es analizada.

1.3. OBJETIVOS

1.3.1. Objetivo General

Desarrollar una metodología de caracterización de biomarcadores en registros de electroencefalografía durante la ejecución de tareas de reconocimiento de emociones en rostros para la búsqueda de alteraciones en procesos de cognición social que puedan estar relacionadas con patologías crónicas no transmisibles (neurodegenerativas) y neuropsiquiátricas, empleando métodos de reprocesamiento, caracterización de señales, análisis de relevancia y reconocimiento de patrones. La metodología será validada en una muestra poblacional colombiana.

1.3.2. Objetivos Específicos

- Formarse como investigador en el campo del análisis de datos aplicado a problemas en Neurociencias.
- Fomentar el pensamiento crítico respecto a la integración de tecnologías en las ciencias médicas, particularmente el procesamiento y análisis emocional e identificar los componentes involucrados en esta integración.
- Integrar herramientas computacionales y uso de lenguajes de programación para el análisis de señales, el aprendizaje de máquina y el reconocimiento de patrones.
- Diseñar e implementar algoritmos para el preprocesamiento y remoción de artefactos de tipo técnico y fisiológico en señales EEG.
- Validar el correcto preprocesamiento de las señales con el personal clínico.

2. ESTADO DEL ARTE

La evidencia científica ha revelado que alteraciones en la cognición social pueden surgir como manifestaciones de enfermedades neurodegenerativas (epilepsia, Parkinson, dolor crónico, entre otras) y neuropsiquiátricas (ansiedad, depresión, autismo, esquizofrenia, trastorno bipolar) con repercusiones personales, laborales y socioeconómicas negativas que impactan en una disminución de la calidad de vida, e incrementan los indicadores de discapacidad y mortalidad. Los más recientes estudios epidemiológicos reportados por el Boletín de Salud Mental de abril de 2018 [1] y la más reciente Encuesta Nacional de Salud Mental muestran que en los departamentos del Eje Cafetero la prevalencia de enfermedades neuropsiquiátricas es la más alta del país, con Caldas en primer lugar con un porcentaje de 7.41% de personas atendidas por trastornos mentales y del comportamiento, seguido en el tercer puesto por Risaralda con un 5.98% y por Quindío en la cuarta posición con un 5.08%. De acuerdo con estos mismos estudios, Caldas y Quindío son los únicos departamentos con indicadores en rojo en el porcentaje de personas hospitalizadas por trastornos mentales y del comportamiento. De igual manera, para enfermedades neurodegenerativas como la epilepsia, el estudio reporta para los mismos departamentos, valores que los ubican dentro de los 5 departamentos con los indicadores más altos en el país de porcentajes de personas atendidas por epilepsia.

A nivel clínico la evaluación de las alteraciones en la cognición social está limitada a la información provista por el paciente o su cuidador, a las herramientas que tenga el especialista para identificar síntomas afectivos y cognitivos y en menor medida también a la duración de la consulta, lo cual hace difícil probar hipótesis sobre los mecanismos subyacentes a las respuestas sociales y afectivas dada su relación relativamente distal a eventos mentales de interés. Adicionalmente, medir los ligeros cambios en línea ocurridos durante los procesos mentales utilizando estos métodos tradicionales a menudo interfiere con la función psicológica natural.

De acuerdo con los estudios epidemiológicos anteriormente mencionados, el objetivo al emplear estas metodologías es cuantificar la capacidad de inhibir respuestas automáticas y cambios reversibles de conducta, abstracción y memoria de trabajo. Sin embargo, los estudios realizados con este tipo de instrumentos señalan la necesidad de poder contar con herramientas alternativas basadas en las neurociencias y ha resaltado el potencial de combinar información emocional y social con el análisis de señales electrofisiológicas ya que permiten sondear la dinámica temporal de los procesos neurales con alta resolución con un costo económico inferior a otras técnicas de estudio.

Todo lo anterior cobra validez gracias a que los registros EEG plasman la actividad combinada de la interconexión de neuronas ubicada en el electrodo de medida a la hora de que el paciente recibe un estímulo; pues esta manda una onda eléctrica la cual se puede analizar mediante técnicas de preprocesamiento, caracterización y análisis de señales eléctricas; por lo cual resulta ser una herramienta útil para el diagnóstico y el control de enfermedades neurodegenerativas tales como la epilepsia, amnesia, inflamación cerebral, tumores y daños generales del cerebro cerebrales [2].

3. MARCO TEÓRICO

3.1. ¿Como funciona el Sistema nervioso?

El tejido nervioso se encuentra en la aptitud de generar diferencias de potenciales dentro de él que funcionan como la base de los estímulos que recibe el cuerpo, todo gracias a una macro construcción de neuronas que funcionan entrelazadas entre si todo el tiempo.

El sistema nervioso está compuesto por una cantidad astronómica de neuronas y células “satélites” no excitables las cuales funcionan como soporte. Para estimular la neurona es necesario producir un cambio momentáneo en el potencial de reposición, hay un límite inferior capaz de producir este cambio al que se conoce como “umbral” de la neurona y puede ser diferente dependiendo del lugar donde se encuentre y de la persona [3], por lo tanto, los estímulos varían según las condiciones donde se presenten.

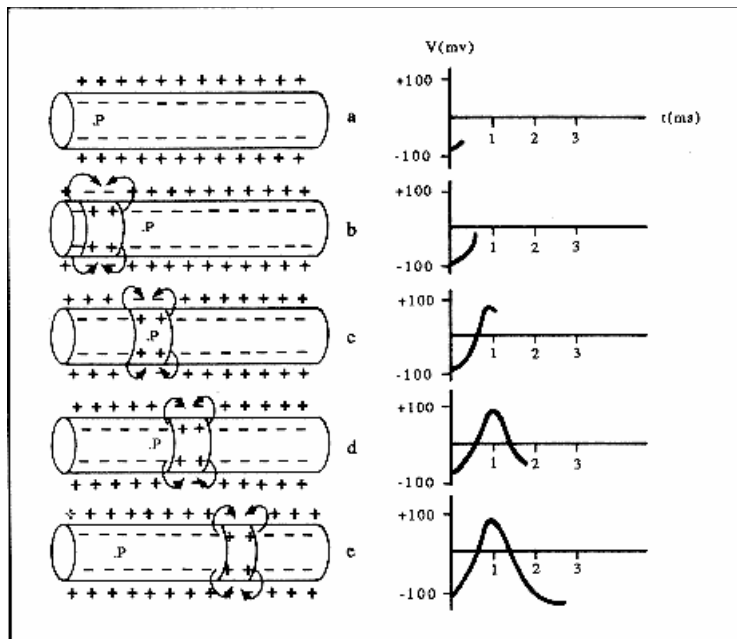


Figura 1. Trasmisión de un pulso eléctrico a lo largo de una neurona. [3]

3.1.1. El Encefalograma.

Un electroencefalograma (EEG), es un registro de la actividad eléctrica continua del cerebro medida por la diferencia de potencial eléctrico entre un electrodo colocado en un área específica del cuero cabelludo y un electrodo “neutral” que se denomina punto de referencia, el cual puede ser ubicado en cualquier otro sitio del cuerpo. Debido a que los valores de voltajes producidos en este tipo de exámenes son muy pequeños se debe tener un equipo de medida con mucha una alta sensibilidad y precisión.

Los registros EEG plasman la actividad combinada de la interconexión de neuronas ubicada en el electrodo de medida a la hora de recibir un estímulo. Gracias a esto es que la electroencefalografía es una herramienta útil para el diagnóstico y el control de enfermedades neurodegenerativas tales como la epilepsia, amnesia, inflamación cerebral, tumores y daños generales del cerebro cerebrales [2].

Para denotar las ondas cerebrales se han encontrado diferentes tipos de ondas características las cuales se presentan a continuación con sus respectivos EEG:

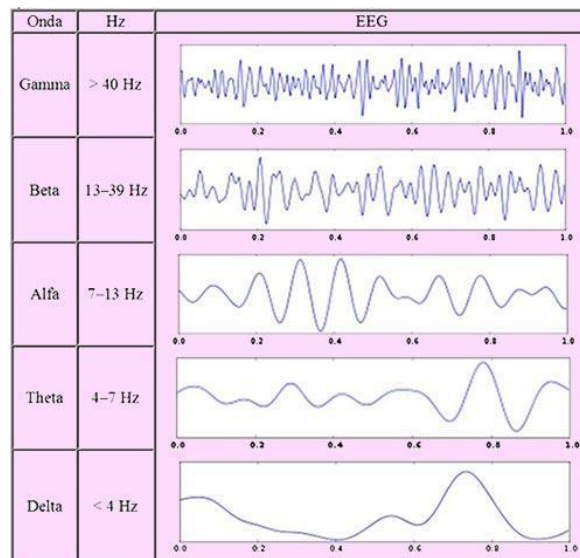


Figura 2. Ondas Cerebrales y sus EEG. [4]

3.2. Técnicas de Caracterización.

Para estudiar la caracterización de señales EEG se puede usar el dominio del tiempo, el dominio de la frecuencia, o bien, una combinación entre ambas:

3.2.1. Técnicas en el dominio del tiempo:

Modelo Autorregresivo (AR): Los modelos autorregresivos se utilizan para realizar pronósticos sobre variables ex-post (observaciones que se conoce completamente su valor) en determinados momentos del tiempo normalmente ordenados cronológicamente. Como bien dice su nombre, son modelos que se regresan en sí mismos. Es decir, la variable dependiente y la variable independiente son la misma con la única diferencia que la variable dependiente estará en un momento del tiempo posterior (t) al de la variable independiente (t-1). Este método es ordenado cronológicamente porque actualmente se encuentra en un instante de tiempo (t). Si se avanzara en un período se estaría en un tiempo (t+1) y si retrocediera un período sería el tiempo (t-1); en este último se basa el modelo autorregresivo ya que su ecuación se describe como [5].

$$x_k = a_1x_{k-1} + a_2x_{k-2} + \dots + a_px_{k-p} \quad (1)$$

Técnicas de Estadística Instantánea: Este apartado sirve especialmente para describir las señales neurofisiológicas con un compás de tiempo preciso y específico con herramientas matemáticas tales como: El valor absoluto medio, longitud de onda, cambios en la pendiente de la señal, integral cuadrada simple, Amplitud de Wilson, Parámetros de Hjorth, Derivadas de series. [6]

3.2.2. Técnicas en el dominio de la frecuencia:

Transformada Rápida de Fourier: La transformada rápida de Fourier es un algoritmo que reduce el tiempo de cálculo de las señales de n^2 pasos a $n \cdot \log_2(n)$ con el único requisito de que el número de puntos en la serie tiene que ser una potencia de 2 (2^n puntos).

$$\left. \begin{aligned} X(k) &= \sum_{j=1}^N x(j) \omega_N^{(j-1)(k-1)} \\ x(j) &= \frac{1}{N} \sum_{k=1}^N x(k) \omega_N^{-(j-1)(k-1)} \end{aligned} \right\} \omega_N = \exp\left(-\frac{2\pi i}{N}\right) \quad (2)$$

Transformada de Fourier de tiempo reducido: Dicha transformada es usada para determinar el contenido en frecuencia sinusoidal y de fase en secciones locales de una señal, así como sus cambios con respecto al tiempo; entre sus propiedades destacables esta: Aplicación en tiempo discreto, Aplicación en tiempo continuo, tiene inversa.

$$X(m, w) = \sum_{n=-\infty}^{\infty} x[n]w[n - m]e^{-jwn} \quad (3)$$

Densidad de Potencia Espectral: La densidad espectral es una función matemática que da a conocer la distribución de la potencia de dicha señal sobre las distintas frecuencias en donde está formada. Así, se puede establecer el rango de frecuencias donde se concentran las variaciones de potencia [7].

3.2.3 Técnicas en el dominio tiempo-frecuencia:

Transformada Wavelet: Esta transformada realiza un filtrado de señales y la convierte en dos procesos: “downsampling” y “upsamplig”. Cada nivel de descomposición filtra la señal por medio de un banco de filtros pasa bajos y un banco de filtros pasa altos. A la salida del primer banco se obtiene los coeficientes de aproximación de la señal, y con el segundo banco, los coeficientes de detalle. En el caso de los EEG, dependiendo de la frecuencia de muestreo se pueden obtener los ritmos a partir de coeficientes de detalle, de aproximación o ambos, en diferentes niveles de descomposición [8].

Transformada Wavelet: Transformada de Hilbert-Huang: La transformada de Hilbert-Huang es una herramienta para analizar señales no lineales y no estacionarias la cual ha demostrado ser muy efectiva para una gran variedad de señales. El método para obtener esta transformada se compone de dos partes: la descomposición en modos empíricos de la señal (Empirical Mode Decomposition, EMD) y el análisis de cada uno de los modos a través de la transformada de Hilbert y espacios Hilbertianos (Hilbert Spectral Análisis, HSA). [9]

3.3. Preprocesamiento de Señales EEG.

El preprocesamiento de señales, consiste en descartar la información presente en la señal que no resulta relevante para el reconocimiento de su contenido, como por ejemplo, eliminación del ruido (mediante técnicas clásicas de filtrado, aproximación de funciones, o la Transformada Wavelet), eliminación de la interferencia de la red, eliminación de las variaciones de la línea base (utilizando diferentes tipos de filtros), la detección de los puntos significativos de una onda (mediante algoritmos de tratamiento digital de las señales, detectando la primera y segunda derivadas, filtrado digital, transformaciones no lineales, etc.), todo ello para conseguir una señal limpia de interferencias y perfectamente segmentada [10].



Figura 3. Etapas del análisis de señales EEG.

3.3.1. Técnicas de Preprocesamiento de Señales.

Entre los métodos o técnicas más usados en el preprocesamiento de señales se describen es:

- Referencia de Promedio Común (CAR): Resulta ser un método de bajo costo computacional con el fin de remover ruido, éste consiste en referenciar la señal a un promedio común de todos los electrodos para abstraer de cada muestra el valor promedio de la señal de todos los neuro sensores; dicho promedio de toda la actividad representa un estimado de la actividad en el sitio de referencia y después se extrae este promedio [17].

- Superficie Laplaciana (SL): Es similar al método CAR con la diferencia que en este caso se resta una combinación de las señales de un conjunto de electrodos circundantes de la señal de electrodo central [17].

- Análisis de Componentes Principales (PCA): Técnica estadística para identificar y volver a referenciar los datos a través de un mapeo lineal, la cual transforma un número de variables posiblemente correlacionadas en un número menor de variables no correlacionadas conocidas como “componentes principales”; el eje primario se calcula de tal manera que abarque la mayor cantidad de variabilidad en los datos. Los componentes restantes se calculan similarmente y se tiene en cuenta la dirección de la variabilidad restante en orden decreciente con respecto a la cantidad de variabilidad en los datos [17].

- Análisis de Componentes Independientes (ICA): Técnica estadística y computacional para revelar componentes ocultos que subyacen a conjuntos de variables, mediciones o señales aleatorias; por lo general se empieza con una suposición: las fuentes subyacentes desconocidas son independientes entre sí y se han combinado linealmente para formar una señal mixta, este método devuelve las componentes independientes cuando esta suposición de independencia es correcta [17].

- Patrones Espaciales Comunes (CSP): Técnica de filtrado discriminativa específica para mejorar la señal, la cual detecta los patrones dentro de las señales complejas de EEG mediante la incorporación de información espacial de la EEG; esto se emplea planteando una matriz de covarianza como base y buscando un subespacio discriminativo de tal modo que la varianza para una clase es maximizada y la varianza para otra clase es minimizada al mismo tiempo [17].

3.4 Artefactos en Señales EEG.

En los encefalogramas, un artefacto se define como cualquier potencial eléctrico que no se origina en el cerebro. Se pueden encontrar dos tipos básicos de artefactos, los de origen fisiológico, generados por parte del paciente debido al funcionamiento normal del cuerpo, y los de origen no fisiológico debido al ruido ambiente y la maquinaria utilizada para la toma de medidas [18].

3.4.1 Artefactos de Tipo Fisiológico:

Los artefactos de origen fisiológico suelen ser debidos al movimiento y parpadeo de ojos, la respiración, el movimiento de la lengua, los potenciales de la piel, el temblor del cuerpo, la actividad cardíaca, la actividad muscular, las glándulas sudoríparas, el pulso en los tejidos o los marcapasos [20]. Estos artefactos se ven reflejados en los encefalogramas de la siguiente manera:




Figura 4. Artefactos de tipo fisiológico en señales EEG [19].

Entre los tipos de artefactos fisiológicos más comunes y sus métodos de corrección en el preprocesamiento de los datos crudos caben destacar:

- Actividades eléctricas musculares (EMG): Es el tipo más común de ruido que se puede encontrar en un EEG y se produce gracias a la contracción de varios músculos en el cuero cabelludo, cara, mandíbula y cuello. Por lo general estos tipos de artefactos se producen cuando el paciente está tensionado, ansioso y/o tiene dificultades para relajarse o permanecer quieto. Para controlar los

movimientos involuntarios se ponen electrodos que dan una referencia de tal manera que se puedan correlacionar simultáneamente con el artefacto en el registro del EEG [21].

- Movimiento del globo ocular y los párpados (EOG): Se generan por cambios del potencial del ojo; este cambio afecta principalmente a las señales de los electrodos más frontales induciendo en ellos muchas frecuencias altas y bajas, dependiendo de su duración y amplitud [22]; para contrarrestarlos se pone un electrodo de referencia en la nariz.
- Movimiento de la lengua (Potencial de Glossokinetic - GKP): Ocasionan que cambie el campo eléctrico alrededor de la boca y la mandíbula ya que la lengua es un dipolo; Para contrarrestar dicho ruido se debe hacer pruebas al paciente donde repita palabras que pueden causar un movimiento significativo de la lengua, como por ejemplo decir la expresión "lalala", luego se le pide al paciente que no hable o que no mueva la lengua; a momento de comparar ambas señales se puede determinar cuál es el posible artefacto [23].
- Los Artefactos Cardíacos (ECG): Se producen gracias a la actividad eléctrica que pueda mandar el corazón. La frecuencia cardiaca del ECG puede ser registrada colocando dos electrodos EEG en cualquier parte no cefálica del cuerpo, ya que estos generan gran amplitud, se puede diferenciar de una forma más nítida entre un artefacto del ECG y uno de origen cerebral; el uso de un montaje bipolar en lugar de un montaje de referencia OA1/OA2 generalmente reduce el voltaje del artefacto ECG [21].

3.4.2 Artefactos de Tipo Técnico:

Los artefactos de origen técnico suelen ser debidos a interferencias procedentes de factores externos del entorno o de errores experimentales tales como interferencias en la fuente de alimentación, mal funcionamiento del equipo o calibración e incluso el movimiento voluntario por parte del paciente [24]. Estos artefactos se ven reflejados en los encefalogramas de la siguiente manera:




Figura 5. Artefactos de tipo técnico en señales EEG [19].

Entre los tipos de artefactos técnico más comunes y sus métodos de corrección en el preprocesamiento de los datos crudos caben destacar:

- Artefactos causados por la frecuencia de la corriente alterna (50/60 Hz): En muchos casos provienen de los diferentes dispositivos eléctricos y/o mecánicos tales como: la camilla, la ventilación, los dispositivos de infusión intravenosa, dispositivos de compresión secuencial, monitores de los ECG, máquinas de diálisis, tubos fluorescentes, la calefacción/ refrigeración, las luces y las mantas; esto puede generar una mala medida del EEG por lo que se recomienda que si la impedancia de los electrodos es menor o igual a $5K\Omega$ y está presente el artefacto de 50/60 Hz, se deben empezar a desconectar los dispositivos eléctricos del enchufe uno a la vez, y por cada acción verificar si la señal del EEG mejora, esto se hace cíclicamente hasta identificar la fuente para poder eliminarla [7]. Si esto no mejora la señal EEG también se puede optar por un filtro “notch” con frecuencia de corte igual a 50/60 Hz, se debe tener en cuenta que las señales cerebrales dentro del rango también se atenúan, por lo tanto, una espiga epileptiforme puede tener su amplitud baja debido a que algunos componentes de la espiga tienen características de frecuencia aproximada a la frecuencia de corte [25].

- Desplazamiento accidental de los electrodos: Este artefacto es producido por exceso de gel conductor aplicada al paciente, sudor corporal o mal contacto del electrodo con la cabeza; para evitar esto se debe hacer una correcta configuración de los electrodos y equipo.
- Chasquido del electrodo: Se da por el contacto deficiente del electrodo. Los movimientos ligeros de la cabeza aumentan la impedancia de este. Este artefacto se puede contrarrestar mediante la comprobación de la impedancia del electrodo con un multímetro digital.

4. METODOLOGÍA

4.1. Base de Datos

La base de datos utilizada fue realizada como parte del trabajo de grado de Maestría en Neurociencias de la Universidad Nacional de Colombia (sede Bogotá) cuya autora fue Diana Patricia Cifuentes Santillana [26], y consta de 77 sujetos colombianos divididos por género y grupo etario de la siguiente manera: 41 personas pertenecientes al género femenino, y 30 al género masculino. Por su parte, los grupos etarios estudiados se encuentran segmentados así: 38 sujetos en el grupo adulto-joven (20 a 39 años), 24 en el grupo adulto intermedio (40 a 55 años), y 9 en el conjunto de adulto mayor (56 a 75 años). Para cada uno de estos sujetos se obtuvo un registro electroencefalográfico tomado de un equipo Acticap (Brain Products, Inc.) de manera continua mientras el participante realizaba una tarea de reconocimiento de emociones; y se adquirió también un registro de datos de comportamiento generados de manera automática por el equipo de adquisición y los cuales contienen fecha, hora, lugar de la prueba, marcas de inicio y fin de estímulo, los tiempos de respuesta y aciertos. La etapa de registro de señales EEG estuvo compuesta por dos partes:

- Entrenamiento del participante: Se indicaron las teclas que debía presionar el participante teniendo en cuenta la emoción presentada en la imagen. También, se enfrentó al sujeto a los tiempos de exposición que tuvo el estímulo (o imagen mostrada), y a una retroalimentación de cómo eran los tiempos de respuesta y acierto de esta. En esta parte, solo se presentaron imágenes de emoticones, evitando así el acostumbramiento del paciente a los rostros humanos.
- Prueba que utilizó como estímulos fotografías de rostros humanos: Correspondió a la prueba con la que se tomaron los registros electroencefalográficos, los cuales fueron grabados cuando los estímulos (imágenes/fotografías de rostros) extraídos de la base de datos PERT-96 [27] se mostraron a los participantes. Los estímulos fueron fotografías tridimensionales a

color del rostro de diferentes modelos, tanto hombres como mujeres, de diferentes etnias y edades. Un ejemplo de los estímulos se puede observar en la Figura 6.



Figura 6. Estímulos presentados a los participantes, en orden de izquierda a derecha: alegría, tristeza, ira, miedo y asco.[27]

4.2 EEGLAB.

EEGLAB es un “toolbox” interactivo de Matlab para procesar datos continuos y relacionados con eventos de EEG, MEG y otros datos electrofisiológicos que incorporan el análisis de componentes independientes (ICA), el análisis de tiempo/frecuencia, el rechazo de artefactos, las estadísticas relacionadas con los eventos y varios modos útiles de visualización de los datos promediados y de un solo ensayo. EEGLAB está disponible para los sistemas operativos: Linux, Unix, Windows y Mac OS X.

De esta manera, EEGLAB proporciona una interfaz gráfica de usuario interactiva (GUI) que permite a los usuarios procesar de forma flexible e interactiva sus datos de EEG de alta densidad y otros datos cerebrales dinámicos utilizando el análisis de componentes independientes (ICA) y/o el análisis de tiempo/frecuencia (TFA), así como los métodos de promediado estándar. EEGLAB también incorpora un amplio tutorial y ventanas de ayuda, además de una función de historial de comandos que facilita la transición de los usuarios desde la exploración de datos basada en la interfaz gráfica de usuario hasta la creación y ejecución de scripts de análisis de datos por lotes o personalizados. EEGLAB ofrece una gran cantidad de métodos para visualizar y modelar la dinámica cerebral relacionada con los eventos, tanto a nivel de "conjuntos de datos" individuales

de EEGLAB y/o a través de una colección de conjuntos de datos reunidos en un "conjunto de estudios" de EEGLAB. [28].

Teniendo en cuenta lo anterior se usará este toolbox para hacer las siguientes tareas y poder preprocesar de una manera adecuada las señales EEG:

- Recolectar e importar la información del EEG a EEGLAB.
- Ajustar la referencia y los canales.
- Primera etapa de filtrado.
- Identificar y eliminar malos canales.
- Segmentar por épocas.
- Aplicar el Análisis de Componentes Independientes.
- Rechazo de malas componentes.

La siguiente imagen ilustra con detalle el proceso antes mencionado:

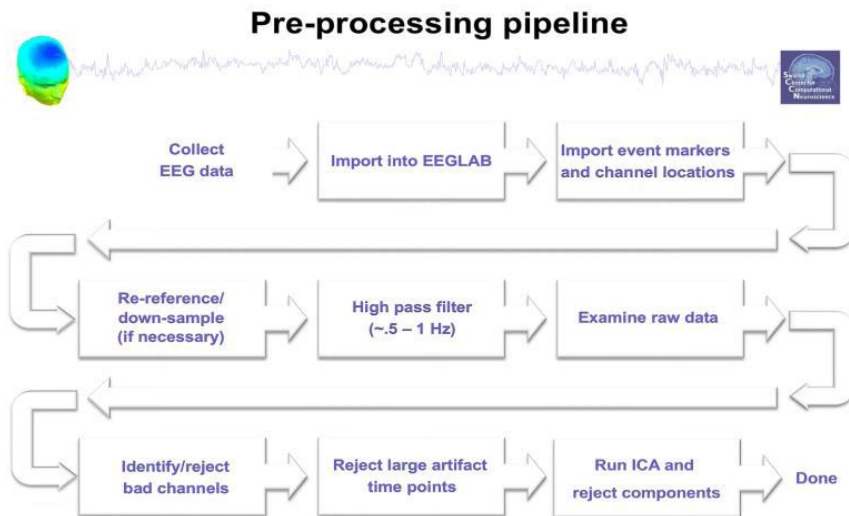


Figura 7. Pasos para el preprocesamiento de señales.

Teniendo en cuenta lo anterior, la etapa de preprocesamiento de las señales electroencefalográficas estuvo conformada por dos partes: una fase de filtrado básico y una fase de preprocesamiento profundo usando el análisis de componentes independientes, cada una de las cuales se describirán a continuación:

4.3.1 Ajuste de Referencia y Canales.

Una vez obtenida la señal en EEGLAB uno de los pasos más cruciales en el preprocesamiento fue el ajuste las referencias y los canales dentro de la señal EEG. Para la localización de los canales se opta por el modelo esférico denominado “BESA file for 4-shell dipfit spherical model” (Brain Electrical Source Analysis de cuatro revestimientos) donde su disposición espacial es la siguiente:

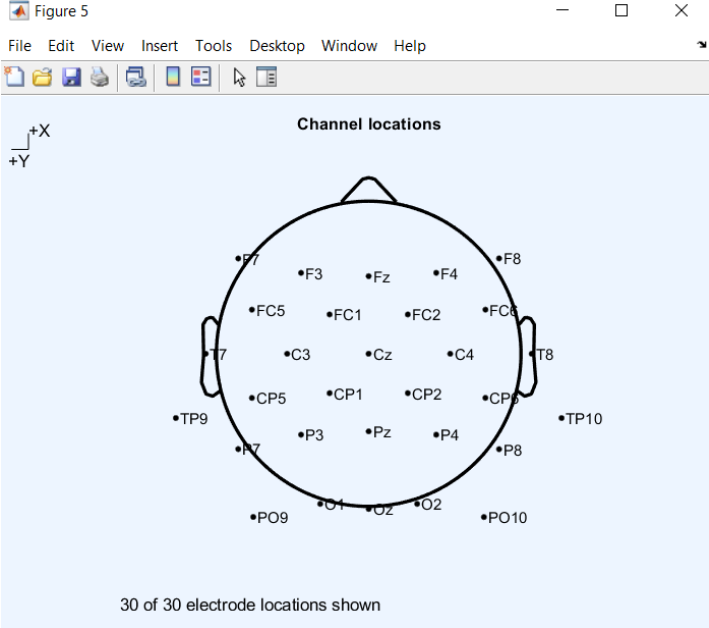


Figura 9. Disposición de electrodos a lo largo de la cabeza.

Después de localizar los canales se promedia cada una de las señales del EEG para obtener la referencia y el punto de partida en común para todas las señales y poder empezar el preprocesamiento de las señales.

4.3.2 Primera Etapa de Filtrado.

Esta fase es ejecutada por la extensión “PrepPipeline v0.55.4” y se compone cuatro procesos dependientes del paso que los precede:

- a. Abarcar los eventos limites dentro del EEG.
- b. Eliminar la línea de tendencia de la señal EEG, o proceso denominado 'detrend', este proceso se hace para los 32 electrodos/canales con un filtro pasa-altas con una frecuencia de corte de 1Hz y pasos de 0.02Hz.

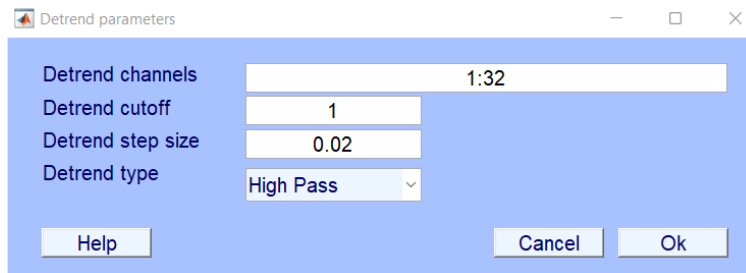


Figura 10. Parámetros Detrend.

- c. Reducción del ruido lineal producido por los armónicos que tiene la red eléctrica dentro de los canales en el encefalograma; este ruido es removido mediante un filtro lineal que alberga las siguientes características:

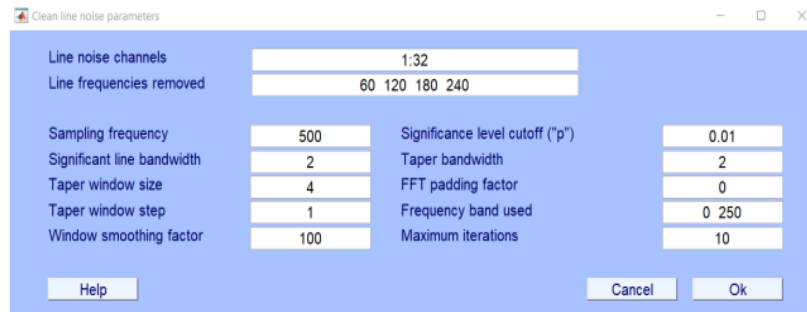


Figura 11. Parámetros Line Noise

- d. Referencia general de todos los datos (Canales, Épocas, Eventos, etc.) y estandarizarlos mediante el método estadístico llamado “Ransac”, se optaron por los siguientes parámetros:

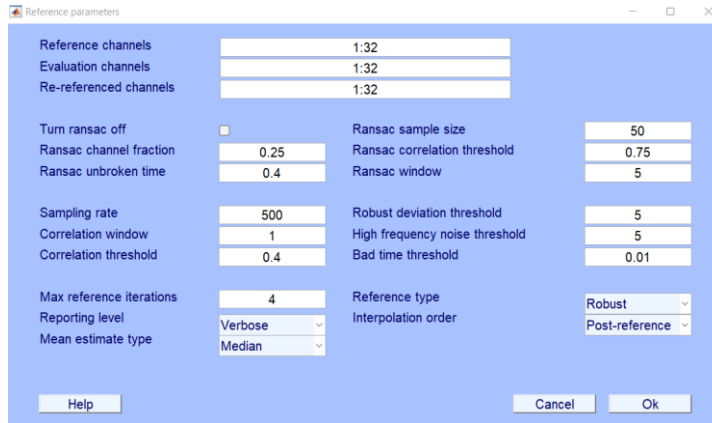


Figura 12. Parámetros de referencia.

4.3.3 Segmentación por Épocas.

Como se ha evidenciado, no toda la información dentro del encefalograma resulta ser útil y se vuelve indispensable hacer una segmentación por épocas para que a la hora de hacer el estudio de análisis de componentes independientes se pueda obtener una ventana de información valiosa y que el algoritmo computacional pueda rechazar las componentes adecuadas.

Los parámetros para realizar la segmentación el EEG fueron **las emociones básicas** (alegría, tristeza, ira, miedo y asco) dentro de una ventana de un segundo en un intervalo compuesto de -0.2 segundos hasta 0.8 segundos.

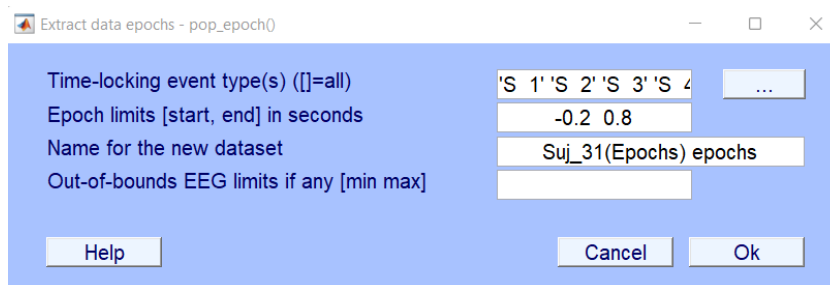


Figura 13. Parámetros de la extracción de épocas.

4.3.4 Análisis de Componentes Independientes

Para computar este análisis, hay que tener en cuenta que existen varios algoritmos computacionales: RUNICA, BINICA, FASTICA, JADE, etc. A lo largo de la experimentación y fundamentándose en la literatura [29] se opta por el método SOBI (Second-order blind identification) que se basa en la estadística de segundo orden para optimizar la correlación temporal de las señales calculando los siguientes pasos:

- Blanqueamiento de la señal.
- Cálculo de las matrices de correlación retardada.
- Diagonalización conjunta (JD).

El concepto principal recae sobre la suposición de la forma diagonal de las matrices de correlación retardada que siguen la siguiente expresión:

$$\begin{aligned} R_x(\tau) &= E\{x(t)x(t + \tau)^T\} \\ &= A R_s(\tau)A^T, \forall \tau \end{aligned} \quad (4)$$

Donde R_x es la matriz de correlación de las señales del EEG y R_s es la matriz de correlación retardada. Teniendo en cuenta que esta ecuación es válida para todos los valores de t debe existir una matriz unitaria $U = B^*A$ que diagonaliza conjuntamente todas las matrices de correlación.

$$U^T R_x(\tau) U = R_c(\tau) \quad (5)$$

Por ende, todas las señales del EEG aproximadas se calculan por $U=B*Bx(t)$ [29]. Dicho lo anterior, el método SOBI supera a los métodos convencionales como por ejemplo RUNICA en tiempos de cómputo y hay una gran similitud a los resultados arrojados por los demás algoritmos [30].

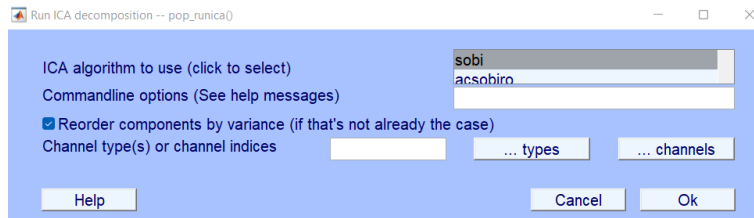


Figura 14. Elección del algoritmo de computación.

4.3.5 Remoción de Artefactos de Larga Duración

Después de hacer el estudio de ICA se ejecuta la extensión “ARR v1.3” con el que se remueven los artefactos de larga duración ocular (EOG), musculares (EMG) y nerviosos de larga duración con filtros con la separación de fuentes a ciegas (BSS) bajo el algoritmo de SOBI.

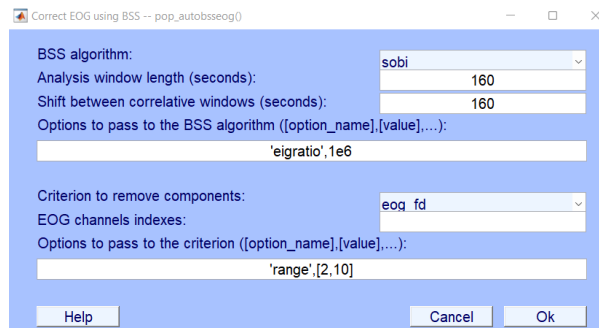


Figura 15. Parámetros EOG Removal.

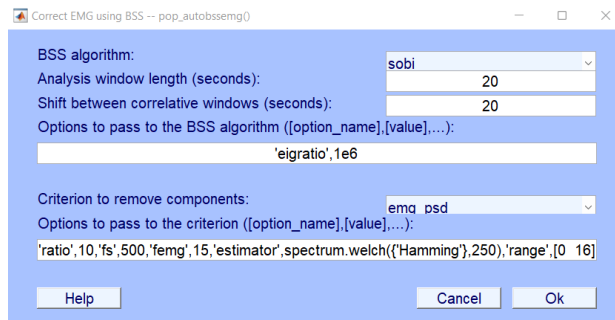


Figura 16. Parámetros EMG Removal.

4.3.6 Rechazo de Componentes Ruidosas

Como paso final del preprocesamiento, se usa la extensión “ADJUS v1.1.1” la cual rechaza las componentes que no se consideran como actividades cerebrales gracias a movimientos como:

- a. HEM (Movimientos Horizontales)
- b. VEM (Movimientos Verticales)
- c. EB (Parpadeos)
- d. GD (Discontinuidades)

Donde se establecen el valor de los umbrales para el cual se considera el rechazo de las componentes bajo los siguientes dos parámetros:

- HEM: Diferencia ocular espacial (SED) y Varianza máxima de época (MEV).
- VEM: Diferencia media espacial (SAD) y Varianza máxima de época (MEV).
- EB: Diferencia media espacial (SAD) y Curtosis temporal (TK).
- GD: Característica espacial de discontinuidad genérica (GDSF) y Varianza máxima de época (MEV).

5 EXPERIMENTOS, RESULTADOS & DISCUSIÓN.

Teniendo en cuenta la metodología explicada con anterioridad, a continuación, se desea exponer las diferencias gráficas y cuantitativas más notorias entre la señal cruda y después de someterla a la etapa de preprocesamiento. Además de esto se hacen distintos experimentos teniendo en cuenta la base de datos cruda y la base de datos preprocesada con el fin de registrar la diferencia de rendimiento de los siguientes modelos de clasificación: árboles de decisión, K-vecinos más cercanos, máquinas de soporte vectorial con kernel (RBF) y bosque aleatorio y ver como mejoran los aciertos (accuracy) teniendo el preprocesamiento previamente expuesto. Así, dicha finalidad incluye un estudio de aprendizaje supervisado binario donde se evalúa cada emoción y neutro, es decir, tristeza y neutro, alegría y neutro, ira y neutro, miedo y neutro, y asco y neutro. También, se tendrá un análisis de un problema multiclase para demostrar el rendimiento cuando se tienen en cuenta todas las emociones (tristeza, alegría, ira, miedo, asco y neutro).

5.2 Diferencias entre la señal cruda y preprocesada.

5.2.1 Comprobación Visual.

Para comprobar como mejora visual en la señal después de tener una etapa de preprocesamiento se tienen en cuenta los siguientes criterios:

1. La escala de la señal.
2. Potenciales evocados.

Se escoge aleatoriamente un sujeto para inspeccionar su EEG con el fin de ver su evolución durante todo el preproceso. 1. Para efectos visuales se opta por concatenar todas las señales de los 32 canales en solo una.




Figura 17. Señal EEG Cruda.




Figura 18. Señal EEG Filtrada.




Figura 19. Señal EEG Preprocesada.

Es evidente ver una mejoría notoria visual en la señal de la figura 19 con respecto a la de la 17. Nótese que se ha bajado su escala de resolución con respecto de la señal original y filtrada de 49 a 22 y finalmente a 13 respectivamente lo cual conlleva consigo mismo a eliminación y reducción de los picos “bruscos” que tenía el encefalograma por defecto.

Además de eso también se examina su “Topoplot”:




Figura 20. Topoplot del EEG.

Donde los números en rojo son las componentes rechazadas y los números en verde son las componentes aceptadas; además de eso se puede verificar los umbrales de rechazo para cada componente accediendo a sus potenciales evocados:

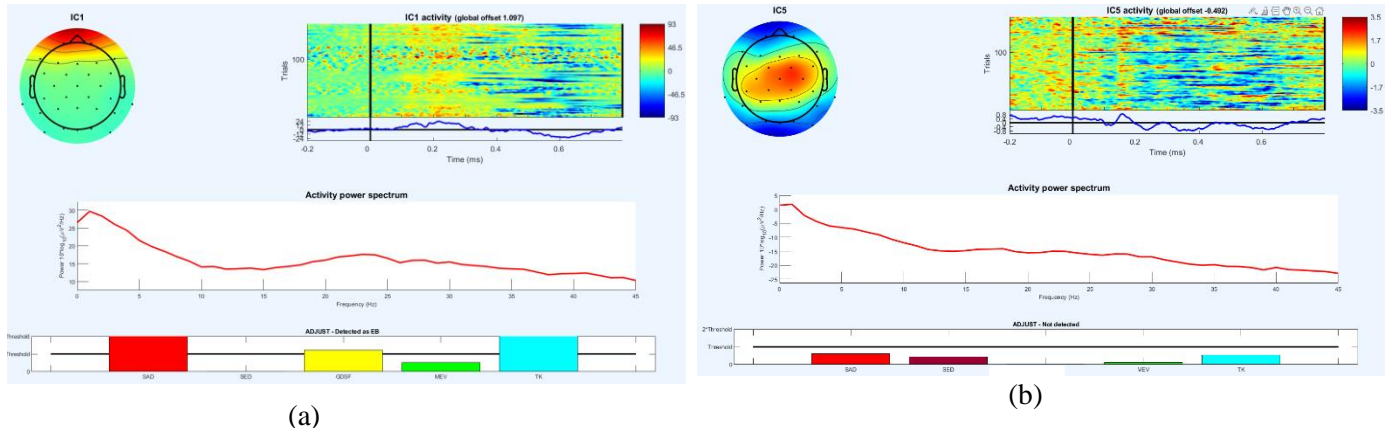


Figura 21. Potenciales Evocados (a. Rechazado y b. Aceptado).

Se puede ver que la figura 21a fue rechazado debido a que excede los umbrales los criterios de evaluación, mientras que la figura 21b no lo fue debido a que no excede ni siquiera el primer umbral.

5.2.2 Comprobación Cuantitativa.

Para la comprobación cuantitativa se tienen en cuenta parámetros como: Desviación estándar, correlación, estadísticas ransac, ruido de alta frecuencia, referencia robusta de los datos, Diferencia ocular espacial, Varianza máxima de época, Diferencia media espacial, Kurtosis Temporal y Característica espacial de discontinuidad genérica.

En el caso del EEG de la figura 19 se obtuvieron los siguientes datos:

Deviation statistics summary

- Deviation window statistics (over 378 windows)
- Large deviation channel fraction:
- [before=0.089782, after=0.014964]

Correlation statistics summary

- Max correlation window statistics (over 378 windows)
- Overall median maximum correlation [before=0.82554, after=0.84759]

Ransac statistics summary

- Ransac window statistics (over 75 windows)
- Low ransac channel fraction [before=0.0083333, after=0.00083333]

HF statistics summary

- Noise window statistics (over 378 windows)
- Channel fraction with HF noise:
- [before=0.068122, after=0.010499]

Ordinary vs robust average reference (unfiltered) correlation: 0.00020349

Ordinary vs robust average reference (filtered) correlation: 0.00033636

De los datos expuestos se puede ver que la desviación de los datos redujo su valor de manera notoria haciendo que los datos estén más cerca de lo estimado (diferencia entre el valor tomado en el encefalograma y el valor verdadero). Su correlación aumentó a valores cercanos a 0.9 o a la unidad lo cual es ideal ya que dignifica una menor la dispersión en los puntos obtenidos alrededor de la línea de tendencia. A su vez, los valores atípicos obtenidos en el método “Ransac” también se redujeron a valores cercanos a cero por lo que ahora es menos probable encontrar un dato atípico aleatorio en toda señal. El ruido de altas frecuencias se redujo haciendo que los armónicos se vean minimizados, y, de esta manera atenué la señal. Y la correlación de la referencia promedio y ordinaria aumenta lo cual supone una tendencia más fuerte entre estas dos variables al aplicarse el filtrado.

Además de esto, los datos de los umbrales de los potenciales evocados gracias a el estudio de ICA fueron:

SED - Spatial eye difference threshold=0.185174

MEV - Maximum epoch variance threshold=4.090406

SAD - Spatial average difference threshold=0.122391

TK - Temporal kurtosis threshold=0.511693

GDSF - Generic Discontinuities Spatial Feature threshold=0.612040

Haciendo que las componentes rechazadas fueran:

ICs with Horizontal eye movements: N/A

ICs with Vertical eye movements: 6

ICs with Blinks: 1 7 15 21 24 32

ICs with Generic Discontinuities: 6

5.3 Análisis Emocional por Parte de los Clasificadores

Los siguientes resultados corresponden a una evaluación mediante la cual se implementaron los modelos para una tarea de clasificación binaria.

Tabla 1: Resultados del análisis emocional de señales EEG con un componente básico de preprocesamiento.

Clasificador	Acierto medio de clasificación (%)				
	Tristeza	Alegría	Ira	Miedo	Asco
	vs. neutro				
Árboles de decisión	56.4356	55.6656	53.5754	55.4455	52.1452
MSV: kernel RBF	69.0869	68.6469	63.0363	67.9868	65.0165
KNN	80.9681	79.4279	78.1078	81.6282	79.4279
Bosque aleatorio	65.1265	64.5765	65.4565	63.2563	62.2662

Tabla 2: Resultados del análisis emocional de señales EEG con un componente profundo de preprocesamiento.

Clasificador	Acierto medio de clasificación (%)				
	Tristeza	Alegría	Ira	Miedo	Asco
	vs. neutro				
Árboles de decisión	55.6656	56.7657	57.9758	54.5655	55.3355
MSV: kernel RBF	90.8691	90.3190	92.6293	90.0990	90.5391
KNN	95.5996	96.4796	96.0396	95.8196	96.5897
Bosque aleatorio	70.9571	72.6073	73.2673	74.6975	72.6073

Tabla 3: Métricas para todas las emociones vs. neutro.

Emoción	Métricas		
	Precisión	Recall	F1-score
Tristeza	0.9748	0.9707	0.9727
Neutro	0.9677	0.9721	0.9699
Alegría	0.9727	0.9686	0.9706
Neutro	0.9653	0.9698	0.9675
Ira	0.9894	0.9728	0.9810
Neutro	0.9704	0.9884	0.9793
Miedo	0.9702	0.9837	0.9769
Neutro	0.9852	0.9728	0.9790
Asco	0.9633	0.9745	0.9689
Neutro	0.9767	0.9665	0.9716

Tabla 4: Resultados del análisis emocional para la detección de todas las seis emociones de la base de datos.

Clasificador	Acierto medio de clasificación (%)
	Todas las emociones
Árboles de decisión	30.5097
MSV: kernel RBF	81.2981
KNN	86.9454
Bosque aleatorio	55.8489

El análisis realizado para la Tabla 1 y la Tabla 2 corresponde a un punto de partida desde una línea base (o 'Baseline') que tuvo en cuenta las características extraídas en el dominio de la frecuencia y tiempo-frecuencia para evaluar modelos de clasificación y así reconocer emociones en las señales EEG. Ahora, con esto último, la Tabla 1 contiene resultados cuando las señales pasaron por una etapa de preprocesamiento básico (señal cruda), y mediante los cuales se puede observar que el modelo de clasificación de KNN (K-vecinos más cercanos) tuvo un mejor rendimiento reportando aciertos medios en porcentaje de 80.9681, 79.4279, 78.1078, 81.6282 y 79.4279, para el reconocimiento en una tarea binaria: tristeza y neutro, alegría y neutro, ira y neutro, miedo y neutro, y asco y neutro, respectivamente. En cuanto a rendimiento en la clasificación, KNN fue seguido por las máquinas de soporte vectorial con kernel RBF, bosque aleatorio, y el de más bajo rendimiento, que fueron los árboles de decisión.

Ahora, considerando los resultados de la Tabla 2, los cuales se calcularon bajo una etapa de preprocesamiento previo se pudo observar un aumento notorio en los aciertos medios de clasificación para KNN, máquinas de soporte vectorial con kernel RBF, y levemente para el bosque aleatorio y los árboles de decisión. Para KNN (mejor modelo en este caso), los porcentajes de acierto medio reportaron 95.5996, 96.4796, 96.0396, 95.8196 y 96.5897 todos los casos.

Estos resultados se sustentan en las en las Tablas 3 y 4 las cuales responden a las métricas y el acierto medio de todos los clasificadores respectivamente.

6 CONCLUSIONES Y RECOMENDACIONES

6.2 CONCLUSIONES

- Se pudo realizar un algoritmo eficiente para el preprocesamiento de señales encefalográficas usando EEGLAB que cobra su validez con la mejoría de la Figura 17 a la Figura 19 y los datos cuantitativos de la sección 5.1.2.
- Se preprocesaron los 77 sujetos de la tesis de Diana Cifuentes (Anexo 2) que sirvieron como datos de entrenamiento para los diferentes clasificadores expuestos en este documento.
- Según lo reportado en lo inmediatamente anterior, se afirma que hacer una etapa de preprocesamiento influye directamente en tener mejores resultados en cuanto al acierto medio de clasificación de las emociones en señales EEG. Pues, para el reconocimiento de tristeza y neutro se pasó de un acierto medio de 80.9681 % a un 95.5996 % con una etapa de preprocesamiento, y así sucesivamente, alegría y neutro pasó de un 79.4279 % a un 96.4796 %, ira y neutro pasó de un 78.1078 % a un 96.0396 %, miedo y neutro pasó de un 81.6282 % a un 95.8196 %, y asco y neutro pasó de un 79.4279 % a un 96.5897 %.
- En primera instancia, con las emociones crudas, las emociones mejor se reconocidas fueron miedo y neutro con un 81.6282 % de acierto medio con el clasificador KNN, y después de hacer la etapa de preprocesamiento cambió a asco y neutro con un 96.5897 % igualmente con KNN.

- Por último, en la Tabla 4 se puede evidenciar los resultados del análisis para el reconocimiento de todas las seis emociones de la base de datos, es decir, tristeza, alegría, ira, miedo, asco y neutro. Según esta tabla, KNN reportó el mejor resultado con un acierto medio de clasificación de 86.9454 %, lo que se considera un resultado sobresaliente para el reconocimiento de emociones en señales electroencefalográficas.

6.3 RECOMENDACIONES

Existen diversas posibles mejoras al sistema a continuación se describen algunas de ellas:

- **Implementar más extensiones de EEGLAB:** EEGLAB al ser un software libre y en constante construcción cada día se crean nuevas extensiones para el preprocesamiento de señales, es probable que en un tiempo se creen mejores extensiones y más exactas para la remisión de artefactos, esta recomendación es con el ánimo de investigar que extensiones están disponibles a la fecha y ver cuál puede ser útil para este estudio.
- **Usar la herramienta de “STUDY” de EEGLAB:** El preprocesamiento hecho fue sujeto por sujeto, sin embargo, la herramienta “STUDY” sirve para crear un estudio profundo para todos los sujetos de la base de datos, abriendo una nueva posibilidad de como preprocesar las señales.
- **Probar la herramienta “Classification Learner” de Matlab:** Si bien se pusieron a prueba varios clasificadores, no se probaron la totalidad de clasificadores disponibles haciendo que quepa la probabilidad que exista un mejor clasificador que KNN, con la herramienta “Classification Learner” de Matlab se pueden introducir toda la base de datos y probar una infinidad de clasificadores (incluidas redes neuronales) el cual puede mostrar cual es el clasificador más óptimo para este problema en específico.

7 ANEXOS

7.2 Anexo 1

Descargar EEGLAB gratis: <https://sccn.ucsd.edu/eeglab/download.php>

7.3 Anexo 2

[Base de datos.](#) (Ingresar con el correo institucional de la UTP)

8 BIBLIOGRAFÍA

- [1] Ministerio de Salud, «Boletín de Salud Mental – Análisis de Indicadores en Salud Mental por Territorio», abril de 2018. Disponible en url: <https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/VS/PP/ENT/bol-etin-onsmabril-2018.pdf>
- [2] Trillo Ramos, A. (2017). Análisis de señales electroencefalográficas con Matlab.
- [3] MARÍA CRISTINA PIÑA BARBA - LA FÍSICA EN LA MEDICINA III. SISTEMA NERVIOSO - Disponible en: http://bibliotecadigital.ilce.edu.mx/sites/ciencia/volumen1/ciencia2/37/htm/sec_7.htm
- [4] GUILLERMO SÁNCHEZ MEDINA - Ondas o Registros Cerebrales que detectan el Funcionamiento Cerebral – Disponible en: <https://encolombia.com/medicina/psiquiatria-salud-mental/azar-determinista/ondas-registros-cerebrales/>
- [5] PAULA RODO – MODELO AUTOREGRESIVO (AR) – Disponible en: <https://economipedia.com/definiciones/modelo-autorregresivo-ar.html>
- [6] Medina, B., SIERRA, J. E., ULLOA, A. B. (2018). Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI. Revista ESPACIOS, 39(22).

- [7] Lely A. Luengas C. 1, y Daissy C. Toloza Análisis frecuencial y de la densidad espectral de potencia de la estabilidad de sujetos amputados. Disponible en: <http://www.scielo.org.co/pdf/teclo/v23n48/2256-5337-teclo-23-48-3.pdf>
- [8] Ballesteros Larrotta, Dora María Aplicación de la transformada WAVELET en la descomposición temporo-frecuencial de señales de electroencefalografía – Disponible en: <https://www.redalyc.org/pdf/304/30400311.pdf>
- [9] J. Blázquez - Aplicación de las transformadas de Hilbert a la dinámica de una pala de aerogenerador – Disponible en: http://oa.upm.es/8171/1/INVE_MEM_2010_81803.pdf#:~:text=La%20transformada%20de%20Hilbert-Huang%20es%20una%20herramienta%20para%20analizar,disciplinas%20muy%20distintas%5B3%5D.
- [10] P. Márquez, “Procesamiento digital de señales mediante la teoría de wavelets,” Universidad Pontificia Comillas, 2013
- [11] Vipin Gupta, Mayur Dahyabhai Chopda y Ram Bilas Pachori. “Cross-subject emotion recognition using flexible analytic wavelet transform from EEG signals.” En: IEEE Sensors Journal 19.6 (2018), págs. 2266-2274.
- [12] Chunmei Qing y col. “Interpretable emotion recognition using EEG signals.” En: Ieee Access 7 (2019), págs. 94160-94170.
- [13] Xiao-Wei Wang, Dan Nie y Bao-Liang Lu. “Emotional state classification from EEG data using machine learning approach.” En: Neurocomputing 129 (2014) págs. 94-106.
- [14] Xiang Li y col. “Exploring EEG features in cross-subject emotion recognition.” En: Frontiers in neuroscience 12 (2018), pág. 162.
- [15] Wei-Long Zheng y Bao-Liang Lu. “Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks.” En: IEEE Transactions on autonomous mental development 7.3 (2015), págs. 162-175.

- [16] Hyun Joong Yoon y Seong Youb Chung. “EEG-based emotion estimation using Bayesian weighted-log-posterior function and perceptron convergence algorithm.” En: Computers in biology and medicine 43.12 (2013), págs. 2230-2237.
- [17] Vaibhav Gandhi. Chapter 2 - interfacing brain and machine. In Vaibhav Gandhi, editor, Brain-Computer Interfacing for Assistive Robotics, pages 7 – 63. Academic Press, San Diego, 2015.
- [18] Dworetzky, B. A., Schomer, D. L., “Artifact and Recording Concepts in EEG”, Journal of Clinical Neurophysiology, vol. 28, pp. 252-263, 2011
- [19] Neurofisiología Malaga - La Actividad Cerebral – Disponible en: <http://neurofisiologiagranada.com/eeg/eeg-actividadcerebral.htm>.
- [20] Belén López, Andrés Úbeda, Daniel Planelles, Carlos Perez-Vidal, Eduardo Iáñez and José M. Azorín - APLICACIÓN DE ICA PARA LA ELIMINACIÓN DE ARTEFACTOS OCULARES Y MANDIBULARES EN SEÑALES EEG DURANTE LA REALIZACIÓN DE TAREAS MENTALES – Disponible en: http://www.ja2014.upv.es/wp-content/uploads/papers/paper_15.pdf
- [21] D.M. White and A.C. Van Cott, “EEG Artifacts in the Intensive Care Unit Setting (Presented Conference Paper style)”, in Mar 2010 American Journal of Electroneurodiagnostic Technology 50(1):8-25
- [22] Mateo Hueza Echeverri, Juan Manuel López López -ANÁLISIS DE RESPUESTA NOCICEPTIVA MEDIANTE LA SEÑAL DE EEG - Disponible en: <https://acofipapers.org/index.php/eiei/article/view/1708/1686>
- [23] Antonio Quintero-Rincón - Preprocesamiento de EEG con Filtros Hampel
- [24] Daniela Alejandra Palma Bustamante – EXTRACCIÓN DE ARTEFACTOS OCULARES DE EEG MEDIANTE ANALISIS DE COMPONENTES

INDEPENDIENTES – Disponible en:
https://oa.upm.es/67423/1/TFG_DANIELA_ALEJANDRA_PALMA_BUSTAMANTE.pdf

- [25] S.Sanei and J.A. Chambers, EEG Signal Processing (Book style with paper title and editor), John Wiley & Sons, 2007, ch.7
- [26] Diana Patricia Cifuentes Santillana. “Efecto del envejecimiento normal en humanos sobre la discriminación de emociones, teoría de la mente y Potenciales Relacionados a Evento (PRE)”. En: Universidad Nacional de Colombia Sede Bogotá (2018).
- [27] Ruben C. Gur y col. “A method for obtaining 3-dimensional facial expressions and its standardization for use in neurocognitive studies”. En: Journal of Neuroscience Methods 115.2 (2002), págs. 137-143. issn: 0165-0270. doi: [https://doi.org/10.1016/S0165-0270\(02\)00006-7](https://doi.org/10.1016/S0165-0270(02)00006-7). Disponible en: <https://www.sciencedirect.com/science/article/pii/S0165027002000067>.
- [28] What is EEGLAB - Disponible en: <https://sccn.ucsd.edu/eeglab/index.php>
- [29] Guillermo SAHONERO-ALVAREZ, Humberto CALDERON - A Comparison of SOBI, FastICA, JADE and Infomax Algorithms - Disponible en: <https://www.iiis.org/CDs2017/CD2017Spring/papers/ZA832BA.pdf>
- [30] Andrzej Cichocki, Sergei L Shishkin, Toshimitsu Musha, Zbigniew Leonowicz, Takashi Asada, Takayoshi Kurachi - EEG filtering based on blind source separation (BSS) for early detection of Alzheimer's disease – Disponible en: <https://pubmed.ncbi.nlm.nih.gov/15721088/>