



INAOE

**Análisis y clasificación de
señales EEG: ojos cerrados,
parpadeos, mordida y gestos
faciales para su potencial
implementación en sistemas
BCI**

por

David Manuel Carmona Peña

Tesis sometida como requisito parcial para
obtener el grado de

Maestro en ciencias y tecnologías biomédicas
en el

**Instituto Nacional de Astrofísica, Óptica y
Electrónica**

Julio 2024

Puebla, México

Bajo la supervisión de:

Dr. Carlos Alberto Reyes García

Investigador Titular INAOE

Dra. Alina Santillán Guzmán

Investigadora Titular ITSAO

©INAOE 2024

El autor otorga al INAOE el permiso de
reproducir y distribuir copias parcial o totalmente
de esta tesis.



Agradecimientos

Quiero expresar mi más sincero agradecimiento a mis asesores, la Dra. Alina Santillan Guzmán y el Dr. Carlos Alberto Reyes Gracia, quienes con su apoyo y orientación me ayudaron a resolver las dudas que surgieron a lo largo de esta etapa, siendo fundamentales para llevar a cabo este proyecto.

Agradezco de corazón a mi madre y a mi padre, cuyos consejos, cariño y apoyo incondicional fueron fundamentales para mi progreso tanto personal como académico. Sin ellos, no habría podido avanzar con éxito en ningún aspecto de mi vida. También quiero reconocer a mi hermana, mi más grande confidente y un ejemplo a seguir. Sus palabras de aliento y su constante motivación me han impulsado a seguir adelante por el camino que ella misma está recorriendo. Agradezco enormemente a mis amigos de toda la vida en Toluca, así como a aquellos que vinieron a visitarme y a compartir nuevas experiencias. Su apoyo y compañía fueron indispensables en este importante logro para mí.

Quiero expresar mi profundo agradecimiento a mi pareja y compañera de vida, Lizet Joselin Aguilar Isaac, por su constante apoyo y por estar a mi lado en cada momento crucial. Sin su presencia y respaldo incondicional, no habría alcanzado el punto en el que me encuentro hoy. Agradezco su valentía al embarcarse en nuevas aventuras fuera de nuestro entorno habitual, lo cual nos llevó a iniciar juntos una emocionante nueva etapa en un lugar que ahora llamamos hogar: Puebla.

También deseo expresar mi sincero agradecimiento al Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE) por brindarme la oportunidad de vivir esta enriquecedora experiencia y por permitirme conocer a cada uno de los profesores que, con su sabiduría y orientación, me acompañaron en este proceso. Además, agradezco al INAOE por darme la oportunidad de relacionarme con personas extraordinarias que conocí durante mi posgrado. Estas personas no solo compartieron conmigo nuevas aventuras, conocimientos y experiencias, sino que también contribuyeron a hacer mi estadía en Puebla, ahora mi segundo hogar, mucho más placentera y significativa, dejando un lugar permanente en mi corazón.

Asimismo, quiero expresar mi gratitud al Consejo Nacional de Humanidades Ciencia y Tecnología (CONAHCyT) por otorgarme la beca de posgrado que hizo posible la realización de mis estudios de maestría en el INAOE.

Resumen

Como seres humanos, debemos ser capaces de comunicarnos con nuestro entorno. Esto puede lograrse de dos formas: una es modificando nuestro entorno mediante mecanismos musculares, y la otra es expresando sentimientos, deseos y/o ideas. Gracias a los avances tecnológicos, esta comunicación también puede darse mediante la interacción entre humanos y computadoras, utilizando hardware, software y aplicaciones apropiadas. Estas pueden ser de gran ayuda para aquellas personas que, por algún motivo, se ven privadas de alguna de estas formas de comunicarse con su entorno. Para esto es necesario recurrir a sistemas que puedan apoyar a estas personas en sus actividades diarias. Estos sistemas se denominan interfaces cerebro-computadora (BCI, por sus siglas en inglés). Los sistemas BCI se basan en el registro de señales de la actividad cerebral mediante electroencefalogramas (EEG). Estas BCI cuentan con una gran cantidad de investigaciones que se basan en señales de control, abordando diversos neuro-paradigmas (Potenciales Evocados, potencial P300, imaginación motora y habla imaginada), que suelen ser muy complejos y requieren una gran cantidad de tiempo para su entrenamiento y uso, llegando a ser específicos para cada usuario. En consecuencia, la presente tesis explora un método alternativo que se basa en las señales EEG de los movimientos oculares verticales, acción de morder, así como los gestos faciales y los ojos cerrados.

El objetivo de este trabajo es analizar y clasificar las señales EEG registradas durante la ejecución de estas acciones mencionadas, para asociarlas a comandos y su posible uso en sistemas BCI. La investigación se basa en el reconocimiento de estas acciones en las señales EEG para los comandos de avanzar, izquierda, derecha y encender. Se registraron las señales EEG de 25 sujetos, después de la eliminación de señales no aptas para el estudio, quedaron 21 sujetos, y el problema fue abordado con un algoritmo de clasificación supervisada.

La selección de los canales con los que se trabajó fue mediante un análisis visual, en el cual se tomaron los canales donde se apreciaban mejor las acciones deseadas, obteniendo un total de 6 canales. Se cortaron secciones de 5 segundos donde se encontraba la acción deseada. Se obtuvieron 21 cortes por cada acción, en cada uno de los 6 canales, obteniendo un total de 126 cortes por acción por sujeto, y un total de 2646 cortes de señales por acción.

Para la primera clasificación se obtuvieron 21 características y cinco clases (3 parpadeos continuos, Fruncir el ceño, morder, Levantar las cejas y señal sin alguna acción). Para esta clasificación, donde se tomaron los 6 canales y las cinco acciones, se obtuvo un porcentaje de exactitud de 39.54 % +/- 6.80 % para Random Forest, 44.90 % +/- 6.63 % para un modelo de Máquina de Soporte Vectorial (SVM, por sus siglas en in-

glés) y 44.68 % +/- 7.27 % para un segundo modelo de SVM.

Al analizar y probar que dos canales y dos clases presentaban una mayor confusión en la clasificación, se optó por dejarlos fuera de los modelos de clasificación y mejor identificarlos por su frecuencia en esos dos canales (O1 y O2).

En el segundo modelo del clasificador se trabajó con 21 características extraídas, 3 clases (3 parpadeos continuos, levantar las cejas y señal sin ninguna acción) y con 4 canales y las dos acciones que se identificaron con el análisis de la frecuencia con los que estos dos (Acción de morder y ojos cerrados) se identifican mas (>30 Hz y >8 Hz, <12 Hz respectivamente). Obteniendo un porcentaje de exactitud del 66.50 % +/- 10.92 % para Random Forest, 72.48 % +/- 10.3 % para el primer modelo de SVM y 72.84 % +/- 9.69 % para el segundo modelo de SVM, los modelos de SVM varían en los valores de los hiperparámetros. Esto proporciona evidencia de que se pueden identificar estas acciones para su futura implementación de comandos en sistemas BCI.

Abstract

As human beings, we need to be able to communicate with our environment. This can be achieved in two ways: one is by modifying our environment through muscular mechanisms, and the other is by expressing feelings, desires and/or ideas. Thanks to technological advances, this communication can also take place through human-computer interaction, using appropriate hardware, software, and applications. These can greatly help people who, for whatever reason, are deprived of one of these ways of communicating with their environment. This requires the use of systems that can assist these people in their daily activities. These systems are called Brain-Computer Interfaces (BCI). BCI systems are based on the recording of brain activity signals using electroencephalograms (EEG). These BCIs have been the subject of a great deal of research based on control signals, addressing different neuro-paradigms (evoked potentials, P300 potential, motor imagery and imagined speech), which are usually very complex and require a great deal of time for training and use, becoming user-specific. Therefore, this thesis explores an alternative method based on EEG signals from vertical eye movements, biting, facial gestures, and closed eyes.

This work aims to analyze and classify the EEG signals recorded during the execution of these actions, to associate them with commands, and to consider their possible use in BCI systems. The research is based on the recognition of these actions in the EEG signals for the commands forward, left, right and on. The EEG signals of 25 subjects were recorded, and after eliminating signals unsuitable for the study, 21 subjects remained, and the problem was approached with a supervised classification algorithm. The selection of the channels to work with was done by visual analysis, taking the channels where the desired actions were best appreciated, resulting in a total of 6 channels. Segments of 5 seconds were cut where the desired action was found. A total of 21 slices were obtained for each action, in each of the 6 channels, giving a total of 126 slices per action per subject, and a total of 2646 signal slices per action.

For the first classification, 21 features and five classes were obtained (3 continuous blinks, frowning, biting, eyebrow-raising, and signal without action). For this classification, using the 6 channels and the 5 actions, the accuracy percentage obtained was 39.54 % +/- 6.80 % for Random Forest, 44.90 % +/- 6.63 % for a Support Vector Machine (SVM) model, and 44.68 % +/- 7.27 % for a second SVM model.

Having analyzed and verified that two channels and two classes caused the most confusion in the classification, it was decided to remove them from the classification models and to identify them better by their frequency in these two channels (O1 y O2).

In the second classifier model, we worked with 21 extracted features, 3 classes (3 continuous blinks, eyebrow-raising and no action signal) and 4 channels. The two actions

not included in the classification model were identified by analyzing the frequency with which these two actions (biting and eyes closed) were most often identified (>30 Hz and >8 Hz, <12 Hz respectively). The accuracy obtained was 66.50 % +/- 10.92 % for Random Forest, 72.48 % +/- 10.3 % for the first SVM model, and 72.84 % +/- 9.69 % for the second SVM model. This shows that these actions can be identified for future implementation of commands in BCI systems.

Índice general

Índice general	VII
Índice de figuras	1
Índice de Tablas	5
1. Introducción	6
1.1. Problemática	7
1.2. Hipótesis	8
1.3. Motivación	8
1.4. Objetivos	9
1.4.1. Objetivo General	9
1.4.2. Objetivos Específicos	9
1.5. Contribuciones	9
1.6. Alcances y limitaciones	10
1.7. Estructura del documento	10
2. Marco Teórico	12
2.1. Sistema nervioso	12
2.2. Encéfalo	13
2.2.1. Cerebro	14
2.3. Bioseñales	15
2.4. Adquisición de las bioseñales.	15
2.4.1. Adquisición de la actividad cerebral.	16
2.4.2. Electroencefalografía	17
2.5. Interfaces Humano Computadora	19
2.5.1. Interfaces cerebro computadora	19
2.6. Señales de control	21
2.6.1. Potenciales Evocados (PE)	21
2.6.2. P300	22
2.6.3. Ritmos Sensomotores	22
2.6.4. Movimientos oculares verticales	23
2.7. Métodos de extracción de características	23
2.7.1. Transformada de Fourier	24
2.7.2. Transformada de Wavelet	25

2.7.3.	Trasformada de Hilbert-Huang	26
2.8.	Métodos de clasificación de características	26
2.8.1.	Maquina de Soporte Vectorial (SVM)	27
2.8.2.	Random Forest	31
3.	Antecedentes	33
3.1.	Trabajo relacionado	34
3.1.1.	Enfoque de red neuronal convolucional 1D	34
3.1.2.	Un algoritmo para reconocer parpadeos voluntarios	35
3.1.3.	Parpadeos voluntarios	36
3.1.4.	Un parpadeo de un solo electrodo	37
3.1.5.	Parpadeos controlados por el usuario.	38
3.1.6.	Sistema BCI híbrido que utiliza SSVEP y parpadeos	39
3.1.7.	Hacia una interacción BCI más intuitiva y cómoda mediante señales EEG relacionadas con los parpadeos y gestos faciales.	40
4.	Metodología	41
4.1.	Diseño experimental para la captura de señales EEG que son de nues- tro interés.	42
4.1.1.	Búsqueda y selección de los participantes	44
4.1.2.	Cartas de consentimiento informado	45
4.1.3.	Protocolo del estudio	45
4.1.4.	Obtención de datos.	46
4.1.5.	Procedimiento de toma de datos.	46
4.1.6.	Normalización	48
4.2.	Análisis de las señales y extracción de características.	48
4.2.1.	Análisis de las señales	48
4.2.2.	Selección de canales a analizar	53
4.2.3.	Filtrado	54
4.2.4.	Procesamiento de las señales y extracción de características	54
4.2.5.	Trasformada Rápida de Fourier y Densidad Espectral de Po- tencia	54
4.2.6.	Trasformada Wavelet Discreta	55
4.2.7.	Transformada de Hilbert-Huang	55
4.2.8.	Transformada de Wavelet Continua	56
4.3.	Clasificación de las características.	56
4.3.1.	App Classification Learner Matlab	56
4.3.2.	Modelo Entrenado	57
4.4.	Prueba y validación del modelo entrenado.	57
4.4.1.	Matlab	57
5.	Resultados	59
5.1.	Base de datos	59
5.2.	Procesamiento de las señales	60
5.3.	Características obtenidas	66
5.4.	Clasificación con la aplicación de Matlab	67

5.5. Dispersión del Accuracy entre hombres y mujeres.	74
6. Conclusiones	78
6.1. Trabajo a futuro	79
Bibliografía	81
A. Carta de consentimiento informado	88
B. Tablas de los resultados obtenidos por cada sujeto	91
C. Visualización de cada acción en los respectivos canales seleccionados y proceso que se llevo acabo en cada acción	113

Índice de figuras

1.1. Arquitectura general de una BCI.	7
1.2. Porcentaje de la población con discapacidad según dificultad en la actividad [1].	8
2.1. Sistema nervioso	13
2.2. Hemisferios cerebrales y sus cisuras.	14
2.3. Lóbulos cerebrales ([2]).	15
2.4. Posición de los electrodos EEG, ECoG y neurona única [3].	17
2.5. Distribución del Sistema Internacional 10-20 [4].	18
2.6. Combinación de dos señales (Señal A y señal B) en diferentes frecuencias y la transformada de Fourier (Señal D) que muestra las frecuencias que la señal nueva presenta (Señal C)	25
2.7. Separación por un subespacio unidimensional (hiperplano) dividiendo un conjunto de datos (conjunto de datos representados por los colores rojo y morado) en 2 dimensiones [5]	28
2.8. Separación de los datos por más de un subespacio unidimensional (hiperplano) [5]	28
2.9. Separación óptima del subespacio unidimensional (hiperplano) de los conjuntos de datos [5]	29
2.10. La imagen muestra dos conjuntos de datos, representados por puntos rojos y azules, que se entremezclan en una región. [5]	29
2.11. Separación de dos conjuntos de datos por medio de un subespacio unidimensional [5]	30
2.12. La representación tridimensional de datos y la separación de estos mediante un hiperplano [5].	30
2.13. En la imagen se presentan los distintos núcleos (kernels) que pueden aplicarse a las Máquinas de Vectores de Soporte (SVM). El kernel lineal permite la separación de datos mediante una línea recta. Por otro lado, el kernel polinomial posibilita la separación de los datos en clases mediante una curva. El kernel RBF (Radial Basis Function) separa las clases mediante una curva suave que se ajusta a los datos. Finalmente, el kernel Sigmoid separa las clases a través de una curva con forma de S.	31

2.14. Predicción con Random Forest: En cada árbol, se destaca el camino seguido hasta alcanzar el nodo final. En cada nodo terminal, se especifica el índice de las observaciones de entrenamiento que lo componen [6]	32
4.1. Etapas de la metodología propuesta.	41
4.2. Señales EEG en el software EmotivPro, se marcan las señales en un recuadro negro cuando el sujeto esta haciendo tres parpadeos seguidos y con una flecha los canales que se seleccionaron.	43
4.3. Señales EEG en el software EmotivPro, se marcan en un recuadro negro cuando el sujeto esta haciendo la acción de fruncir ceño y con una flecha los canales que se seleccionaron.	43
4.4. Señales EEG en el software EmotivPro, se marcan en un recuadro negro cuando el sujeto esta haciendo la acción de levantar las cejas y con una flecha los canales que se seleccionaron.	44
4.5. Señales EEG en el software EmotivPro, se marcan en un recuadro negro cuando el sujeto esta haciendo la acción de morder y con una flecha los canales que se seleccionaron.	44
4.6. Señal de un sujeto de prueba que a la mitad de la prueba empezó a presentar mucho ruido, esto debido a un problema con la diadema ya que los electrodos dejaron de hacer contacto con el cuero cabelludo, las flechas marcan donde empezó el ruido	49
4.7. Se tomo el primer canal, se observa el momento cuando empieza el problema con la señal, la flecha marca donde empieza a notar mas el ruido.	49
4.8. Señal de un canal de un sujeto de prueba donde se aprecian 3 secciones de interés donde están ocurriendo las acciones a analizar.	50
4.9. Ampliación de la primera sección de la imagen. Secciones donde se ejecutan las acciones deseadas. 1) Sección donde se realizan 3 parpadeos continuos 7 veces en aproximadamente en un minuto, 2) Sección donde se realiza la acción de fruncir ceño por 5 segundos 7 veces en poco mas de un minuto, 3) Sección donde se realiza la acción de morder por 5 segundos 7 veces en poco mas de un minuto, 4) Sección donde se realiza la acción de fruncir el ceño por 5 seguidnos 7 veces en poco mas de un minuto. 4.8	50
4.10. Se señalan con flechas las primeras 7 repeticiones de la acción de 3 parpadeos continuos teniendo una duración de 5 segundos las secciones señaladas.	51
4.11. Se señalan con flechas las primeras 7 repeticiones de la acción de Fruncir el ceño teniendo una duración de 5 segundos las secciones señaladas.	52
4.12. Se señalan con flechas las primeras 7 repeticiones de la acción de Morder teniendo una duración de 5 segundos las secciones señaladas.	52
4.13. Se señalan con flechas las primeras 7 repeticiones de la acción de levantar las cejas teniendo una duración de 5 segundos las secciones señaladas.	53

4.14. Visualización de todos los canales de la Diadema EMOTIV y se marcan en un recuadro las señales de los canales con los que se va a trabajar.	54
4.15. Ondicula db4 Wavelet.	55
5.1. Se señalan con flechas las primeras 7 repeticiones de la acción de 3 parpadeos continuos.	60
5.2. Información que contiene cada carpeta, en este caso se muestra la carpeta donde se encuentran los cortes de las señales de 3 parpadeos continuos y el nombre con el que se guardaron los cortes de la senal0001 hasta la senal2646.	60
5.3. Corte de la acción de 3 parpadeos continuos sin filtro.	61
5.4. Corte de la acción de 3 parpadeos con filtro de 2 a 40 Hz.	61
5.5. Corte de la acción de 3 parpadeos con filtro de 2 a 40 Hz.	62
5.6. Señal después de la DWT como reducción de ruido	63
5.7. Amplitud obtenida del valor absoluto del resultado de la Transformada de Hilbert	64
5.8. Datos de la segunda división de la transformada de Hilbert	64
5.9. Escalograma de magnitud, las zonas amarillas representan una magnitud alta en las frecuencias que oscilan entre los 2 y 2.8 Hz entre el primer y cuarto segundo.	65
5.10. Energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo	66
5.11. Cortes de cada canal mostrando cada sección de 3 parpadeos continuos, acercando una sección de un canal frontal y un canal occipital.	69
5.12. Matriz de confusión de cada modelo de clasificación entrenado de el sujeto 5	70
5.13. Matriz de confusión de cada modelo entrenado de el sujeto 8	71
5.14. Gráfica de dispersión del Accuracy de cada sujeto en los 3 modelos entrenados (Con mediana inclusiva)	73
5.15. Gráfica de dispersión del Accuracy de cada sujeto en los 3 modelos entrenados dividió entre Hombres y Mujeres (Con mediana Inclusiva)	74
5.16. Visualización cuando un sujeto se encuentra con los ojos cerrados con la representación de la señal Alfa en uno de los canales Occipitales	76
5.17. A) Frecuencia en los 6 canales seleccionados, B) En verde se muestra los canales Occipitales y el mensaje que se despliega cuando en estos dos canales se encuentra la frecuencia de 8 a 12 Hz, C) En verde se muestran los canales Occipitales y el mensaje que se despliega cuando estos dos canales se encuentran en las frecuencias entre 25 a 35 Hz y en las partes naranjas y rojas muestra que cuando en los dos canales no se encuentran en estas frecuencias no muestra ningún mensaje de detección.	77
C.1. Cortes de cada canal mostrando cada sección de Fruncir el Ceño, acercando una sección de un canal frontal y un canal occipital.	113

C.2.	Cortes de cada canal mostrando cada sección de Levantar Cejas, acercando una sección de un canal frontal y un canal occipital.	114
C.3.	De Izquierda a derecha, Señal sin filtro de la acción Levantar las cejas, señal con filtro pasa bandas de 2 a 40Hz y señal después de la eliminación de ruido con Wavelet db4.	114
C.4.	De Izquierda a derecha, trasformada de Hilbert Amplitud vs tiempo y fase vs tiempo, segundo dato del resultado de Hilbert. Acción Levantar las Cejas.	114
C.5.	De Izquierda a derecha, escanograma de CWT energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo. Acción Levantar las Cejas	115
C.6.	De Izquierda a derecha, Señal sin filtro de la acción Morder, señal con filtro pasa bandas de 2 a 40Hz y señal después de la eliminación de ruido con Wavelet db4.	115
C.7.	De Izquierda a derecha, trasformada de Hilbert Amplitud vs tiempo y fase vs tiempo, segundo dato del resultado de Hilbert. Acción Morder.	115
C.8.	De Izquierda a derecha, escanograma de CWT energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo. Acción Morder	116
C.9.	De Izquierda a derecha, Señal sin filtro de la acción FruncirCeño, señal con filtro pasa bandas de 2 a 40Hz y señal después de la eliminación de ruido con Wavelet db4.	116
C.10.	De Izquierda a derecha, trasformada de Hilbert Amplitud vs tiempo y fase vs tiempo, segundo dato del resultado de Hilbert. Acción Fruncir Ceño.	116
C.11.	De Izquierda a derecha, escanograma de CWT energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo. Acción Fruncir Ceño	117

Índice de Tablas

1.1. Lista de tareas priorizadas.	10
2.1. Dispositivos de toma de datos EEG.	20
4.1. Tareas realizadas en una de las secciones del protocolo.	47
4.2. Hiperparámetros establecidos por cada modelo de clasificación.	57
5.1. Técnica aplicada a la señal y características extraídas.	67
5.2. Promedio y desviación estándar del porcentaje de precisión de los modelos probados con cada sujeto de prueba.	68
5.3. Promedio y desviación estándar del porcentaje de los modelos probados con cada sujeto de prueba, excluyendo los canales Occipitales, así como las clases de fruncir ceño y morder.	70
5.4. Accuracy de los modelos entrenados con el sujeto 5	70
5.5. Accuracy de los modelos entrenados con el sujeto 8	71
5.6. Acciones que se podrían asociar a cada acción identificada	77

Capítulo 1

Introducción

Con el desarrollo de nuevas tecnologías, se han propuesto diferentes alternativas que pueden ampliar las formas en las que las personas pueden usar máquinas o dispositivos electrónicos para comunicarse o bien expresar alguna intención una de estas formas es la interacción humano-máquina (HCI, por sus siglas en inglés), pero, especialmente para personas con discapacidades motrices una de las formas por las cuales estas personas pueden comunicarse con su entorno sin la necesidad de utilizar los extremidades superiores e inferiores, es por medio de las interfaces cerebro computadora (BCI, por sus siglas en inglés) [7]. En los últimos años, uno de los campos más investigados junto con la biomedicina ha sido el de las Interfaces Cerebro-Computadora (BCI). Las BCI son particularmente importantes para pacientes con trastornos del movimiento, como parálisis severa, esclerosis lateral amiotrófica o el síndrome de locked-in, donde existe poca o ninguna capacidad de control del movimiento residual [8].

Con base en esto, se pretende alcanzar una interpretación de las ondas cerebrales que, a simple vista, podrían parecer totalmente aleatorias. Para lograrlo, se exploraron las señales EEG y se les aplicaron diversos métodos matemáticos que permiten obtener información relevante para entender las ondas cerebrales ante distintas situaciones, como los estímulos externos inducidos por la visión o el sonido, la concentración y la pronunciación de palabras imaginadas [8].

La forma de obtener estas señales eléctricas del cerebro es por medio del electroencefalograma (EEG) y estos se pueden clasificar según su método de adquisición: invasivo y no invasivo [8]. Las BCI (por sus siglas en inglés) basadas en EEG extraen características específicas en tiempo real (Figura 1.1) de patrones producidos por las señales eléctricas del cerebro, y se emplean para operar dispositivos externos que pueden ser computadoras, conmutadores o punteros, prótesis [9] o bien algún dispositivo con el cual se pueda desplazarse como lo es una silla de ruedas eléctrica.

Un sistema BCI utiliza características extraídas de las señales EEG para permitir que el usuario se comunique con el mundo exterior. Las señales más utilizadas han sido los Ritmos Sensorio Motores (SMR, por sus siglas en inglés), los Potenciales Corticales Lentos (SCP, por sus siglas en inglés), el Potencial relacionado con eventos (ERP,

por sus siglas en inglés), Potenciales Evocados Visuales en Estado Estable (SSVEP, por sus siglas en inglés) y Asociada a Imágenes Motoras (MI, por sus siglas en inglés) [9], [10], [11].

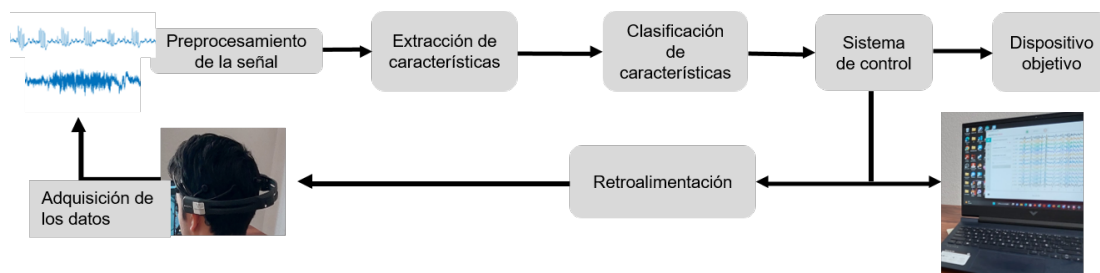


Figura 1.1: Arquitectura general de una BCI.

Otra señales que se ha utilizado para las BCI han sido los movimientos oculares verticales, que son movimientos naturales producidos por las personas (comúnmente conocidos como parpadeos) estos pueden ser intencionales o no intencionales, estos se producen cuando los párpados se cierran de manera rápida o lenta para formar una barrera mecánica que proteja al ojo de objetos extraños o bien para contribuir a la distribución homogénea de las lágrimas por la superficie del ojo para mantenerlo continuamente hidratado [12], [13]. Los parpadeos pueden ser fácilmente reconocidos por su amplitud y pueden ser observados en el EEG principalmente en los electrodos frontales.

1.1. Problemática

De acuerdo a la Organización Mundial de la Salud, se estima que en el 2021, mil trescientos millones de personas (el 16 % de la población mundial) tenían una discapacidad significativa. Entre ellas, casi 190 millones tenían dificultades en sus funciones físicas y motrices, y requieren con frecuencia servicios de asistencia. De este grupo, alrededor de 142 millones tenían niveles graves de discapacidad [14]. De acuerdo con el censo de población y vivienda 2020, en México hubo 6,179,890 personas con alguna discapacidad, lo que representa el 4.9 % de la población total del país. Las limitaciones de movilidad de los miembros superiores e inferiores se presentan con mayor frecuencia, siendo esta el 48 % de los casos [1].




Figura 1.2: Porcentaje de la población con discapacidad según dificultad en la actividad [1].

En la figura 1.2 muestra que la suma de estos porcentajes supera el 100 % debido a que una persona puede tener múltiples discapacidades simultáneamente. Esto refleja la dificultad que enfrentan algunas personas para moverse, caminar, desplazarse o subir escaleras debido a problemas de movilidad en los miembros superiores e inferiores, o la ausencia de alguno de ellos. Algunas personas tienen los miembros superiores e inferiores, pero no pueden moverlos o tienen restricciones para hacerlo, así como dificultades para hablar o comunicarse. Estas personas a menudo necesitan asistencia constante. Para ellos, puede ser difícil entender a las personas con estas discapacidades, ya sea para saber adónde quieren ir, si desean moverse o no, o para expresar sus propios pensamientos.

1.2. Hipótesis

Mediante un algoritmo de clasificación de señales EEG registradas durante el análisis y procesamiento de un conjunto reducido de gestos faciales seleccionados, es posible asociarlos con comandos que podrán ser utilizados en una interfaz cerebro-computadora para su potencial aplicación en acciones de apoyo.

1.3. Motivación

Como seres humanos somos capaces de comunicarnos con nuestro entorno o bien responder a estímulos del ambiente, esta respuesta se logra a través de dos vías esenciales:

- Modificando nuestro entorno en forma directa a través de los mecanismos musculares.
- Expresando los sentimientos, deseos y/o ideas por medio de la comunicación.

No obstante, en algunos casos las funciones motrices se ven comprometidas debido a las lesiones medulares, infarto cerebral, esclerosis lateral amiotrofica, esclerosis múltiple, distrofia muscular, tumores, accidentes o bien desde nacimiento se tienen estas

limitaciones, sufriendo daños parciales o totales en las extremidades, provocando pérdida de la capacidad de repuesta natural (parcial o total) a su entorno. Este tipo de discapacidades dio lugar al desarrollo de estas tecnologías buscando hacer una vida más amena para estas personas ayudándolas a desplazarse por cuenta propia, disminuyendo la necesidad de que otras personas las estén desplazando.

1.4. Objetivos

1.4.1. Objetivo General

- **Clasificar** las señales EEG generadas de ojos cerrados, parpadeos, mordida y gestos faciales para proponer comandos que sean útiles para una interfaz cerebro computadora.

1.4.2. Objetivos Específicos

- **Diseñar** un protocolo para adquirir las señales EEG de ojos cerrados, parpadeos, mordida y gestos faciales
- **Identificar** las características de las señales EEG de ojos cerrados, parpadeos, mordida y gestos faciales así como los canales donde se observan/presentan más estas señales.
- **Definir** el proceso de extracción de características de las señales EEG producidas por ojos cerrados, parpadeos, mordida y gestos faciales
- **Implementar** un modelo de clasificación de las señales EEG mencionadas anteriormente, para asociarlos a comandos y su posible uso en sistemas BCI (Interfaz Cerebro-Computadora).

1.5. Contribuciones

La principal contribución que se lograría con este proyecto de investigación, si bien no busca sustituir a aquellos sujetos que están asistiendo a las personas con alguna discapacidad, podría ser de gran utilidad para las personas con enfermedades y/o discapacidades. Esto les permitiría desplazarse libremente, colaborando así con los asistentes para saber dónde desean dirigirse. Además, otra función que se podría plantear es controlar un cursor en la pantalla o seleccionar bloques de palabras predefinidas (como "comer", "ir al baño", "apagar/prender "x" cosa ", etc.). Esto ayudaría a comunicar sus necesidades en cierto momento.

Se proponen comandos para cada acción analizada. Los comandos de mayor importancia son "avanzar", "derecha" e "izquierda", y el usuario podrá seleccionar qué comando asociar a cada acción realizada.

Se va a obtener un corpus compuesto de señales EEG registradas durante las acciones anteriormente mencionadas, los corpus de cada acción van a tener señales EEG de los 21 sujetos en dicha acción teniendo un total de 2646 cortes de señales de cada acción.

El corpus anteriormente mencionado se podrá usar para trabajos a futuro, también se podría aumentar los datos de este mismo.

1.6. Alcances y limitaciones

Durante el presente proyecto se desarrollará el diseño de un protocolo para la creación de una base de datos de 2646 cortes de señales EEG. Los gestos faciales que se utilizarán son: fruncir ceño, levantar cejas, 3 parpadeos, morder y ojos cerrados. Se utilizarán 6 canales: AF3, AF4, F7, F8, O1 y O2 de cada uno de los 21 sujetos. Se ha establecido el alcance del trabajo, y se procederá con la construcción de una lista de tareas priorizadas, la cual se muestra en la tabla a continuación: 1.1.

Tabla 1.1: Lista de tareas priorizadas.

No.	Descripción.
1.	El algoritmo debe de clasificar las señales de las acciones realizadas.
2.	Se van a proponer comandos a cada acción realizada.
3.	Para la captura de las señales de los gestos y parpadeos se utilizara la diadema Emotiv Epoc +.
4.	Los gestos faciales que se utilizaran son: 3 parpadeos (los dos ojos), fruncir ceño, morder, levantar cejas, ojos cerrados.
5.	El usuario podrá configurar que gesto se asocia a que comando.

La limitación de los resultados obtenidos radica en que no se puede garantizar su efectividad en personas con discapacidad motora, ya que los datos utilizados provienen de individuos sin dicha condición..

1.7. Estructura del documento

El resto del documento se compone de 5 capítulos, los cuales son descritos brevemente a continuación. Ya hemos cubierto el capítulo 1, que contiene la introducción. En el capítulo 2 “Marco Teórico” se describen los principales conceptos que dan soporte a la propuesta. En el capítulo 3 “Trabajo relacionado” se describe una serie de trabajos que están relacionados con la actual propuesta. En el capítulo 4 “Método propuesto” se describen los componentes principales de la propuesta para tratar la problemática.

En el capítulo 5 “Experimentos y resultados” se presentan los experimentos y resultados más relevantes obtenidos durante el trabajo de Maestría. Por último, en el capítulo 6 “Conclusiones y trabajo futuro” se presentan las conclusiones preliminares del trabajo, y se da una perspectiva acerca del trabajo por realizar para tratar de refinar la solución propuesta.

Capítulo 2

Marco Teórico

En este capítulo se presentan algunos conceptos básicos que van a ser utilizados a lo largo del documento tales como: el cerebro, las bioseñales, electroencefalograma, interfaces humano computadora, interfaces cerebro computadora, transformada de Fourier, transformada de wavelet discreta, los clasificadores. En las siguientes secciones se describen brevemente cada uno de los conceptos anteriormente mencionados.

2.1. Sistema nervioso

El sistema nervioso se divide en dos partes: el sistema central y el sistema periférico. El sistema nervioso central (SNC) se encuentra ubicado en el eje central del cuerpo formado por el cerebro y la médula espinal, ubicados dentro de las cavidades craneal y espinal, respectivamente. El sistema nervioso periférico (SNP) incluye todos los nervios fuera del cerebro y los nervios fuera de la médula espinal, incluidos los nervios cerebroespinales y los ganglios periféricos. Estos últimos son fundamentales porque proyectan impulsos nerviosos a órganos y músculos (eferentes), que nos permiten mover nuestras extremidades. Estos nervios también pueden realizar la ruta opuesta, transportando información sensorial al cerebro (aférentes) para respuestas motoras a los estímulos [15].

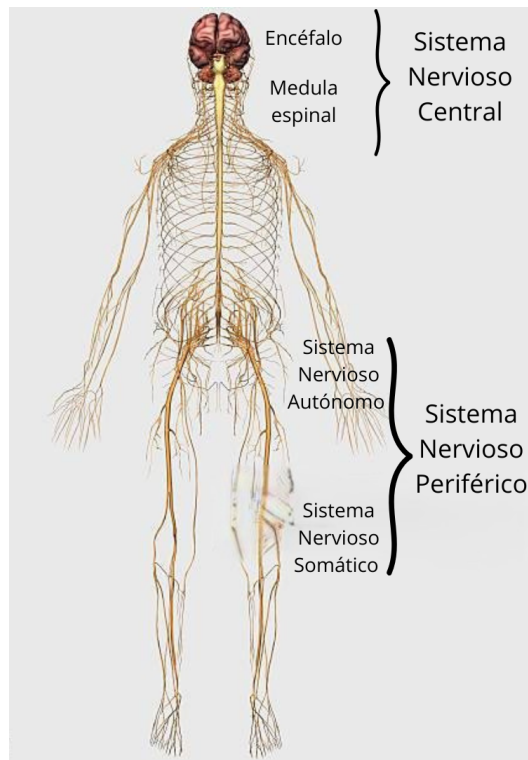


Figura 2.1: Sistema nervioso

La función principal del sistema nervioso es comunicarse con nuestro entorno y dentro de nuestro cuerpo. Asimismo, dentro del sistema nervioso podemos distinguir el somático, que conduce mensajes sensoriales al cerebro y mensajes motores a los músculos, y el autónomo, que regula funciones corporales como la frecuencia cardíaca y la respiración. El SNS actúa a través de los músculos esqueléticos para regular las acciones voluntarias y reflejas, mientras que el SNA regula la actividad muscular involuntaria, como el músculo cardíaco y el músculo liso [15] [16].

2.2. Encéfalo

El encéfalo está formado principalmente por: el tronco encefálico, el cerebelo y el cerebro ubicado en el cráneo. El tronco del encéfalo se divide a su vez en tres partes, a saber: el bulbo raquídeo, ubicado en la parte inferior del tronco del encéfalo, conecta la médula espinal, luego la protuberancia y finalmente el mesencéfalo. El cerebelo ocupa la parte inferior posterior de la cavidad craneal detrás de la médula y la protuberancia, y finalmente el cerebro, que constituye toda la parte superior del encéfalo [17]. A continuación se describirá a detalle el cerebro y las señales que de él emanan.

2.2.1. Cerebro

Los humanos tienen uno de los cerebros más grandes y complejos en comparación con otros animales, y el desarrollo de capacidades cognitivas superiores les ha dotado de comportamientos específicos de cada especie [18]. Es la parte más grande del encéfalo y el órgano neural más importante, consta de dos hemisferios, parcialmente separados por una fisura (cisura interhemisférica) que lo divide en hemisferios izquierdo y derecho (Figura 2.2). La superficie exterior de los hemisferios cerebrales, conocida como corteza cerebral, cuya función principal es recibir información de los órganos sensoriales, está formada principalmente por cuerpos neuronales, axones amielínicos y astrocitos protoplasmáticos (materia gris), que se encuentran en patrones complejos y están divididos en regiones por fisuras llamadas surcos.




Figura 2.2: Hemisferios cerebrales y sus cisuras.

Cada hemisferio realiza una función diferente, es decir, el hemisferio izquierdo se encarga de las tareas lógicas y analíticas mientras que el hemisferio derecho se encarga de la parte creativa e intuitiva. Cada hemisferio, a su vez, está dividido en cuatro lóbulos, que reciben el nombre de los huesos que lo rodean: frontal, parietal, temporal y occipital (Figura 2.3) [18], [17], [15], cuyas funciones se enuncian a continuación:

- **Lóbulo frontal:** Responsable de la resolución de problemas y la actividad intelectual, controlando la atención, el comportamiento y el movimiento muscular.
- **Lóbulo Parietal:** Responsable de recibir información sensorial de todo el cuerpo así como procesar la información espacial.
- **Lóbulo Temporal:** Es responsable del procesamiento de la audición, memoria y emociones.
- **Lóbulo occipital:** Es responsable de la visión y en la percepción de los colores.




Figura 2.3: Lóbulos cerebrales ([2]).

2.3. Bioseñales

El término bioseñal abarca un grupo de señales producidas en todos los organismos vivos. En el cuerpo humano, cada músculo y nervio genera potenciales, voltajes e intensidades de campos eléctricos que representan la actividad y el comportamiento de los órganos, proporcionando información sobre si los órganos están en buenas condiciones. Los eventos biológicos que ocurren en el cuerpo humano producen actividades mecánicas, eléctricas y químicas. Esto significa que estos eventos generan señales para análisis y diagnóstico médico que posteriormente pueden ser medidas y monitoreadas [19], [20].

Se pueden dividir en los siguientes tipos: electrocardiograma (ECG) es un registro de la actividad eléctrica producida por el corazón, electromiografía (EMG) es un registro de señales eléctricas producidas por el movimiento de los músculos esqueléticos y electrooculograma (EOG) es un registro de la actividad eléctrica asociada al movimiento ocular. Los cambios y la electroencefalografía (EEG) registran la actividad espontánea del cerebro a través de electrodos colocados en el cuero cabelludo. Las señales biológicas representan el flujo de corrientes iónicas en varios órganos (corazón, músculos, cerebro y ojos) y la medición de estos potenciales de tejido vivo superficial implica amplitudes de voltaje muy pequeñas que van desde $1\mu\text{V}$ a $100\mu\text{V}$ [20].

El elemento básico del cerebro es la neurona, una célula que se comunica con las células de su alrededor transmitiendo información a través de impulsos eléctricos. Las ondas cerebrales son una actividad eléctrica producida por el cerebro como resultado de la transmisión de mensajes a través de los axones de las neuronas. Son ondas de voltaje de baja amplitud (10 a $100\mu\text{V}$) con frecuencias en el rango de 1 a 100 Hz [21].

2.4. Adquisición de las bioseñales.

Las ondas en las frecuencias anteriores se pueden capturar y guardar para su posterior análisis. Los circuitos de adquisición de bioseñales utilizan básicamente los mismos principios, como alta amplificación, impedancia de entrada y resistencia a la interferencia eléctrica, pero tienen características diferentes, como amplitud, ancho de banda de frecuencia y posición de los electrodos.

2.4.1. Adquisición de la actividad cerebral.

Dependiendo del alcance de la medición, existen cuatro tipos de grabación, en dos modalidades: invasiva y no invasiva: Registro de neuronas individuales mediante microelectrodos: un microelectrodo es un sensor con una punta muy fina que es capaz de registrar la actividad de una sola neurona o de un pequeño grupo de neuronas de forma individual. Se trata de una técnica invasiva porque los electrodos utilizados se implantan quirúrgicamente directamente en la corteza cerebral.

Grabación con macroelectrodos: Registra los potenciales postsinápticos de miles de millones de células neuronales en la zona que rodea dicho electrodo. Estos electrodos se pueden colocar en áreas estratégicas del cuero cabelludo, una técnica llamada electroencefalografía (EEG). Se trata de una técnica no invasiva ya que no se requiere cirugía para colocar estos electrodos [22].

Registro con neuromagnetómetros: La magnetoencefalografía (MEG) es una técnica científica que se basa en la detección de los campos magnéticos generados por las corrientes eléctricas que fluyen a través de los axones neuronales. Esta técnica utiliza detectores superconductores conocidos como SQUID (Dispositivos Superconductores de Interferencia Cuántica) para medir campos magnéticos extremadamente débiles que son imperceptibles para otros sensores. La magnetoencefalografía es considerada una técnica no invasiva, ya que no requiere intervención quirúrgica para la detección de estos campos magnéticos [22].

Registro con infrarrojo: La espectroscopia funcional de infrarrojo cercano (fNIRS) es un método científico de imágenes ópticas que permite realizar mediciones no invasivas. Este enfoque utiliza una ventana óptica en el rango del infrarrojo cercano (700 - 900 nm), que es casi transparente para la piel, los huesos y el tejido cerebral. La fNIRS se basa en la respuesta hemodinámica del cerebro, la cual se relaciona con los cambios en los coeficientes de absorción de la hemoglobina oxigenada (HbO₂) y la hemoglobina desoxigenada (dHb). Estos cambios proporcionan información sobre la actividad cerebral y se pueden medir de manera no invasiva [23].

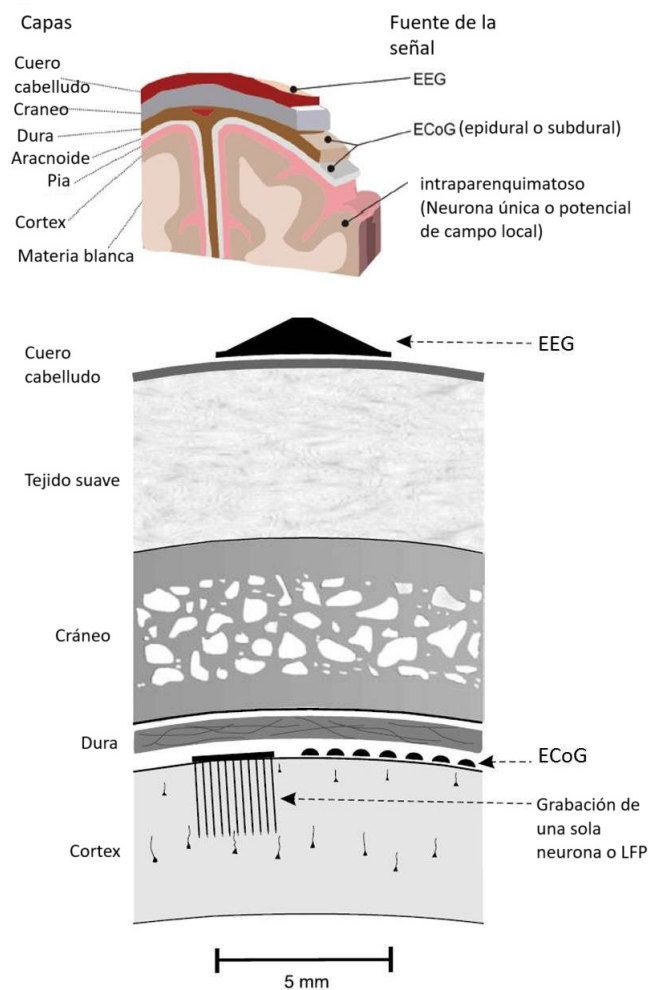


Figura 2.4: Posición de los electrodos EEG, ECoG y neurona única [3].

2.4.2. Electroencefalografía

Históricamente, el EEG ha sido la herramienta más utilizada para medir la actividad cerebral. Esto es posible gracias a sus características técnicas: de fácil acceso, económico, no invasivo y fácil de implementar. En 1920, Hans Berger fue el primero en demostrar que la actividad del cerebro humano produce corrientes eléctricas que pueden medirse con electrodos colocados en el cuero cabelludo. En 1973, Jacques Vidal acuñó el término “interfaz cerebro-computadora, definiéndolo como: “ el uso de señales cerebrales en el diálogo hombre-máquina ” y “un medio para controlar máquinas externas como computadoras y prótesis” [24].

La electroencefalografía registra los campos eléctricos generados por la actividad de las neuronas de la corteza cerebral mediante electrodos colocados en puntos estratégicos del cuero cabelludo, lo que se denomina Sistema Internacional 10-20, que se refiere a la distribución de estos electrodos Figura 2.5 [25]. Se estima que aproximadamente entre 60 y 100 millones de neuronas que se encuentran en una superficie

de aproximadamente 6 a 10 cm² deben tener actividad sincronizada para formar un campo eléctrico de polar lo suficientemente grande como para ser detectado por electrodos. [26]

Como se mencionó anteriormente, el EEG tiene electrodos que captan la señal que convierten el flujo de corriente iónica del cuerpo en flujo de corriente eléctrica. Estos sensores suelen colocarse en la superficie del cráneo, siguiendo un patrón estandarizado conforme al sistema internacional 10-20, denominado así por la distancia física entre electrodos adyacentes (10 % y 20 % de la distancia total entre cuatro puntos). Los puntos estratégicos del cráneo son el nasión y el inion (de adelante hacia atrás) y el punto preauricular (de derecha a izquierda) (Figura 2.5). El método fue desarrollado para permitir una prueba EEG común y estandarizada para que los resultados puedan compararse, reproducirse y analizarse utilizando métodos científicos. [22]

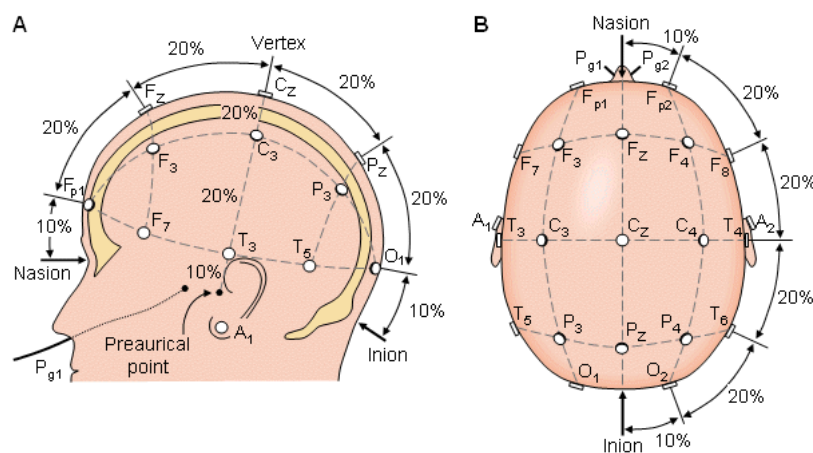


Figura 2.5: Distribución del Sistema Internacional 10-20 [4].

Las amplitudes de las bioseñales registradas se encuentran en el rango de 30 a 100 μ V (microvoltios), y estas señales presentan una frecuencia variable en el tiempo. El EEG es sensible a ruido por artefactos fisiológicos como la actividad cardiaca, movimiento ocular, movimientos faciales, potenciales de la piel y ruido de la corriente eléctrica (60 Hz).

Como se puede apreciar en la Figura 2.5 (sistema 10-20), cada posición se codifica de acuerdo a las siguientes normas:

1. Cada posición recibe, inicialmente, una o dos letras según el sensor correspondiente a un lóbulo (como se mencionó en el apartado "Cerebro" en la Figura 2.3):
 - a) Lóbulo Frontal: letra F
 - b) Lóbulo Occipital: letra O

- c) Lóbulo Parietal: letra P
 - d) Lóbulo Temporal: letra T
2. Después de la letra correspondiente al lóbulo, cada posición recibe un número o la letra "Z" según su posición sagital respecto al centro. Así, los sensores ubicados en el eje de simetría sagital reciben una "Z"; los que se encuentran al lado izquierdo del eje de simetría, dígitos impares; y los que se encuentran al lado derecho del eje de simetría, valores pares.

2.5. Interfaces Humano Computadora

En la interfaz hombre-computadora (HCI), con la ayuda de hardware, software y aplicaciones apropiadas, el usuario ingresa comandos a la computadora y esta responde al usuario de acuerdo con la función del comando diseñado. La interacción entre humanos y máquinas depende del intercambio bidireccional de información entre el usuario y el dispositivo. Se supone que el usuario puede controlar el funcionamiento del dispositivo a través de la información ingresada y las acciones realizadas en el dispositivo, y también se debe considerar la retroalimentación que el dispositivo proporcionará al usuario para que la información se reciba correctamente. Una señal o comando emitido establece una mejor comunicación entre un usuario y una computadora o dispositivo [27].

Debido a los recientes avances tecnológicos, se han propuesto diferentes alternativas para que estos dispositivos HCI puedan ampliar la forma en que las personas se comunican y/o interactúan con dispositivos externos sin dejar atrás a una porción de la población comparable a la República Mexicana con más de 6 millones de habitantes, lo que representa casi el 5 % de la población del país [1]. Estos dispositivos externos pueden ser, el uso de computadoras, prótesis móviles o sillas de ruedas. Para utilizar interfaces humano computadora con personas con alguna discapacidad motora, una de las mejores formas para estas personas es, a través de la actividad cerebral, ya que no involucra el uso de miembros inferiores y superiores. Esta interacción se llama interfaz cerebro-computadora (BCI).

2.5.1. Interfaces cerebro computadora

Los sistemas BCI (por sus siglas en inglés) permiten a los usuarios interactuar con dispositivos externos a través de comunicaciones de hardware y software, sin la intervención de los miembros superiores e inferiores, y detectar la actividad eléctrica generada por el cerebro. Con las interfaces cerebro-computadora se crea un nuevo método de comunicación con dispositivos externos como computadoras, prótesis y sillas de ruedas. Esto podría resultar especialmente relevante para personas con trastornos graves del movimiento, ya que este nuevo método de comunicación podría mejorar su calidad de vida.

El funcionamiento de BCI se puede dividir en cinco etapas: adquisición de señales, pre-procesamiento de señales, extracción de características, traducción o clasificación de características y, finalmente, conversión de características en comandos para controlar el equipo [19], [11]. En la etapa de la adquisición de las señales se ocupa un dispositivo por el cual se puedan observar y guardar las señales EEG. Actualmente en el mercado hay muchos dispositivos para la adquisición de esta señal como se muestra en la tabla 2.1

Tabla 2.1: Dispositivos de toma de datos EEG.

Dispositivo	No. Electrodo	Descripción
Emotiv EPOC+	14 Electrodo y 2 de referencia.	Sensores de Fieltro empapados de solución salina compatibilidad bluetooth y tasa de muestreo 256 Hz.
Emotiv Insight	5 Electrodo y 2 de referencia.	Sensores de polímero semi-seco, compatibilidad bluetooth y tasa de muestreo 128 Hz.
NeuroSky	1 Electrodo y 1 de referencia.	Auriculares con electrodo en la parte frontal, los electrodo de referencia y de tierra se encuentran en el clip para la oreja y tasa de muestro 512 Hz.
Diadema Dry EEG	12 Electrodo y 1 de referencia.	Sensores secos, grabación en microSD o Bluetooth y tasa de muestro 256 Hz.
OpenBCI	De 8 a 16 Electrodo	Sensores de peine de cloruro de plata pasivos y secos, compatibilidad bluetooth y tasa de muestreo 125 Hz.

El instrumento y software empleados en la presente tesis serán el Emotiv EPOC+ de 14 canales a 256 Hz y EmotivPRO versión 3.4.2.444 para el grabado de bioseñales EEG en las sesiones de todos los participantes. Los canales que incluye el dispositivo Emotiv EPOC+ son: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 y AF4 [28].

La etapa de pre-procesamiento consiste en filtrar la señal obtenida aplicando filtros para eliminar las señales que no interesan para el propósito de esta tesis. En la etapa de extracción de atributos, se obtiene información de características de la señal recopilada para crear una serie de vectores de atributos que caracterizan la calidad de la señal recopilada a lo largo del tiempo. Durante la fase de clasificación, se analiza la señal para determinar su categoría utilizando la información contenida en los vectores de atributos. En esta sección, es necesario seleccionar un conjunto de propiedades adecuado para una mejor precisión de clasificación de las señales utilizadas en los

sistemas BCI. Finalmente, en la fase de control del dispositivo externo, convierte la señal clasificada en comandos comprensibles para el dispositivo de destino conectado al BCI (que puede ser un ordenador o una silla de ruedas).

2.6. Señales de control

El objetivo de BCI es interpretar las intenciones del usuario mediante el seguimiento de su actividad cerebral. En estas señales cerebrales se pueden encontrar una variedad de fenómenos relacionados con diferentes tareas cognitivas. Sin embargo, la mayoría de los fenómenos siguen siendo esquivos y aún se desconocen sus orígenes, pero en algunas señales cerebrales generadas voluntariamente se han entendido algunos fenómenos, de modo que el sistema de interfaz cerebro-computadora puede decodificarlos y realizar la comunicación entre el usuario y BCI.

Una gran cantidad de estudios describen señales que pueden usarse como señales de control en sistemas BCI. Sin embargo, en esta sección analizaremos las señales utilizadas en la operación de los sistemas BCI, que incluyen potenciales evocados (PE), P300, ritmos sensorio motores (imágenes motoras) y movimientos oculares verticales.

2.6.1. Potenciales Evocados (PE)

Los potenciales evocados o también llamados respuestas evocadas son respuestas eléctricas registradas desde el sistema nervioso ante la presencia de un estímulo, que pueden ser causadas por eventos sensoriales, motores o cognitivos. [29] Dependiendo del tipo de estímulo que crea el potencial, estos tienden a solidificarse en:

PE visual (VEP): también conocido como potencial evocado visual en estado estacionario (SSVEP), es el tipo de sistema BCI [30], [31], más comúnmente utilizado y consiste en estímulos visuales modulados a una frecuencia fija y ocurre como un evento en la actividad del EEG.

PE auditivo (AEP): también conocido como potencial evocado auditivo en estado estacionario (SSAEP), es el cambio en el potencial eléctrico producido por un estímulo sonoro [32].

PE Somato sensoriales: también conocidos como potenciales evocados somato sensoriales en estado estacionario (SSSEP), son cambios en el potencial provocado a partir de estímulos eléctricos [29], [22].

2.6.2. P300

En el EEG existe un potencial muy importante llamado P300, que es un pico de polaridad positiva que se produce ante varios estímulos poco frecuentes entre una variedad de estímulos frecuentes. [33], [22] La letra P indica que se trata de un potencial evocado positivo, mientras que la 300 define un retraso en el procesamiento cognitivo de unos pocos milisegundos, aunque se han observado retrasos de hasta 700 milisegundos. [22]

El P300 es el potencial endógeno más conocido que surge parcialmente en la corteza parental 300 ms después de la percepción de un estímulo poco frecuente entre varios estímulos frecuentes. Esto sugiere que cuanto menos probable sea que el estímulo sea poco frecuente, mayor será la amplitud del pico producido en la respuesta. Puesto que esta señal generada por el estímulo es infrecuente no es necesario un entrenamiento para el uso en una BCI con este potencial evocado P300, pero el rendimiento de este va bajando mientras más se use ya que el usuario se va acostumbrando a este estímulo infrecuente y por lo tanto la amplitud del potencial va disminuyendo [33]

2.6.3. Ritmos Sensoriomotores

En los ritmos sensoriomotores, los cambios se manifiestan durante una tarea mental, como la visualización de una imagen o la preparación de un movimiento. Estos cambios están representados por los ritmos sensoriomotores Mu y Beta, que se registran en las áreas somatosensoriales y motoras del cerebro. En la corteza cerebral, el ritmo Mu exhibe amplitudes rítmicas de 8 a 12 Hz, mientras que el ritmo Beta exhibe amplitudes rítmicas de 13 a 28 Hz. Cuando la actividad cerebral está relacionada con la ejecución o la imaginación de ciertas tareas motoras, la amplitud de los ritmos sensoriomotores experimenta cambios. Es importante destacar que en la parte motora, el ritmo cambia de Alfa a Mu. Aunque Alfa, Mu y Tau se encuentran en el mismo rango de frecuencias, están ubicados en diferentes regiones cerebrales: el ritmo Alfa se localiza principalmente en la parte posterior, en la región occipital, mientras que el ritmo Mu se encuentra en la región motora. Para cambios con respecto a la magnitud no es necesaria la realización de una tarea motora real, basta con la imaginación de la realización de alguna tarea motora para producir cambios en la magnitud. [34]

Estos ritmos sensoriomotores pueden ser dos modulaciones diferentes, llamadas desincronización relacionada con eventos (ERD) y sincronización relacionada con eventos (ERS), que surgen durante la realización o imaginación de ciertos movimientos. La ERD se asocia con la preparación o iniciación motora que implica atenuación de las amplitudes alfa y beta. La ERS, por otro lado, implica un aumento de la amplitud y se produce tras la ejecución del movimiento y su posterior relajación. [33] Los BCI se pueden diseñar utilizando ritmos sensoriomotores; sin embargo, el control de los ritmos sensoriomotores no es sencillo y la mayoría de las personas tienen dificultades para imaginar movimientos que modulen correctamente estos ritmos.

2.6.4. Movimientos oculares verticales

Los movimientos oculares verticales son movimientos humanos naturales (también conocidos como parpadeo) que ocurren cuando los ojos se abren y cierran y son registrados por el EEG. Este tipo de señal se reconoce fácilmente porque tiene una gran amplitud y se encuentra en el EEG principalmente en las áreas frontal y prefrontal, es decir, se observan los electrodos FP1 (AF3) y FP2 (AF4) y los electrodos F7 y F8. [12], [35] Por lo tanto, cualquier señal que implique movimientos oculares (fruncimiento del ceño, levantamiento de cejas) también se reflejará en estos electrodos.

Este tipo de señales se reflejan en las bandas de frecuencia delta y theta. Normalmente estas señales están diseñadas para ser eliminadas mediante un filtro o alguna técnica como el Análisis de Componentes Independientes (ICA), que se combina con un filtro tipo Wiener. ([36]) Sin embargo, en el presente trabajo pretendemos utilizar estas señales generadas por EEG de parpadeos, expresiones faciales y mordiscos. Como objetivo principal que nos planteamos fue clasificar las señales de 3 parpadeos continuos, fruncir ceño, acción de morder y levantar las cejas y, en última instancia, proponer comandos para un posible uso en un sistemas BCI.

2.7. Métodos de extracción de características

Estas actividades generan distintos patrones de señales cerebrales dependiendo de la tarea realizada. Para clasificar cada uno de estos patrones en su categoría respectiva, es esencial identificar características significativas que reflejen su semejanza con una categoría específica y sus diferencias con otras. Por consiguiente, resulta fundamental identificar un conjunto de características que sean adecuadas para el funcionamiento óptimo del sistema BCI.

En la literatura se pueden encontrar diferentes métodos para obtener características relevantes de las señales cerebrales. Métodos como el Análisis de Componentes Principales (PCA) o el método Common Spatial Pattern (CSP) realizan transformaciones lineales para obtener la información más relevante. Existen métodos de análisis de frecuencia como la transformada de Fourier, así como métodos de análisis de tiempo y/o frecuencia como los filtros adaptativos o la transformada y descomposición wavelet, así como la transformada de Hilbert-Huang (HHT). La transformada de Fourier, la transformada Wavelet y la transformada de Hilbert-Huang se explican a continuación ya que son los métodos que se utilizaron para este trabajo.

2.7.1. Transformada de Fourier

La transformada rápida de Fourier (FFT) se utiliza para estudiar la distribución de amplitud espectral del EEG y extraer una pequeña cantidad de partes del espectro para reflejar diferentes tareas cerebrales ([37]). Al utilizar FFT, la señal EEG se puede mapear desde el dominio del tiempo al dominio de la frecuencia. El espectro de una señal se identifica descomponiendo la señal en sus correspondientes sinusoides de diferentes frecuencias. ([38])

La transformada de Fourier 2.1, se define para un vector x con n puntos muestreados uniformemente por:

$$y_{k+1} = \sum_{j=0}^{n-1} \omega^{jk} X_{j+1} \quad (2.1)$$

donde

$$\omega = e^{-2\pi i/n} \quad (2.2)$$

Es una de las raíces complejas de unidad n donde i es la unidad imaginaria. Para x e y , los índices j y k oscilan entre 0 y $n-1$.

En aplicaciones BCI, como en Huang [39] así como en ([40]) ([41]) que adoptan la transformada de Fourier (FT) para la extracción de características en diferentes tareas como la motora y SSVEP. Es importante mencionar que, si bien la FT desempeña un papel fundamental en el análisis de señales estacionarias, presenta limitaciones cuando se trata de analizar el espectro de una señal no estacionaria.

Las FFT se destacan por su rapidez de cálculo, pudiendo realizarse en tiempo real. Sin embargo, presentan ciertas limitaciones: la frecuencia utilizada para descomponer la señal depende de la frecuencia de muestreo y del número de frecuencias requeridas. Sin ajustar estos parámetros, las frecuencias no son seleccionables; esto puede resultar en un espectro con dispersión de energía en múltiples frecuencias si una onda simple no coincide con una frecuencia transformada ([38]). En la Figura 2.6, se ilustra este fenómeno con una señal que combina dos señales de frecuencias diferentes (5 y 10 Hz). La Transformada de Fourier resultante muestra las frecuencias de ambas señales.

Esta limitación nos lleva a considerar alternativas, como la Transformada de Wavelet, que aborda de manera más efectiva la detección de eventos transitorios y cambios abruptos en la señal. La siguiente sección explorará cómo la Transformada de Wavelet ofrece una solución más versátil para el análisis de señales no estacionarias.

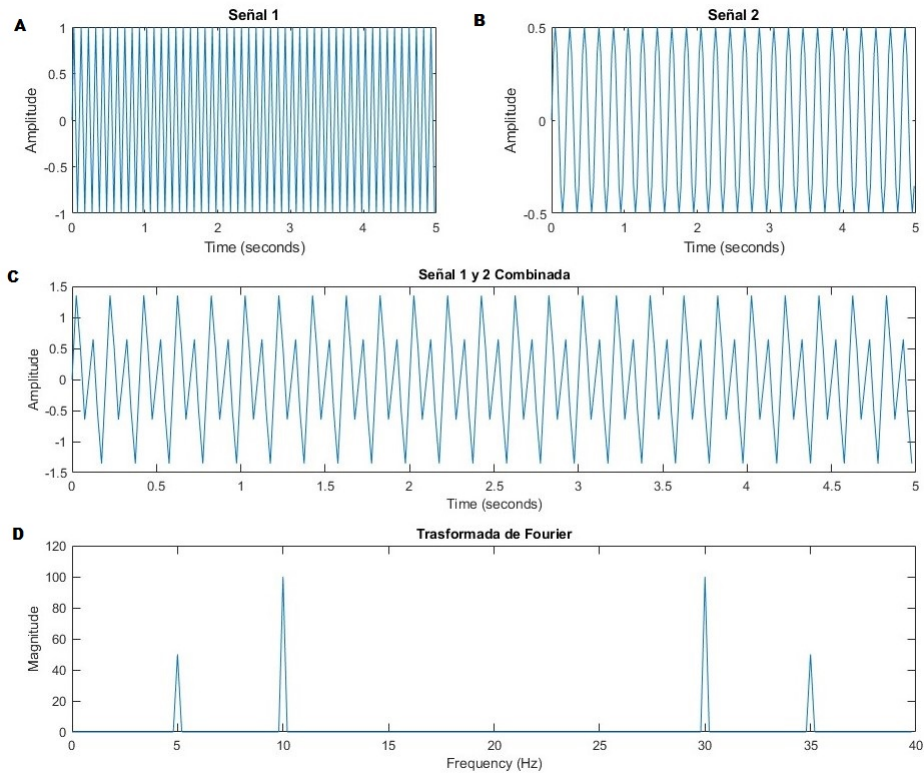


Figura 2.6: Combinación de dos señales (Señal A y señal B) en diferentes frecuencias y la trasformada de Fourier (Señal D) que muestra las frecuencias que la señal nueva presenta (Señal C)

2.7.2. Transformada de Wavelet

Anteriormente se explicó cómo utilizar la transformada rápida de Fourier para obtener la representación de la señal en el dominio de la frecuencia. Similar a FT, la transformada wavelet es una función $f(t)$, que descompone la señal en las siguientes funciones $\psi_s, \tau(t)$ [42] forma una función base y se llama "wavelet". La transformada wavelet está definida por la ecuación 2.3:

$$W_f(s, \tau) = \int f(t)\psi_{s,\tau}(t)dt \quad (2.3)$$

La función base es un conjunto de wavelets escalados y traducidos a partir de una función wavelet llamada wavelet madre, definida en la ecuación 2.4 donde s es el factor de escala y t es el factor de traducción.

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}}\psi\left(\frac{t - \tau}{s}\right) \quad (2.4)$$

Las wavelets permiten analizar señales a diferentes escalas simultáneamente. Además, la resolución depende de la escala: se puede utilizar una resolución temporal alta

para analizar frecuencias altas, mientras que se puede utilizar una resolución de frecuencia alta para analizar frecuencias bajas correspondientes a escalas gruesas. Estos puntos hacen de las wavelets una herramienta muy interesante para analizar señales EEG [42] Varios autores han aplicado el análisis de ondas para caracterizar señales EEG de imaginación motora para los sistemas BCI [43], [44], [45]. Los resultados de la clasificación se basan en la elección de una wavelet madre específica y un nivel apropiado de descomposición.

2.7.3. Transformada de Hilbert-Huang

La Transformada de Hilbert-Huang (HHT, por sus siglas en inglés) es muy útil para analizar señales no lineales y no estacionarias. Como método de análisis de tiempo-frecuencia, HHT puede revelar simultáneamente información de señales en el dominio del tiempo y en el dominio de la frecuencia. En comparación con los métodos de análisis de tiempo-frecuencia anteriores, HHT se basa en la descomposición de modo empírico (EMD) [46], que es un método de descomposición intuitivo, directo y adaptativo que utiliza la base de descomposición derivada de la señal. Las técnicas de EMD descomponen un conjunto de datos en un número finito y generalmente pequeño de funciones de modo intrínseco (IMF) que admiten la transformada de Hilbert [47].

La presentación final de los resultados es una distribución energía-frecuencia-tiempo, denominada espectro de Hilbert. En este método, las principales innovaciones conceptuales incluyen la introducción de "funciones de modo intrínseco"(IMFs). Con el EMD (o HHT), se pueden obtener las IMFs, que básicamente son los componentes de cada señal, ordenados por frecuencia. Es decir, la primera IMF corresponderá a la mayor frecuencia, mientras que la última IMF corresponderá a la menor frecuencia. Estas IMFs se utilizan para eliminar el ruido y la tendencia de la señal, proporcionando así una representación más clara de las características subyacentes de la señal [46]. Las aplicaciones de EMD y HHT se han presentado en muchos trabajos, principalmente diagnóstico y detección de convulsiones [48], [49], [50] y detección automática de crisis epilépticas basadas en imágenes de tiempo-frecuencia combinando HHT y SVM [51].

2.8. Métodos de clasificación de características

Para los métodos de clasificación de los sistemas BCI, estos métodos se pueden realizar a través de sesiones en línea o fuera de línea o ambos tipos de sesiones. Las sesiones fuera de línea incluyen probar métodos específicos utilizando conjuntos de datos previamente registrados. En estas sesiones, no es necesario analizar las señales de manera casual o en tiempo real, y las propiedades de las señales se pueden estimar a lo largo del tiempo y realizar cálculos que involucran tiempo. A veces, estos resultados son valiosos, pero no resuelven los problemas asociados con las señales en tiempo

real. Por el contrario, el análisis en línea es un método para evaluar la BCI en un entorno del mundo real. Ambos tipos de análisis son necesarios para diseñar algoritmos eficaces en entornos del mundo real.

Cuando se entrena o calibra un algoritmo de clasificación, esto generalmente se hace de manera supervisada utilizando un conjunto de señales previamente etiquetadas. Se supone que el clasificador puede detectar patrones similares descubiertos durante las sesiones de retroalimentación. Sin embargo, esto significa que la efectividad del BCI se reduce, ya que la sesión durante la captura de señal puede diferir de la sesión observada u obtenida durante la sesión en línea. Además, el entrenamiento progresivo de un usuario o los cambios en el enfoque, la atención o la motivación también pueden afectar las señales cerebrales ([52])

El objetivo de la clasificación del sistema BCI es identificar la intención del usuario basándose en vectores de características que representan las propiedades de las señales obtenidas de las conexiones neuronales en la corteza cerebral. Como se mencionó en la sección anterior, este vector se genera a partir de características extraídas de la señal de interés. Para clasificar estas características obtenidas de las señales de la corteza cerebral, se han propuesto varios algoritmos, como el clasificador basado en el vecino más cercano (k-NN), el bosque aleatorio (RF), la máquina de vectores de soporte (SVM) y finalmente la red neuronal.

En la siguiente sección, se presentan algunos clasificadores que aparecen en la literatura y que se aplican comúnmente a BCI: Random Forest (RF) y Support Vector Machine (SVM).

2.8.1. Máquina de Soporte Vectorial (SVM)

De acuerdo con ([5]) la máquina de soporte vectorial (SVM) es un método de aprendizaje supervisado para analizar datos y distinguir patrones, que se utiliza a menudo en análisis de clasificación y regresión y se desarrolló en el campo de la ciencia computacional en la década de 1990. En comparación con otros clasificadores, SVM construye un hiperplano discriminatorio que maximiza el margen de identificación de categorías; SVM tiene un buen rendimiento de generalización, no es sensible al sobreentrenamiento y funciona bien con datos limitados.

Hiperplano

Este es un espacio de dimensión p , que se define como un subespacio lineal de dimensión $p-1$. El término lineal significa que el subespacio no tiene que pasar por el origen. En el espacio bidimensional, un hiperplano es un subespacio unidimensional, es decir, una línea recta. En el espacio tridimensional, un hiperplano es un subespacio bidimensional, es decir, un plano regular que va a establecer un límite de decisión que

maximiza el margen entre las dos clases como se muestra en la figura 2.7. ([5])




Figura 2.7: Separación por un subespacio unidimensional (hiperplano) dividiendo un conjunto de datos (conjunto de datos representados por los colores rojo y morado) en 2 dimensiones [5]

Cuando hay n observaciones, cada una con p predicciones, y su variable de respuesta tiene dos niveles (se identifican como +1 y -1), se puede usar un hiperplano para construir un clasificador que permita predictores basados en a qué grupo pertenece una observación.

En el caso de separabilidad completa, generar un hiperplano que separe estos datos, como se muestra en la figura 2.8, da como resultado un número infinito de hiperplanos posibles, lo que requiere de un método que permita la selección de uno de ellos como el mejor método clasificador.




Figura 2.8: Separación de los datos por más de un subespacio unidimensional (hiperplano) [5]

La solución a este problema es seleccionar el hiperplano más alejado de todas las observaciones de entrenamiento como clasificador óptimo, que se denomina hiperplano de separación óptimo. Para calcular esto, se debe calcular la distancia perpendicular de cada observación a algún hiperplano. Como se muestra en la figura 2.9, consta de un hiperplano (es decir, una línea continua) y un margen (línea discontinua) ([5]).




Figura 2.9: Separación óptima del subespacio unidimensional (hiperplano) de los conjuntos de datos [5]

Es poco probable que el ejemplo anterior aparezca en datos reales, por lo que los datos no serán perfectamente separables linealmente como se muestra en la figura 2.10.




Figura 2.10: La imagen muestra dos conjuntos de datos, representados por puntos rojos y azules, que se entremezclan en una región. [5]

Para solucionar este problema se propone el concepto de hiperplano de margen máximo para obtener un hiperplano que "casi" separe los datos (2.11), permitiendo errores al separar los datos, este método se denomina Soft Margin.




Figura 2.11: Separación de dos conjuntos de datos por medio de un subespacio unidimensional [5]

Esto se ha explicado anteriormente con buenos resultados aplicando restricciones prácticas de separación lineal entre clases, esto se denomina clasificador de vectores de soporte. Pero cuando no hay datos que puedan separarse linealmente, la capacidad de clasificación cae drásticamente. Una forma de arreglar datos no lineales es expandir las dimensiones del espacio original, como se muestra en la figura 2.12 arriba a la izquierda, a primera vista no hay forma de separarlos, pero aumentar la dimensión ya muestra una posible separación. Esta es la base de SVM.




Figura 2.12: La representación tridimensional de datos y la separación de estos mediante un hiperplano [5].

Puede cambiar las dimensiones de un conjunto de datos combinando o modificando cualquiera de sus dimensiones. Es decir, el espacio se puede cambiar de dos dimensiones a tres dimensiones aplicando la siguiente función:

$$f(x_1, x_2) = (x_1^2, \sqrt{2}x_1x_2, x_2^2) \quad (2.5)$$

Esta es una de las infinitas transformaciones posibles y puede denominarse Kernel también llamado núcleo. Kernel (K) es una función que devuelve el resultado del producto escalar entre dos vectores realizado en un nuevo espacio dimensional que es diferente del espacio original en el que se ubicaron los vectores.

El objetivo general es encontrar un hiperplano que separe efectivamente las clases en los datos de entrenamiento maximizando la separación entre los puntos de datos más externos de cada clase. Si los datos no se pueden separar linealmente en el espacio de características original, se aplica un núcleo, un proceso que implica agregar nuevas características o transformar características existentes para enriquecer y potencialmente agregar significado a los datos [5].

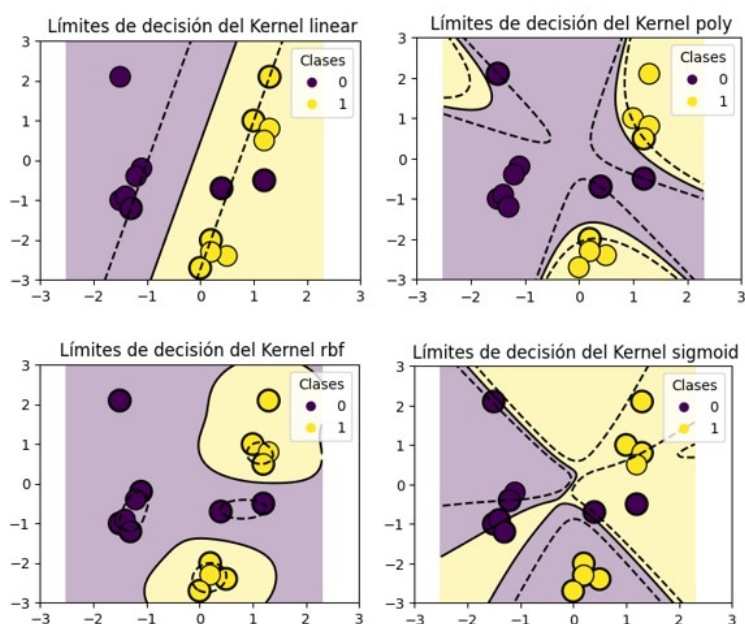


Figura 2.13: En la imagen se presentan los distintos núcleos (kernels) que pueden aplicarse a las Máquinas de Vectores de Soporte (SVM). El kernel lineal permite la separación de datos mediante una línea recta. Por otro lado, el kernel polinomial posibilita la separación de los datos en clases mediante una curva. El kernel RBF (Radial Basis Function) separa las clases mediante una curva suave que se ajusta a los datos. Finalmente, el kernel Sigmoid separa las clases a través de una curva con forma de S.

2.8.2. Random Forest

Como lo menciona [6] y [53] un modelo de bosque aleatorio (RF) consta de múltiples árboles de decisión individuales. Cada árbol se entrena utilizando muestras de datos de entrenamiento ligeramente diferentes, que se generan mediante técnicas de arranque. Para poder hacer predicciones para nuevas observaciones, es necesario combinar las predicciones de todos los árboles que componen el modelo. En cada árbol, las observaciones se distribuyen en bifurcaciones (nodos), dando forma a la estructura del

árbol hasta llegar a un nodo terminal. Las predicciones para nuevas observaciones se obtienen sumando las predicciones de todos los árboles individuales que componen el modelo.

Los árboles de decisión son modelos predictivos conformados por reglas binarias (sí/no), los cuales pueden anticipar el valor de una variable de respuesta al clasificar observaciones según sus atributos.




Figura 2.14: Predicción con Random Forest: En cada árbol, se destaca el camino seguido hasta alcanzar el nodo final. En cada nodo terminal, se especifica el índice de las observaciones de entrenamiento que lo componen [6]

Muchos métodos de predicción generan modelos globales en los que se aplica una única ecuación a todo el espacio del host. Cuando un caso de uso involucra múltiples variables productoras e interactúan de manera compleja y no lineal, puede resultar difícil encontrar un modelo global único que refleje la relación entre las variables [6].

La predicción de un modelo RF es la media de las predicciones de todos los árboles que componen el modelo y funciona de la siguiente manera;

1. Creación de un conjunto de árboles de decisión: Se generan múltiples árboles de decisión de manera individual, cada uno entrenado con un subconjunto aleatorio de los datos de entrenamiento. Cada árbol se construye con un conjunto de características también aleatorio, lo que implica que no todas las características se utilizan en cada árbol [53].
2. Proceso de clasificación: Para clasificar un nuevo punto de datos, se pasa por cada árbol del conjunto. Cada árbol predice la clase a la que pertenece el punto de datos [53].
3. Determinación de la clase final: La clase final se decide por mayoría de votos. La clase que recibe la mayor cantidad de votos de los árboles individuales es asignada al nuevo punto de datos [53].

Esta es una de las formas más comunes de obtener predicciones de un modelo de Random Forest.

Capítulo 3

Antecedentes

Los estudios en el campo de las Interfaces Cerebro-Computadora (BCI) son de suma relevancia, ya que en su mayoría se orientan hacia la mejora de la calidad de vida de personas con discapacidades motoras. Estas interfaces ofrecen una vía para que estas personas puedan comunicarse con su entorno y, en algunos casos, realizar acciones como la escritura, el control de teclados virtuales, la interacción con interfaces gráficas de usuario (GUI) o incluso el desplazamiento en su entorno mediante sillas de ruedas.

La literatura científica cuenta con una abundante cantidad de investigaciones que se enfocan en señales de control, abordando diversos neuroparadigmas, entre los cuales destacan:

1. Movimiento Imaginado (MI): También conocido como ritmos sensomotores, este enfoque se ha explorado extensamente [33], [38], [54], [55].
2. Potenciales Relacionados con Eventos (P300): Otra corriente de investigaciones se ha centrado en el estudio de los potenciales relacionados con eventos, como lo demuestran los trabajos previos [22].
3. Potenciales Evocados Visuales de Estado Estacionario (SSVEP): La detección de estos potenciales ha sido un tema recurrente en la literatura, con aplicaciones que abarcan desde el control de sillas de ruedas hasta interfaces híbridas [30]), [31].
4. Potenciales Evocados Auditivos en Estado Estacionario (SSAEP): Esta modalidad también ha sido objeto de estudio, aunque en menor medida [32].
5. Potenciales Evocados Somato Sensoriales en Estado Estacionario (SSSEP): Al igual que los anteriores, los SSSEP han sido investigados para su aplicación en interfaces cerebro-computadora [29], [22].
6. Habla no pronunciada: es una técnicas emergente que permite a las personas comunicarse sin usar la voz, mediante el uso de interfaces cerebro-computadora [56], [57].

3.1. Trabajo relacionado

A continuación, se presentarán los métodos propuestos y los resultados obtenidos en algunos de los estudios que han abordado las señales de parpadeos así como las de gestos faciales como señales de interés en aplicaciones que van desde la implementación de teclados virtuales hasta comandos para el control de dispositivos.

3.1.1. Enfoque de red neuronal convolucional 1D

En el primer trabajo, realizado por [58], propusieron un método de red neuronal convolucional unidimensional para clasificar parpadeos voluntarios en señales de EEG en aplicaciones de interfaz cerebro-computadora (BCI). Los autores utilizaron una red neuronal convolucional unidimensional personalizada que incluye capas convolucionales, capas de agrupación máxima, capas completamente conectadas y una capa de suavizado máximo que realiza una clasificación bidireccional (parpadeos voluntarios frente a parpadeos involuntarios). Exploraron el potencial de la decodificación de parpadeos como medio para desarrollar BCI.

Se generó un conjunto de datos de 1080 épocas de EEG a partir de 8 señales registradas de 4 sujetos. Estas señales de EEG se adquirieron utilizando la plataforma abierta OpenBCI y una diadema de 4 canales Ultracortex Mark IV y se verificaron mediante un enfoque de leave-one-out para evaluar la eficacia del modelo desarrollado. La CNN (Convolutional Neural Networks) propuesta se entrena de forma iterativa utilizando todo el conjunto de datos e ignorando épocas de 1 sujeto a la vez. El rendimiento de la clasificación se evalúa utilizando métricas estándar como precisión, recuperación, medida F y exactitud. Los valores medios de recuperación, precisión, medida F y exactitud son $97,2\% \pm 4,85\%$, $97,92 \pm 1,91\%$, $97,46 \pm 2,1\%$ y $97,92 \pm 1,41\%$, respectivamente. Estos resultados demuestran que el método propuesto puede clasificar eficazmente parpadeos aleatorios en señales de EEG.

Obteniendo la medida F de la siguiente manera:

$$Precision = \frac{TP}{TP + FP} \quad (3.1)$$

$$Recuperacion = \frac{TP}{TP + FN} \quad (3.2)$$

$$MedidaF = 2 \times \frac{(Precision \times Recuperacion)}{Precision + Recuperacion} \quad (3.3)$$

- TP (verdaderos positivos): El número de ejemplos positivos que se clasificaron correctamente como positivos.

- FP (falsos positivos): El número de ejemplos negativos que se clasificaron incorrectamente como positivos.
- FN (falsos negativos): El número de ejemplos positivos que se clasificaron incorrectamente como negativos.

Los autores concluyeron que el método de red neuronal convolucional unidimensional propuesto puede clasificar eficazmente los parpadeos voluntarios en señales de EEG en aplicaciones BCI. El sistema de registro de EEG de bajo costo propuesto es eficiente y puede usarse en aplicaciones prácticas. Los hallazgos de los autores tienen implicaciones importantes para el desarrollo de sistemas de registro de EEG fáciles de usar y de bajo costo para aplicaciones de interfaz cerebro-computadora.

3.1.2. Un algoritmo para reconocer parpadeos voluntarios

En ([59] Izabela Rejer y Łukasz Cieszyński propusieron un algoritmo para la identificación de parpadeos voluntarios (VEB) basado en el análisis de formas de onda temporales registradas en el canal EEG prefrontal. El algoritmo que propusieron tiene dos versiones: una para identificar diferentes números de parpadeos del ojo izquierdo o derecho (algoritmo RVEB izquierda-derecha); Parpadeo de ambos ojos (algoritmo RVEB izquierda-derecha-ambos ojos).

El algoritmo se probó en un experimento con 12 sujetos diestros sanos y sin ningún trastorno mental, que implicó mostrar una serie de imágenes en un monitor LCD para informar a los sujetos de la tarea a realizar en cada sección. Los datos de EEG se registraron desde dos canales monopares utilizando cuatro electrodos pasivos de gel de oro a una frecuencia de muestreo de 250 Hz. Una vez adquirida la señal, se aplica un filtro de paso de banda de 1-30 Hz de cuarto orden y el algoritmo calcula la altura y el ancho de los picos. Se pueden identificar los patrones de parpadeo que surgen de diversas combinaciones de guiños con el ojo izquierdo o derecho, así como de diferentes cantidades de parpadeos simultáneos de ambos ojos.

Para la clasificación de parpadeos, el algoritmo utiliza un calificador de máquina de vectores de soporte (SVM) que se entrena utilizando un conjunto de datos de entrenamiento que consta de muestras de parpadeo etiquetadas. Se proponen dos mejoras adicionales al algoritmo original: la inclusión de un parámetro de prueba adicional que refleje la relación entre las amplitudes máximas, y la normalización de los umbrales de altura.

La precisión media de clasificación lograda para cada sujeto tras la aplicación del algoritmo RVEB izquierda-derecha fue notablemente elevada. La precisión general, promediada entre los 12 sujetos, fue de casi 97 % (96,9 %), y la precisión de detección promedio del algoritmo RVEB izquierdo-derecho-ambos son del 93,8 %. La tasa de reconocimiento permanece estable bajo diferentes condiciones oculares y diferentes tiempos de parpadeo. La precisión general promedió casi el 97 % en los 12 sujetos.

Este estudio describe en detalle el algoritmo RVEB y su validación experimental. Este algoritmo muestra una mayor precisión en comparación con otros algoritmos propuestos en la literatura. Los autores también mencionaron que el algoritmo RVEB es más simple y fácil de implementar que otros algoritmos. El rendimiento del algoritmo se evalúa en términos de precisión y velocidad de reconocimiento.

3.1.3. Parpadeos voluntarios

En el trabajo de [60] se centra en el desarrollo de interfaces cerebro-computadora que utilizan señales EEG para controlar sillas de ruedas. El método utilizado en el estudio implicó la adquisición de señales EEG a través de un módulo ThinkGear interconectado con un casco con electrodos secos individuales, una computadora y un chasis de silla de ruedas. Se desarrolló un programa en MATLAB para recibir señales EEG sin procesar, mostrarlas en una ventana GUI y enviar comandos de movimiento a la silla de ruedas a través de un módulo Bluetooth.

Para la detección de parpadeos, el algoritmo propuesto utiliza una combinación de preprocesamiento de señales y técnicas de reconocimiento de patrones para detectar e interpretar parpadeos a partir de señales de EEG. En el preprocesamiento de señales, se utilizan filtros de paso de banda apropiados para extraer el rango de frecuencia deseado. Se utilizaron umbrales de intensidad de parpadeo positivos y negativos para evitar las confusiones cuando se utilice el parpadeo como elemento de comando. Este umbral de intensidad de parpadeo positivo es el valor máximo de los bits de datos de EEG de entrada que se clasifican como parpadeos naturales en el programa MATLAB. Mientras tanto, el umbral de intensidad del parpadeo negativo es el valor mínimo de los bits de datos de entrada del EEG que se clasifican como parpadeos naturales. Cualquier señal EEG por encima del umbral positivo o por debajo del umbral negativo se clasifica como parpadeo forzado, que se considerará una orden para la silla de ruedas.

Para evaluar la eficacia del sistema de silla de ruedas, se realizó un experimento con cinco personas. Se pidió a cada persona que realizara movimientos aleatorios en una silla de ruedas parpadeando y se registró el éxito de cada intento. Se estima que la precisión promedio de detección y ejecución de comandos del sistema es del 96,4 %.

También se probó el sistema de silla de ruedas para evaluar su eficiencia. Los resultados promedio después de 10 pruebas mostraron que la silla de ruedas se movía durante 2 segundos por parpadeo, con un tiempo de respuesta de 0,5 segundos. La velocidad de la silla de ruedas es de 0,79 km/h y el tiempo medio de giro es de 2 segundos.

En general, este estudio demostró con éxito la viabilidad y eficacia del uso de señales de EEG para el control de sillas de ruedas, con una alta ejecución de comandos y precisión de detección.

3.1.4. Un parpadeo de un solo electrodo

El algoritmo propuesto en este estudio [61] proporciona una alternativa a la escritura con un solo parpadeo basada en señales de EEG para personas con ciertas discapacidades motoras. El algoritmo utiliza la diadema NeuroSky Mindwave para extraer señales de EEG, que luego se procesan y clasifican mediante Análisis Discriminante Lineal (LDA).

El sistema consta de dos etapas principales: entrenamiento de clasificadores y pruebas en tiempo real. La fase de entrenamiento consiste en adquirir señales EEG de la diadema y preprocesar las señales. Este preprocesamiento incluye filtrado de paso de banda temporal para eliminar ruido y artefactos de la señal. Luego, la señal preprocesada se utiliza para extraer características, como la potencia de banda logarítmica, para capturar información relevante para la clasificación. Estas características se introducen en el clasificador LDA para capacitación.

Durante las pruebas en tiempo real, el algoritmo adquiere señales de EEG de la diadema y aplica los mismos pasos de preprocesamiento que en la fase de entrenamiento. Luego, las características se extraen utilizando la señal preprocesada y se introducen en un clasificador LDA entrenado. Un clasificador analiza las características y clasifica los parpadeos como intencionales o no intencionales. Luego, el sistema envía comandos al teclado virtual según los resultados de la clasificación.

El experimento se realizó en personas de entre 15 y 46 años. Consiste en un teclado virtual que ilumina cada letra, pudiendo aumentar la velocidad de escaneo de teclas. Si el sujeto quiere utilizar la palabra resaltada, éste parpadea, y el algoritmo reconoce el destello y selecciona la palabra iluminada y así sucesivamente para seguir formando la palabra que desea expresar.

Los estudios han demostrado que la precisión al escribir palabras u oraciones correctas usando este sistema mejora a medida que aumentan las pruebas y la práctica. El estudio encontró que, con más práctica, la tasa de error y el tiempo total de escritura disminuyeron de 1.25 minutos para una palabra de cinco letras a 1.02 minutos y para una palabra de 11 letras de 3.16 minutos a 2.21 minutos. A medida que los usuarios se familiarizan con el sistema, la velocidad de escaneo del teclado virtual puede aumentar para así disminuir el tiempo de escritura.

La precisión en la escritura de palabras u oraciones se evalúa mediante experimentos realizados con personas de diferentes edades y géneros. Los resultados mostraron una precisión que oscilaba entre el 80 % y el 100 %, según el individuo y la longitud de la palabra. Se observó que a medida que aumentaba el número de intentos, también aumentaba la precisión en la escritura de palabras u oraciones correctas.

3.1.5. Parpadeos controlados por el usuario.

A partir de esta investigación [62], se desarrolló una solución de interfaz cerebro-computadora (BCI) que puede controlar una silla de ruedas eléctrica utilizando parpadeos como señales de entrada (parpadeos cortos y largos). El algoritmo propuesto consiste en clasificar las señales cerebrales producidas al parpadear para controlar una silla de ruedas eléctrica. Esto consta de varios pasos, que incluyen la adquisición de señales, el preprocesamiento, la extracción de características y la clasificación.

Para adquirir señales, las señales cerebrales se capturaron utilizando una almohadilla biosensora OpenBCI V3 Cyton a través de electrodos de solapa activa reutilizables colocados en el cuero cabelludo de acuerdo con el sistema interactivo 10/20 y colocados en la posición FP1. El algoritmo utiliza una computadora de placa única Odroid XU-4 como controlador principal para procesar señales, enviar comandos al controlador de la silla de ruedas y servir como interfaz de usuario. La comunicación entre el controlador principal y el controlador de la silla de ruedas se establece mediante un Arduino Nano. En el preprocesamiento de la señal se aplicó un filtro de paso alto de 0.5 Hz, un filtro de muesca de 50 Hz y un filtro de paso de banda de 5-25 Hz.

Una vez recogidas las señales, se dividen en dos tipos de señales: parpadeos cortos y parpadeos largos. Esta distinción se hace midiendo los uV producidos durante un parpadeo, que caen por debajo de -74 uV y se elevan por encima de 85 uV durante un parpadeo corto por un período de 1,5 segundos. Por otro lado, los parpadeos largos ocurren cuando un usuario cierra los ojos durante 2 a 5 segundos y los vuelve a abrir y parpadea rápidamente. Cuando esto sucede, la señal cae por debajo de -75 uV y luego vuelve a la normalidad. (entre -25 y 25 uV), sube por encima de 100 uV y luego cae por debajo de -75 uV, todo en un lapso de tiempo de 2 a 5 segundos.

Para generar los comandos de la silla de ruedas se hizo una combinación de parpadeos largos y parpadeos cortos para así generar 5 comandos: parpadeos largos se representa con un guion (-) y los parpadeos cortos con un punto (.), entonces activar y desactivar el dispositivo tenía el comando de ' - - - ' , adelante " - - - . " y así combinaciones para los comandos atrás, izquierda y derecha.

Para la prueba del prototipo desarrollado, participaron en el experimento diez personas sanas de entre 20 y 45 años. Antes del experimento, cada participante utilizó el sistema durante un total de 2 horas para acostumbrarse a su funcionalidad. Los resultados experimentales mostraron que los participantes pudieron realizar la tarea con niveles de error aceptables. El número medio de intentos para la primera tarea fue de 0,82 y el tiempo medio por intento fue de 64,73 segundos. Para la segunda tarea, el número promedio de intentos fue de 0,85 y el tiempo promedio por intento fue de 140,59 segundos. Estos resultados demuestran que el prototipo desarrollado tiene menores requisitos de tiempo de entrenamiento y tiempos de respuesta adecuados para el mundo real.

3.1.6. Sistema BCI híbrido que utiliza SSVEP y parpadeos

En este trabajo de [63] se propone un sistema BCI híbrido para la automatización de sillas de ruedas, un prototipo basado en una combinación de SSVEP y mecanismos de parpadeo.

El diseño del prototipo de la silla de ruedas incluye pequeñas bombillas LED montadas en los reposabrazos, que no impiden la visión hacia delante del usuario. Estos LED facilitan el control de la dirección izquierda y derecha y requieren que el usuario los mire fijamente durante hasta 4 segundos. Los parpadeos se utilizan para los comandos de detener/marcha. La combinación de SSVEP y comandos por parpadeos proporciona una precisión razonable sin inconvenientes para el usuario.

En el experimento participaron 12 voluntarios sanos con visión normal o corregida a normal, utilizando una red de sensores geodésicos eléctricos de 32 canales de Electrical Geodesics Inc. (EGI) en Eugene, Oregon, EE. UU., para registrar señales de EEG y obtener señales de SSVEP. Las direcciones izquierda y derecha están representadas por LED colocados en los reposabrazos de la silla de ruedas que parpadean a diferentes frecuencias (13 Hz y 15 Hz). Los sujetos centraron su atención en un LED específico durante 4 segundos para seleccionar la dirección deseada. El sistema fue diseñado para que el sujeto parpadeara tres veces en un intervalo de 4 segundos para iniciar (impulsar) la silla de ruedas y usara el mismo mecanismo para detener el movimiento de la silla de ruedas durante los cuales se registraron los datos de los electrodos Fp1, Fp2.

Los métodos de extracción de características, como la descomposición de paquetes wavelet y el análisis de correlación canónica (CCA), se aplican a la reconstrucción de banda estrecha de señales EEG.

Se extrajeron los coeficientes CCA para la señal reconstruida. Estos coeficientes se utilizan como características del modelo de aprendizaje automático. La máquina de vectores de soporte (SVM) se utiliza como algoritmo de clasificación.

El algoritmo propuesto se probó utilizando un método de validación cruzada de cinco pliegues. Los datos se dividen en 5 segmentos de igual tamaño, 4 de los cuales se utilizan para entrenamiento y 1 para prueba. Este proceso se repite cinco veces, una para cada segmento como conjunto de prueba. Se utilizó la optimización bayesiana para optimizar los hiperparámetros de un modelo de máquina de vectores de soporte (SVM).

Los resultados de la prueba muestran que la precisión promedio de la validación cruzada es del 89,65 % y la desviación estándar es del 6,6 %. La precisión de la prueba fue del 83,53 % con una desviación estándar del 8,59 %. El sujeto 1 tuvo la mayor precisión, mientras que el sujeto 11 tuvo la menor precisión. La tasa de transferencia de información (ITR) promedio para 12 sujetos se calculó en 56,71 bits/min.

En resumen, este estudio desarrolló con éxito un sistema de control de silla de ruedas que combina SSVEP y parpadeo. El sistema alcanza niveles razonables de precisión y proporciona una detección segura de obstáculos. Los resultados demuestran la viabilidad del control de la silla de ruedas mediante SSVEP y comandos de parpadeo, así como aplicaciones potenciales en tecnología de asistencia para personas con discapacidades motoras.

3.1.7. Hacia una interacción BCI más intuitiva y cómoda mediante señales EEG relacionadas con los parpadeos y gestos faciales.

En investigaciones previas centradas en la utilización de señales EEG relacionadas con el parpadeo, se han limitado principalmente a la detección de parpadeos voluntarios [58], [59], utilizando una variedad de enfoques, como interfaces gráficas de usuario (GUI) [62], [60], selección de letras en un teclado virtual [61], parpadeos largos y cortos, combinaciones de estos para generar comandos direccionales [62], o incluso una combinación de parpadeos con señales SSVEP [63]. Si bien la mayoría de estos estudios han abordado de manera efectiva la generación de comandos a partir de los parpadeos, muchos de ellos han adoptado la estrategia de utilizar una única acción para representar múltiples comandos. Esta aproximación puede resultar en una complejidad innecesaria para los usuarios, ya que se ven obligados a recordar las combinaciones de parpadeos necesarias para ejecutar diferentes acciones. Además, algunos enfoques han requerido la utilización de un elevado número de electrodos para adquirir las señales de interés, lo que puede resultar en un sistema robusto pero incómodo para el usuario.

En contraste, este trabajo se centra en la obtención de señales de interés utilizando un número limitado de electrodos, idealmente no más de seis. Se ha observado que las señales de interés son más fácilmente identificables al analizar pares de electrodos, como los canales AF3 Y AF4 para los parpadeos, así como O1 y O2 para los ojos cerrados, o AF3 y AF4 para fruncir ceño o el levantamiento de cejas. En otros casos, se ha comprobado que la señal es más clara en más de dos electrodos, como en el caso de morder que se alcanza a observar en todos los electrodos, excepto O1 y O2. Esta estrategia de adquisición de datos permite optimizar el rendimiento del sistema, garantizando que las señales de interés sean claramente identificables sin comprometer la comodidad del usuario.

Capítulo 4

Metodología

Este proyecto de investigación se tomaron y clasificaron señales EEG de gestos faciales, morder y parpadeos y transformarlas a comandos para el control de un dispositivo externo como una silla de ruedas. Para el registro de las señales EEG e implementarlos en una BCI se ha diseñado el siguiente método que compone las siguientes etapas que son: obtención de las señales EEG, pre-procesamiento de las señales EEG, extracción de las características y clasificación de estas señales. La figura 4.1 muestra la arquitectura de cada una de las etapas del método propuesto.

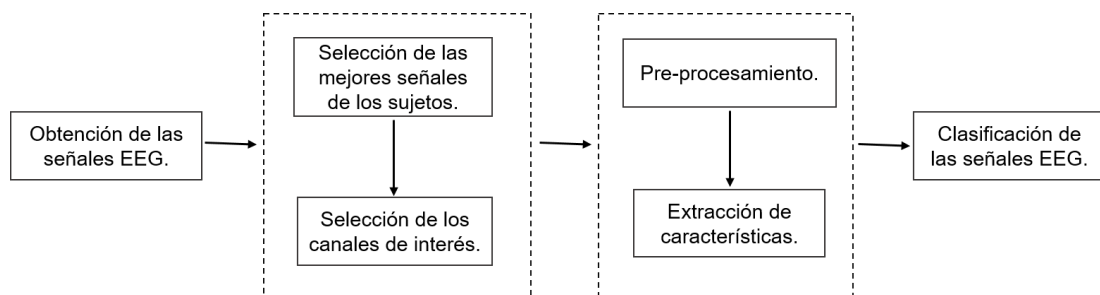


Figura 4.1: Etapas de la metodología propuesta.

Se establecieron 5 pasos. Que son necesarios para cumplir con las etapas de la figura 4.1.

1. Análisis del dispositivo Emotiv EPOC+, su suite para la captura de las señales EEG.
2. Diseño de un protocolo para la captura de las señales EEG que son de nuestro interés.
3. Análisis de las señales y extracción de características.
4. Clasificación de las características.
5. Prueba del clasificador e implementación.

4.1. Diseño experimental para la captura de señales EEG que son de nuestro interés.

En esta sección se inició con la realización de pruebas para ver que gestos son los que se van a utilizar, las pruebas consistían en colocarse la diadema y hacer los gestos visualizando las señales en el software EmotivPro, tomando las señales que a plena vista pueden distinguirse por su amplitud y que se identificaran fácilmente desde el software EmotivPro.

Las imágenes presentan las señales EEG registradas por los 14 canales de la diadema Emotiv Epoc+. En cada imagen, se destaca mediante un rectángulo negro la acción solicitada al sujeto. Durante cada ejecución, en la acción de los tres parpadeos, se nota que los canales AF3 y AF4 exhiben una amplitud notablemente superior en comparación con los demás canales (Figura 4.2). En el caso de la acción de Fruncir, se identifican con una flecha los canales donde la amplitud es más prominente (Figura 4.3). Posteriormente, en la acción de levantar las cejas, se observan perturbaciones en todos los canales, aunque se resaltan con una flecha aquellos que muestran una amplitud y actividad más destacadas (Figura 4.4). Finalmente, durante la acción de morder, se seleccionan los canales con mayor actividad, los cuales son indicados con una flecha en la figura 4.5.

Una vez establecidas las señales con las que se van trabajar se diseñó el protocolo para la toma de señales en este contiene la cantidad de sujetos con los que se va a trabajar y la actividad que se llevó a cabo para la toma de señales.




Figura 4.2: Señales EEG en el software EmotivPro, se marcan las señales en un recuadro negro cuando el sujeto esta haciendo tres parpadeos seguidos y con una flecha los canales que se seleccionaron.




Figura 4.3: Señales EEG en el software EmotivPro, se marcan en un recuadro negro cuando el sujeto esta haciendo la acción de fruncir ceño y con una flecha los canales que se seleccionaron.

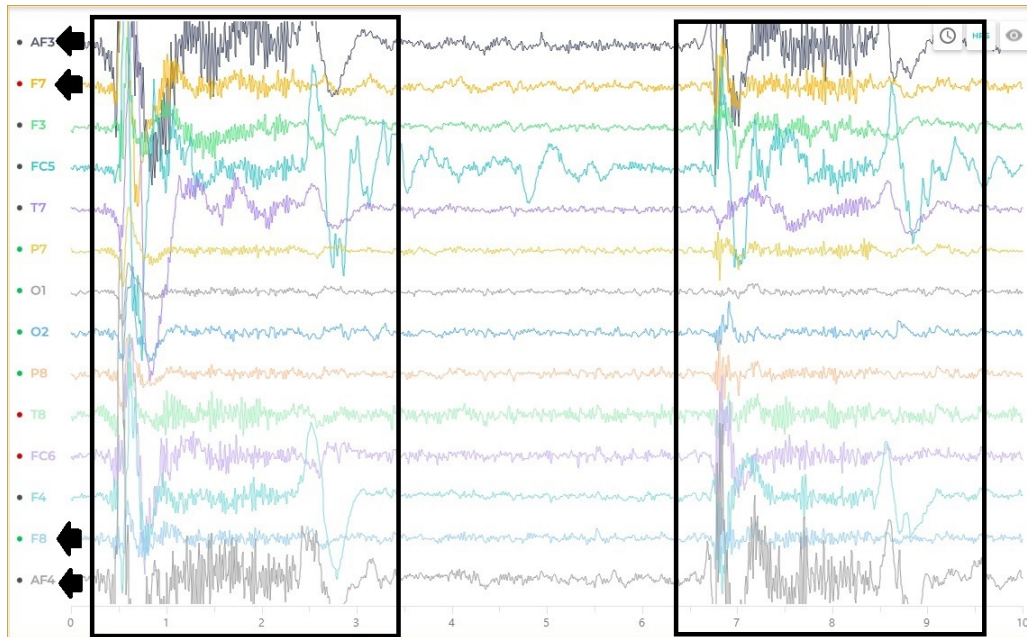


Figura 4.4: Señales EEG en el software EmotivPro, se marcan en un recuadro negro cuando el sujeto esta haciendo la acción de levantar las cejas y con una flecha los canales que se seleccionaron.

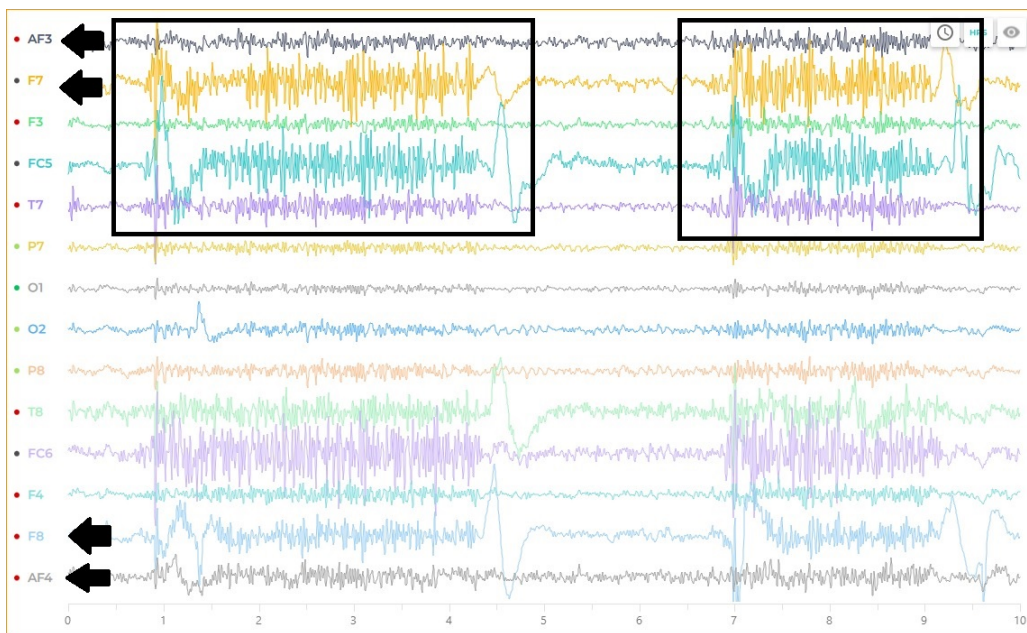


Figura 4.5: Señales EEG en el software EmotivPro, se marcan en un recuadro negro cuando el sujeto esta haciendo la acción de morder y con una flecha los canales que se seleccionaron.

4.1.1. Búsqueda y selección de los participantes

Se seleccionaron 25 participantes (13 del sexo masculino y 12 del sexo femenino) para la realización del estudio, cumpliendo con los siguientes criterios:

Criterios de inclusión:

- Con un rango de edad de 20 a 35 años.
- No encontrarse bajo tratamiento médico.
- No haber sido diagnosticado con algún trastorno psicológico.
- No tener alguna discapacidad motora.

Criterios de exclusión:

- No contar con sus 8 horas de sueño.
- Encontrarse bajo diagnóstico médico.
- Al asistir al estudio contar con el cabello parcialmente húmedo o mojado.
- Presentarse con fatiga por algún deporte previamente ejercido.

4.1.2. Cartas de consentimiento informado

A cada participante se le pidió que leyera la carta de consentimiento informado que se les mandó previamente al estudio, la cual hace mención de las indicaciones paso a paso del protocolo a seguir, autorización del participante para el uso de los resultados en el trabajo, así como la duración total aproximada del estudio y finalmente en el día del estudio se les pidió que la firmaran. La carta de consentimiento puede visualizarse en el Apéndice A.

4.1.3. Protocolo del estudio

Una vez que los participantes aceptaron ser parte del estudio, se les comunicó el lugar de estudio para el registro de las señales, el cual fue en:

Instituto Nacional de Astrofísica, Óptica y Electrónica: En el laboratorio de Procesamiento de Bioseñales y Computación Médica.

Una vez establecido el día del estudio, se les envió a los participantes, 24 horas antes, la carta de consentimiento informado que contenía instrucciones previas al estudio, las cuales fueron:

- Evitar consumir alguna bebida alcohólica 24 horas previas al estudio.
- Tener un horario de sueño normal 8hrs mínimo.
- Tener el cabello seco.

- De preferencia bañarse un día antes del estudio para tener el cabello seco el día de la sesión.
- Evitar gel o cualquier otro tipo de fijador.
- Durante el estudio: abstenerse de hacer movimientos bruscos.

4.1.4. Obtención de datos.

Para el registro de las señales, se utilizó el dispositivo Emotiv Epoc+ que consta de 14 canales (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4), distribuidos de acuerdo al sistema internacional 10/20, con una frecuencia de muestreo de 256 Hz. Se incluyó la licencia correspondiente del software EMOTIV PRO para la visualización y descarga de las señales, así como un equipo de cómputo (laptop).

4.1.5. Procedimiento de toma de datos.

Inicialmente, se solicitó al participante que tomara asiento y leer de nuevo la carta de consentimiento para luego firmarla. Mientras el sujeto leía la carta, se procedió a colocar solución salina en los electrodos en su estuche. Una vez firmada, se le explica el procedimiento que se llevaría a cabo para la toma de las señales EEG.

En el registro de las señales EEG, el protocolo se dividió en 3 secciones, en cada una de las cuales se repitieron 7 veces cada acción de interés, obteniendo un total de 21 repeticiones por cada acción. En la siguiente tabla 4.1 se mostraran los pasos seguidos en una de las secciones del protocolo:

Tabla 4.1: Tareas realizadas en una de las secciones del protocolo.

	Fase	Actividad	Duración
	1	Colocación de la diadema	5 minutos
	2	Ojos abiertos	20 segundos
	2	Ojos cerrados	20 segundos
Repetir 3 veces	2	3 Parpadeos continuos	Hasta cumplir 7 repeticiones de la actividad.
		Ojos abiertos 5 segundos	
		3 Parpadeos continuos	
		Ojos abiertos 5 segundos	
		Relajación	10 segundos
	3	Fruncir ceño 5 segundos	Hasta cumplir 7 repeticiones de la actividad.
		Ojos abiertos 5 segundos	
		Fruncir ceño 5 segundos	
		Ojos abiertos 5 segundos	
		Relajación	10 segundos
	4	Morder por 5 segundos	Hasta cumplir 7 repeticiones de la actividad.
		Dejar de morder por 5 segundos	
		Morder por 5 segundos	
		Dejar de morder por 5 segundos	
		Relajación	10 segundos
	5	Levantar las cejas 5 segundos	Hasta cumplir 7 repeticiones de la actividad.
		Sin movimientos 5 segundos	
		Levantar las cejas 5 segundos	
		Sin movimientos 5 segundos	
		Ojos cerrados	15 segundos
		6	Ojos cerrados
	6	Fin de la prueba	

Las señales registradas se guardaron con un identificador para preservar la confidencialidad de los sujetos de prueba, así como para identificar si la señal pertenecía a un hombre o a una mujer. El identificador estará compuesto por las iniciales del sujeto, seguidas de la letra H si es hombre o M si es mujer. Por ejemplo: H1DMCP/M1SPCP.

4.1.6. Normalización

Las señales obtenidas del software EMOTIV PRO están en formato .edf y se cambió el formato a .mat en el software Matlab para que sea compatible con este. Las señales ya en el formato de Matlab se trabajaron de la siguiente manera: 0

La normalización de los datos se realiza con la siguiente fórmula:

$$z = \frac{x - \mu}{\sigma} \quad (4.1)$$

Donde: x es el valor de los datos originales, μ el promedio de la señal y, σ la desviación estándar.

4.2. Análisis de las señales y extracción de características.

El software utilizado para el análisis y la extracción de características de las señales EEG fue MATLAB R2022b. A continuación, se menciona el procedimiento que se siguió para la obtención y registro de las señales si como la limpieza de la señal obtenida.

4.2.1. Análisis de las señales

Al visualizar las señales de los 25 sujetos, 4 de ellos presentaban mucho ruido, ya sea porque los electrodos no tuvieron buen contacto con el cuero cabelludo de los sujetos o bien la diadema EMOTIV no tuvo buena comunicación con la computadora como se muestra en la figura 4.6 y 4.7, así mismo los sujetos se movían mucho en el estudio lo que provocaba estas graves distorsiones en las señales. Es por ello que se descartaron del estudio quedando solo con 21 sujetos.

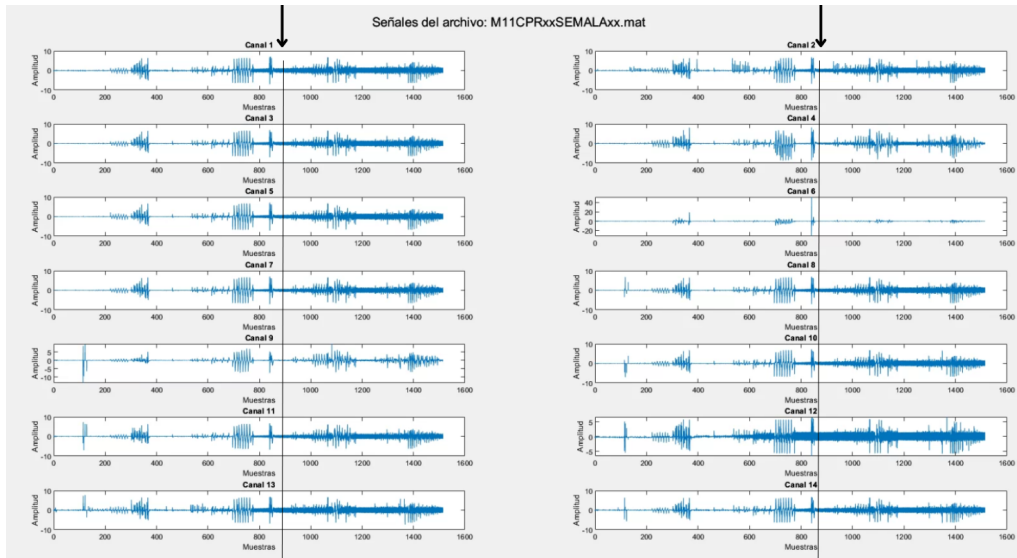


Figura 4.6: Señal de un sujeto de prueba que a la mitad de la prueba empezó a presentar mucho ruido, esto debido a un problema con la diadema ya que los electrodos dejaron de hacer contacto con el cuero cabelludo, las flechas marcan donde empezó el ruido




Figura 4.7: Se tomo el primer canal, se observa el momento cuando empieza el problema con la señal, la flecha marca donde empieza a notar mas el ruido.

Una vez se seleccionaron las señales de los sujetos con los que se va a trabajar se procedió a identificar las secciones de interés, en donde se hace la acción de 3 Parpadeos, fruncir ceño, levantar cejas y morder (Figura 4.8).

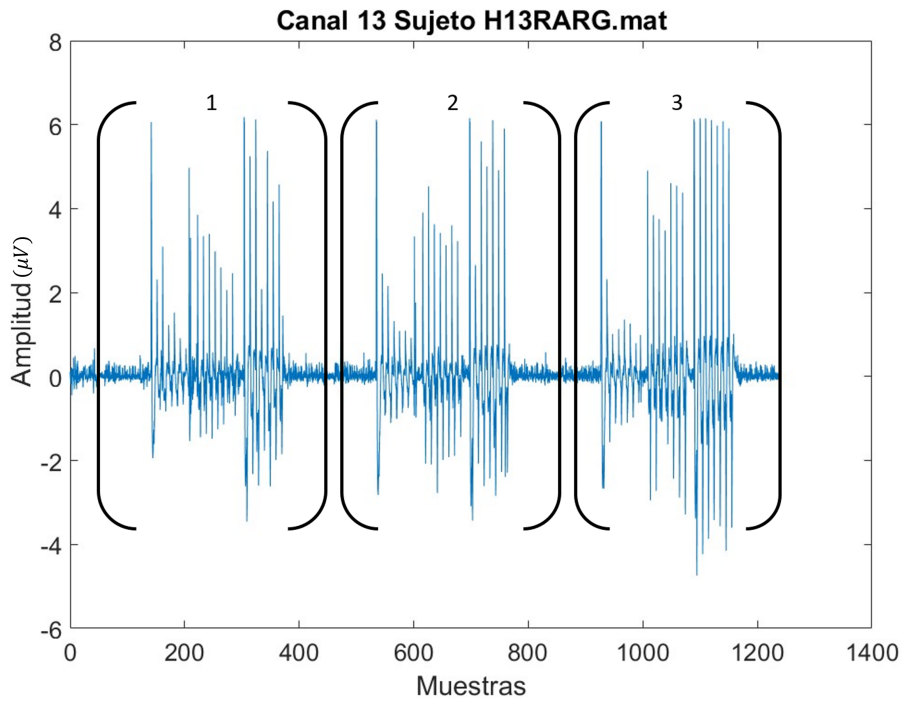


Figura 4.8: Señal de un canal de un sujeto de prueba donde se aprecian 3 secciones de interés donde están ocurriendo las acciones a analizar.

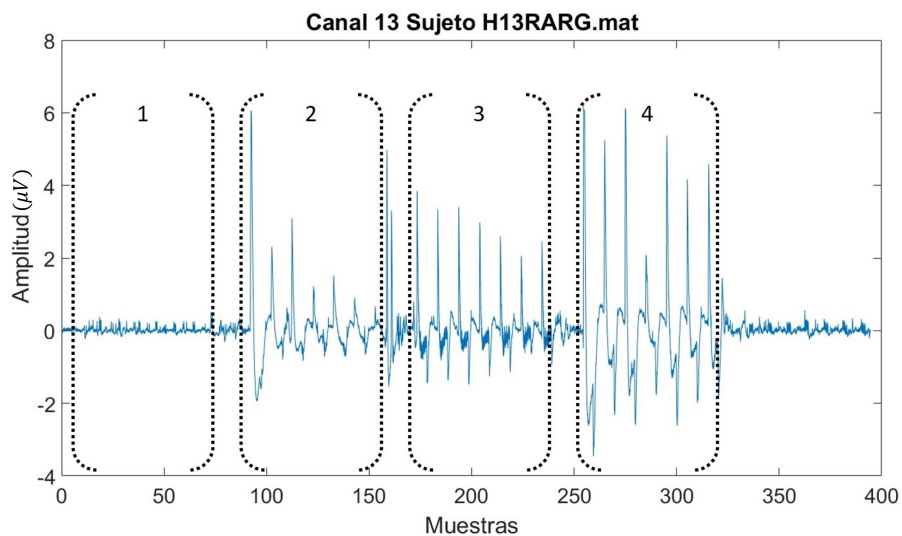


Figura 4.9: Ampliación de la primera sección de la imagen. Secciones donde se ejecutan las acciones deseadas. 1) Sección donde se realizan 3 parpadeos continuos 7 veces en aproximadamente en un minuto, 2) Sección donde se realiza la acción de fruncir ceño por 5 segundos 7 veces en poco mas de un minuto, 3) Sección donde se realiza la acción de morder por 5 segundos 7 veces en poco mas de un minuto, 4) Sección donde se realiza la acción de fruncir el ceño por 5 segundos 7 veces en poco mas de un minuto. 4.8

De la figura 4.9 al tomar las partes de cada acción que son de nuestro interés, se hi-

cieron cortes de las señales con una duración de 5 segundos teniendo señales de esta duración donde se hacen los tres parpadeos continuos (Figura 4.10), fruncir el ceño (Figura 4.11), morder (Figura 4.12) y levantar cejas (Figura 4.13).

Como acción extra de las señales para tener en cuenta contra que señal se quiere identificar se hicieron cortes de señales donde el sujeto no esta haciendo ninguna de las acciones anteriormente mencionadas y en las cuales es posible que tenga en la señal parpadeos pero estos no son continuos y servirían para entrenar al modelo de clasificación y así no confundirse cuando el sujeto haga parpadeos involuntarios.

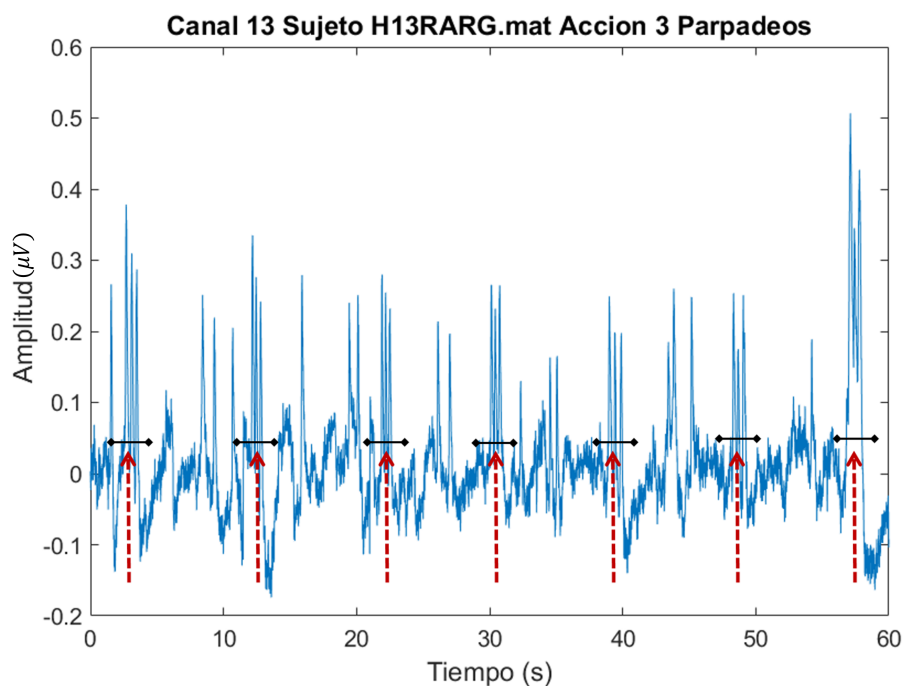


Figura 4.10: Se señalan con flechas las primeras 7 repeticiones de la acción de 3 parpadeos continuos teniendo una duración de 5 segundos las secciones señaladas.




Figura 4.11: Se señalan con flechas las primeras 7 repeticiones de la acción de Fruncir el ceño teniendo una duración de 5 segundos las secciones señaladas.




Figura 4.12: Se señalan con flechas las primeras 7 repeticiones de la acción de Morder teniendo una duración de 5 segundos las secciones señaladas.




Figura 4.13: Se señalan con flechas las primeras 7 repeticiones de la acción de levantar las cejas teniendo una duración de 5 segundos las secciones señaladas.

4.2.2. Selección de canales a analizar

Se seleccionaron los canales de nuestro interés (Figura 4.14) de donde se procedió a extraer los cortes de cada acción realizada por los sujetos de prueba.

Cada acción (como 3 parpadeos, fruncir el ceño, etc.) se repitió 21 veces en toda la prueba. Los cortes se realizaron en cada canal, lo que resultó en un total de 126 cortes de señales con una duración de 5 segundos por cada acción en los 6 canales. Se guardaron las señales de los 21 sujetos en una carpeta con el nombre de la respectiva acción, lo que resultó en un total de 2646 cortes de señales por cada acción.

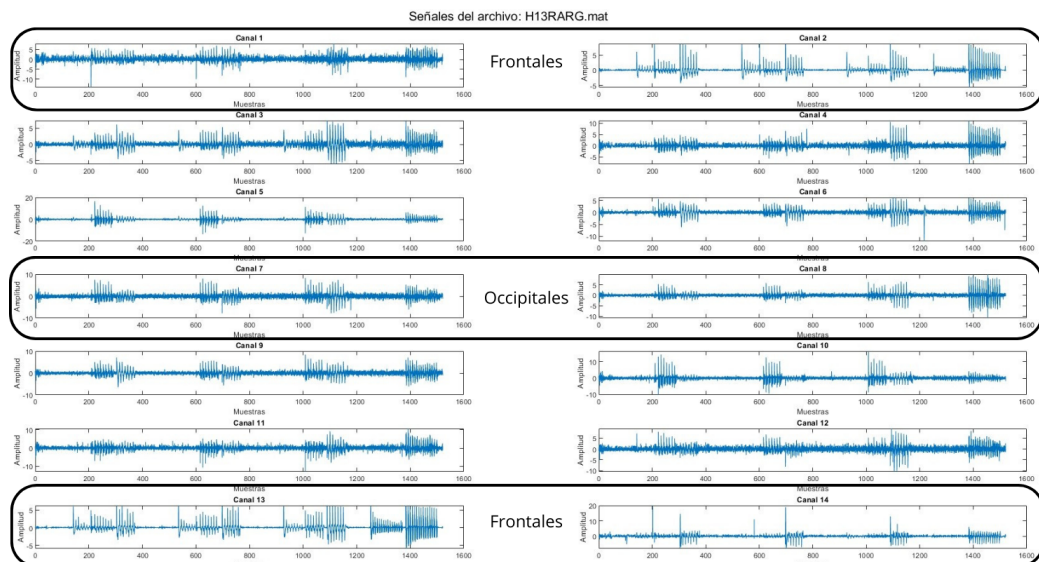


Figura 4.14: Visualización de todos los canales de la Diadema EMOTIV y se marcan en un recuadro las señales de los canales con los que se va a trabajar.

4.2.3. Filtrado

Las señales registradas fueron filtradas aplicándoles un filtro pasa bandas de décimo orden Butterworth, desde 2 Hz hasta 40 Hz, con el fin de suprimir de manera efectiva las frecuencias no deseadas. Se seleccionó un límite inferior de 2 Hz para reducir la distorsión en la señal, sin embargo, se mantuvo la información relevante de los parpadeos, los cuales se encuentran típicamente en un rango de frecuencia de 0.5 Hz a 4 Hz. El límite superior de 40 Hz se estableció para eliminar las interferencias de la línea de alimentación, que suelen encontrarse entre 50 Hz y 60 Hz, siendo una de las fuentes más comunes de ruido. De este modo, se conservaron las señales de interés que se encuentran por encima de los 25 Hz o 30 Hz.

4.2.4. Procesamiento de las señales y extracción de características

El procesamiento de las señales se llevo a cabo con cada una de las señales que están guardadas en cada una de las carpetas, a cada corte de señal que tiene una duración de 5 segundos se le aplico el siguiente proceso.

4.2.5. Transformada Rápida de Fourier y Densidad Espectral de Potencia

Se empleo la función de MATLAB *fft*, para poder obtener la potencia de cada componente de frecuencia se elevo al cuadrado el producto absoluto de FFT y se convirtieron a dB multiplicando el resultado con logaritmo base 10 (se aplico la siguiente formula 4.2), esto con el fin de visualizar y analizar mejor la distribución de la potencia de la

señal.

$$dB/Hz = 10 \times \log_{10}((abs(FFT))^2) \quad (4.2)$$

4.2.6. Transformada Wavelet Discreta

Se procedió a aplicar la transformada de wavelet discreta (DWT, por sus siglas en inglés) con la Daubechies 4 (db4) a las señales, como se muestra en la Figura 4.15. Se eligió esta forma de onda debido a su similitud con las señales que estábamos identificando, ya sea parpadeos o gesticulaciones faciales. Posteriormente, se aplicó la inversa de la Transformada de Wavelet utilizando los coeficientes resultantes de la transformada para reconstruir la señal. Este proceso nos ayudó a atenuar nuestras señales para un análisis más preciso.




Figura 4.15: Ondícula db4 Wavelet.

4.2.7. Transformada de Hilbert-Huang

En nuestra señal resultante de la reducción de ruido mediante la DWT, primero se aplica el EMD, que descompone la señal en sus IMF (Intrinsic Mode Functions), que son componentes adaptativos que representan los elementos constitutivos de la señal, ordenados por frecuencia y llamados modos. Se selecciona el segundo modo, ya que en este se reflejan mejor las señales que estamos analizando. Una vez seleccionado el modo, se aplica la Transformada de Hilbert al IMF seleccionado, lo que nos proporciona información sobre la amplitud y la fase de la señal en función del tiempo. Se toma el resultado de la amplitud y se detectan los picos máximos utilizando la función "findpeaks" en Matlab, con una distancia mínima de 100 datos entre pico y pico ("MinPeakDistance", 100), con el fin de evitar la detección de picos continuos en la señal. Esto también incluye la detección del pico máximo y el cálculo del promedio de los picos detectados.

4.2.8. Transformada de Wavelet Continua

A la señal resultante de la reducción de ruido de la DWT, se aplica la CWT a la señal utilizando la wavelet Morse para obtener una representación en el dominio de la escala y el tiempo, el resultado nos ayuda a visualizar los patrones de la frecuencia que cambian con el tiempo, entonces tenemos por una parte en el eje X el tiempo, en el eje Y la frecuencia y en la barra de colores representa la intensidad o magnitud de la frecuencia.

Posteriormente se calcula el valor absoluto de los coeficientes wavelet obtenidos de la CWT, se define la escala, esto como una secuencia de números de 1 hasta la longitud total del producto absoluto, se calcula la energía de la señal en diferentes escalas sumando los cuadrados de los valores absolutos de la CWT a lo largo de las columnas, esto con el fin de obtener solo valores en x y en y.

Se utiliza la función findpeaks para encontrar los picos máximos en la energía de la señal con una distancia mínima de 100 puntos entre picos consecutivos, se calcula el máximo pico entre los picos detectados y se calcula el promedio de los picos. Estos valores son relevantes para evaluar la importancia de los eventos significativos en la señal.

4.3. Clasificación de las características.

Una vez que se han obtenido las características y que las señales ya tienen una etiqueta que va del 0 al 4, siendo 3 parpadeos continuos, fruncir el ceño, morder, levantar las cejas y señal normal respectivamente, se obtiene una variable en matlab donde se tiene toda esta información de cada señal con sus respectivas características.

4.3.1. App Classification Learner Matlab

En Matlab, existe una aplicación llamada Classification Learner que permite utilizar modelos de clasificación, como los de nuestro interés que son Random Forest y SVM. Se cargó la base de datos obtenida de la extracción de características, y al iniciar el uso de esta aplicación se establecieron ciertos parámetros, uno de los cuales fue el número de pliegues para la validación cruzada. En este caso, se estableció en leave-one-out de 5 pliegues para el entrenamiento de los datos.

Una vez cargados los datos, se seleccionaron los modelos con los que se trabajó, que son Random Forest y SVM. Los hiper-parámetros de cada modelo se describen en la siguiente tabla (Tabla 4.2).

Tabla 4.2: Hiperparametros establecidos por cada modelo de clasificación.

Modelo.	Hiper-parametros
Random Forest	Máx. divisiones: 100 Criterio de división: Gini
SVM 1	Kernel: Gaussiano Escala Kernel: 4.6 Restricción de caja: 1 Método: uno contra uno
SVM 2	Kernel: Gaussiano Escala Kernel: 4.6 Restricción de caja: 1 Método: uno contra uno

4.3.2. Modelo Entrenado

Después de entrenar los modelos, podemos visualizar la interpretación del Accuracy de la validación cruzada mediante una matriz de confusión. Esta matriz nos proporciona información sobre la precisión del modelo entrenado y nos ayuda a evaluar su rendimiento.

4.4. Prueba y validación del modelo entrenado.

4.4.1. Matlab

En la aplicación de Matlab, también existe la opción de especificar el porcentaje de datos que se reserva para la prueba. Sin embargo, en este caso particular, el modelo se entrenó con todos los datos de 20 sujetos, y se utilizó el conjunto de datos del sujeto 21, es decir, el sujeto excluido del entrenamiento, para probar el modelo. Es importante destacar que al sujeto excluido del entrenamiento se le aplicó el mismo proceso de extracción de características que a los sujetos utilizados para entrenar el modelo.

Esta funcionalidad se implementó en la app de Matlab, la cual cuenta con una sección donde se pueden cargar los datos para probar el modelo previamente entrenado. La aplicación toma los datos con los que se va a probar el modelo y los repite 10 veces, luego arroja como resultado el Accuracy promedio del Test. Finalmente, se interpretaron los resultados mediante una matriz de confusión del Test.

Ventajas de la Validación Cruzada:

- Robustez en la Evaluación: La validación cruzada proporciona una estimación más robusta del rendimiento del modelo al evaluarlo en múltiples conjuntos de datos.
- Reducción del Sesgo: Al utilizar diferentes particiones de datos, la validación

cruzada reduce la dependencia del rendimiento del modelo de una única partición.

- **Utilización Eficiente de Datos:** Aprovecha al máximo el conjunto de datos al utilizar cada observación tanto para entrenamiento como para prueba.
- **Identificación de Overfitting:** Permite identificar si el modelo está sobre ajustando a un conjunto de datos específico, ya que se evalúa en múltiples conjuntos diferentes.

Otro enfoque para validar el modelo entrenado implica dejar un sujeto fuera del proceso de entrenamiento y evaluar el modelo con este sujeto excluido. Este procedimiento leave-one-out se repitió para cada uno de los 21 sujetos en el estudio. Es decir, se excluyó el primer sujeto, que se utilizaría para la prueba del modelo, y se entrenó el modelo utilizando los datos de los sujetos 2 al 21. Luego, se excluyó el segundo sujeto y se entrenó el modelo con los datos de los demás sujetos (sujeto 1 y sujetos del 3 al 21), y así sucesivamente para cada sujeto restante. Posteriormente, se calculó el promedio del porcentaje de precisión obtenido para cada sujeto, así como la desviación estándar.

Capítulo 5

Resultados

En este capítulo se presentan los experimentos y resultados obtenidos con los experimentos de esta investigación. Con base a los datos que se muestrearon en este trabajo se extrajeron las características y el entrenamiento de los modelos. Este capítulo se dividió en 3 secciones en las que se presentan los porcentajes de las pruebas de los modelos entrenados, la evaluación de estos en Matlab. Finalmente se presenta la mejor elección para clasificar las clases y evitando así las clases que tienen tendencia a confundirse más entre ellas.

5.1. Base de datos

A continuación se muestra la distribución de cómo se guardaron los cortes de las señales de cada acción de interés de cada sujeto, observando la cantidad total de datos de cada carpeta.

De la figura 5.1, se presenta un corte de una señal donde se observan las primeras 7 acciones. En este caso, se muestran las acciones de 3 parpadeos continuos. Se realizaron cortes de 5 segundos donde se observa cada acción (ver figura 5.1), teniendo un total de 7 cortes de 5 segundos donde se observa la acción deseada (parpadeos, gestos faciales).

Los cortes mencionados se realizaron en todos los canales de interés, que son AF3, AF4, F7, F8, O1 y O2, ya que en estos canales se observan más claramente las acciones de 3 Parpadeos continuos, Fruncir el ceño, Levantar las cejas, morder y finalmente los ojos cerrados. Esto resultó en un total de 42 cortes de señales correspondientes únicamente a las primeras 7 acciones de la primera sección del protocolo. El mismo procedimiento se repitió con las secciones restantes del protocolo, generando un total de 126 cortes de señales para un solo sujeto y una sola acción. Estos cortes se organizaron en carpetas individuales nombradas según la acción correspondiente. Este proceso se replicó con los 21 sujetos, acumulando un total de 2,646 cortes de señales con una duración de 5 segundos para una única acción. Cabe destacar que se obtuvo la misma cantidad de cortes para cada acción y se almacenaron en sus respectivas carpetas, cuyos nombres se presentan en la figura 5.2.




Figura 5.1: Se señalan con flechas las primeras 7 repeticiones de la acción de 3 parpadeos continuos.




Figura 5.2: Información que contiene cada carpeta, en este caso se muestra la carpeta donde se encuentran los cortes de las señales de 3 parpadeos continuos y el nombre con el que se guardaron los cortes de la senal0001 hasta la senal2646.

5.2. Procesamiento de las señales

El procesamiento que se llevó a cabo con las señales se va a representar con una sola señal (3 parpadeos continuos, ver figura 5.3), pero los resultados obtenidos que se

muestran a continuación se aplicaron a todas las señales.




Figura 5.3: Corte de la acción de 3 parpadeos continuos sin filtro.




Figura 5.4: Corte de la acción de 3 parpadeos con filtro de 2 a 40 Hz.

Para obtener el bandpower de la señal, se tuvo que visualizar el espectro de la potencia en unidades lineales, elevando al cuadrado la amplitud. Posteriormente, para visualizarla en decibelios (dB), se multiplicó por el logaritmo base 10 (ver figura 5.5).




Figura 5.5: Corte de la acción de 3 parpadeos con filtro de 2 a 40 Hz.

A partir del valor obtenido, se calculó la potencia en rangos específicos: de 2 a 40 Hz, de 8 a 12 Hz y de 12 a 35 Hz.

A continuación, se extrajeron las siguientes características de las señales:

- Potencia en la banda alfa (8-12 Hz).
- Radio de potencia de alfa (potencia alfa / potencia 2 a 40 Hz).
- Potencia en la banda beta (12-35 Hz).
- Radio de potencia de beta (potencia beta / potencia 2 a 40 Hz).
- Varianza de la potencia total.

De la transformada wavelet discreta aplicada como reducción de ruido se obtuvo esta señal figura 5.6.




Figura 5.6: Señal después de la DWT como reducción de ruido

Del resultado obtenido se sacaron las siguientes características:

- Se calculó la entropía de Shannon sobre los coeficientes de la DWT utilizando la función `wentropy` en Matlab. La entropía de Shannon mide la incertidumbre o la aleatoriedad de la información en los coeficientes DWT.
- Se calculó la entropía logarítmica de la energía sobre los coeficientes de la DWT utilizando la función `wentropy`. Esta medida proporciona información sobre la distribución de la energía en la señal.

De la señal resultante de la reducción de ruido con la DWT se aplicó HHT. Para aplicar esta transformada de Hilbert, primero se descompuso la señal en sus modos empíricos (IMF). A los IMF resultantes se les aplicó la transformada de Hilbert, obteniendo el valor absoluto del resultado de la transformada de Hilbert, así como la amplitud (ver Figura 5.7). Se seleccionó el segundo IMF al que se aplicó la transformada de Hilbert (ver Figura 5.8), ya que en este se observaban más detalles de la distribución de las acciones que se buscaban.




Figura 5.7: Amplitud obtenida del valor absoluto del resultado de la Transformada de Hilbert




Figura 5.8: Datos de la segunda división de la transformada de Hilbert

Del resultado obtenido de HHT se obtuvieron las siguientes características:

- Se calculó el pico más alto de la amplitud. Este indica la intensidad del evento más prominente o destacado en la señal.
- Se calculó el promedio de los picos detectados. Proporciona una medida de la tendencia central de los eventos detectados. Si los picos están distribuidos de manera uniforme, el promedio puede ser representativo de la intensidad general de los eventos.

- Se calculó la diferencia relativa entre el pico más alto y el promedio, normalizada por el promedio. Esta diferencia proporciona información sobre la variabilidad de los eventos detectados.
- Se extrajeron características estadísticas de la amplitud de la transformada de Hilbert, como el promedio, la varianza, la kurtosis y la asimetría.

De la señal filtrada con DWT se aplicó CWT, obteniendo su escalograma de magnitud (ver Figura 5.9). En el eje X se representa el tiempo en segundos, en el eje Y se representa la frecuencia en una escala logarítmica y la barra de colores indica la magnitud, que va desde presencia de una baja magnitud (azul oscuro) hasta presencia de una alta magnitud (amarillo).




Figura 5.9: Escalograma de magnitud, las zonas amarillas representan una magnitud alta en las frecuencias que oscilan entre los 2 y 2.8 Hz entre el primer y cuarto segundo.

Al calcular el valor absoluto de la CWT y obtener su energía a partir de los valores absolutos, se obtuvo la siguiente figura (ver Figura 5.10).




Figura 5.10: Energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo

Del valor obtenido de la energía se sacaron las siguientes características:

- Se extrajo el valor del pico máximo de la energía. Este valor representa la magnitud del pico más alto en la energía de la señal. En términos prácticos, un pico más alto indica un evento en la señal que ha contribuido significativamente a la energía total. La magnitud del pico puede ser una medida de la intensidad o la importancia relativa de ese evento.
- Se obtuvo el promedio de los picos detectados. Al calcular el promedio, se obtiene una medida representativa de la magnitud de los eventos detectados en la señal. Si hay varios eventos significativos, el promedio proporciona una visión general de la intensidad promedio de estos eventos.
- Se calculó la diferencia relativa entre el pico más alto y el promedio de los picos detectados. Esto indica cuánto se destaca el pico máximo en comparación con el promedio de los picos. Una diferencia elevada sugiere que hay uno o unos pocos eventos extremadamente destacados que contribuyen significativamente a la energía total.
- Se extrajeron características estadísticas de la energía: el promedio, la varianza, la kurtosis y la asimetría.

5.3. Características obtenidas

Se obtuvieron un total de 21 características del procesamiento de las señales, las cuales se describen a continuación en la tabla 5.1.

Tabla 5.1: Técnica aplicada a la señal y características extraídas.

Técnica aplicada	Características Extraídas
Densidad Espectral de potencia	Potencia de banda alfa (4 - 8 Hz) Radio de potencia de alfa (potencia alfa / potencia 2 a 40 Hz). Potencia en la banda beta (12-35 Hz). Radio de potencia de beta (potencia beta / potencia 2 a 40 Hz). Varianza de la potencia total
Transformada de Wavelet Discreta	Entropía de Shannon Entropía Logarítmica
Transformada de Hilbert-Huang	Amplitud máxima Promedio de picos detectados en la amplitud cada 100 muestras Diferencia relativa entre la amplitud máxima y promedio de picos detectados Promedio de la amplitud Varianza de la amplitud Kurtosis de la amplitud Asimetría de la amplitud
Transformada de Wavelet Continua	Energía máxima Promedio de picos detectados en la energía cada 100 muestras Diferencia relativa entre la energía máxima y el promedio de picos detectados Promedio de la energía Varianza de la energía Kurtosis de la energía Asimetría de la energía

5.4. Clasificación con la aplicación de Matlab

Los modelos de clasificación se entrenaron con la aplicación de Matlab utilizando los siguientes parámetros:

En la aplicación, se ofrecía la opción de seleccionar el tipo de validación a utilizar. En este caso, se empleó una validación cruzada de 5 pliegues. Se dispone de un total de 2646 cortes de señales para cada acción. Cada conjunto de 126 datos corresponde a un sujeto individual. En el proceso de entrenamiento del modelo de clasificación, se utilizaron los datos de los primeros 20 sujetos, lo que equivale a un total de 2520 datos disponibles para el entrenamiento del modelo. Posteriormente, los 126 cortes de señales restantes se emplearon para probar los modelos previamente entrenados.

Posteriormente, para evaluar el modelo de clasificación, se probó el modelo entrenado

con el sujeto que quedó fuera del entrenamiento. Se aplicó el mismo procesamiento a las señales del sujeto excluido para extraer las características. Con los datos obtenidos, se puso a prueba el modelo previamente entrenado, lo que nos arrojó un accuracy de la prueba del modelo con el sujeto seleccionado.

El procedimiento anterior se repitió con cada uno de los sujetos; es decir, se seleccionó uno para dejarlo fuera del entrenamiento y con los sujetos restantes se entrenó el modelo. Los resultados obtenidos se pueden ver en el Apéndice B. Se promedió la precisión (Accuracy) y se obtuvo la desviación estándar de los 21 modelos y pruebas (ver Tabla 5.2).

Tabla 5.2: Promedio y desviación estándar del porcentaje de precisión de los modelos probados con cada sujeto de prueba.

Clasificador	Promedio	Desviación Estándar
Random Forest	39.51 %	6.80 %
SVM1	44.90 %	6.63 %
SVM2	44.68 %	7.27 %

Después de analizar los resultados obtenidos, se observó que en los canales occipitales no era posible apreciar claramente las acciones de parpadeo, fruncir el ceño y levantar las cejas, como se muestra en la figura 5.11 (se proporciona un ejemplo de la acción de parpadeo, mientras que las otras acciones están disponibles en la sección de Apéndice C). Por lo tanto, se tomó la decisión de eliminar las señales provenientes de los canales occipitales.

Además, se observó que en cada matriz de confusión, las clases de fruncir el ceño y morder mostraban mayores errores de clasificación. Por consiguiente, se optó por excluir la clase de fruncir el ceño. Respecto a la acción de morder, se decidió identificarla mediante la frecuencia predominante cuando ocurre dicha acción excluyéndola del clasificador, ya que se manifiesta en frecuencias superiores a 25 Hz. De esta manera, se buscó mejorar la precisión del modelo al simplificar la clasificación y focalizar el análisis en características más distintivas y fáciles de identificar.

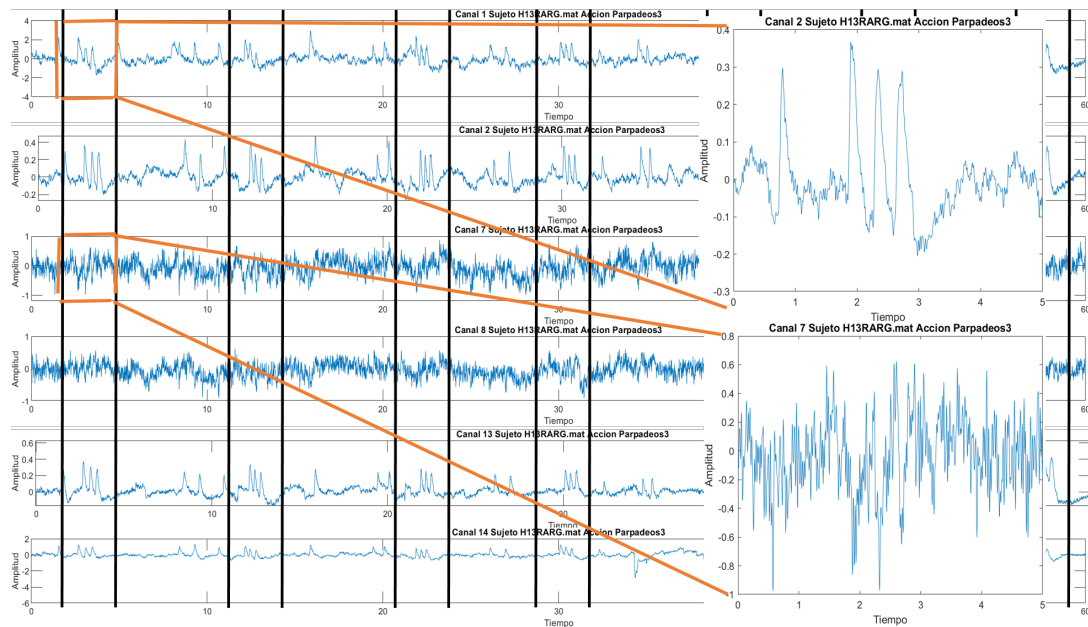


Figura 5.11: Cortes de cada canal mostrando cada sección de 3 parpadeos continuos, acercando una sección de un canal frontal y un canal occipital.

Con el objetivo de mejorar la precisión del clasificador, se entrenó un nuevo modelo utilizando únicamente los canales AF3, AF4, F7 y F8 ya que en estos canales se visualizan mejor las acciones de 3 parpadeos y levantar las cejas, en comparación con los canales occipitales (O1 y O2) como se muestra en la figura 5.11. La nueva configuración de clases (3 parpadeos continuos, levantar las cejas y señal normal) se propuso con la intención de evaluar si un conjunto reducido de canales y clases resultaba en una mayor precisión del clasificador.

Se entrenó un modelo de clasificación leave-one-out con los datos de los 21 sujetos, dejando fuera del proceso de entrenamiento a un sujeto diferente para cada modelo entrenado. Luego, se utilizó este sujeto excluido para probar el modelo de clasificación. Este procedimiento se repitió para cada sujeto, resultando en un total de 21 modelos de clasificación. Se calculó el promedio de los resultados y se determinó la desviación estándar, como se muestra en la tabla 5.3. Este enfoque proporciona una evaluación más exhaustiva del desempeño del clasificador al considerar la variabilidad entre diferentes sujetos.

Tabla 5.3: Promedio y desviación estándar del porcentaje de los modelos probados con cada sujeto de prueba, excluyendo los canales Occipitales, así como las clases de fruncir ceño y morder.

Clasificador	Promedio	Desviación Estándar
Random Forest	66.50 %	10.92 %
SVM1	72.48 %	10.03 %
SVM2	72.84 %	9.69 %

La precisión más alta obtenida fue cuando se clasificaron las señales del sujeto 5 (Tabla 5.4), y la más baja fue la del sujeto 8 (Tabla 5.5). En sus matrices de confusión, las figuras 5.12 y 5.13 muestran cómo se comportó el modelo al clasificar las clases de cada sujeto.

Tabla 5.4: Accuracy de los modelos entrenados con el sujeto 5

Sujetos de entrenamiento	Sujeto de prueba	Modelo	Hiperparámetros	Accuracy
Sujetos 1-4, 6-21	Sujeto 5	Random Forest	Máx. divisiones: 100, Criterio de división: Gini	86.90 %
		SVM1	Kernel: Gaussiano, Escala Kernel: 4.6, Restricción de caja: 1, Método: uno contra uno	89.70 %
		SVM2	Kernel: Gaussiano, Escala Kernel: 5.6, Restricción de caja: 11, Método: uno contra uno	88.50 %




Figura 5.12: Matriz de confusión de cada modelo de clasificación entrenado de el sujeto 5

En la matriz de confusión del sujeto 5 (Figura 5.12) se muestra cómo se comportó al clasificar las siguientes clases: 0 es la clase de 3 parpadeos continuos, 1 la clase de

levantar las cejas y la clase 2 es la señal sin alguna acción. En la matriz de confusión de Random Forest, se observa que 16 de los 84 datos de la clase de 3 parpadeos fueron clasificados erróneamente, mientras que en las clase de levantar las cejas 8 datos fueron clasificados erróneamente y solo 9 datos de la clase donde no se presenta alguna acción fueron confundidos. En SVM1, la clase que presentó menos datos erróneos al clasificar fue la de levantar las cejas, con solo 2 datos clasificados erróneamente, mientras que la clase de 3 parpadeos y la clase donde no se presenta alguna acción solo se clasificaron erróneamente 12 datos. Por último, en SVM2, la clase que presentó menos datos clasificados erróneamente fue la de levantar las cejas, con 5 datos, mientras que la clase de 3 parpadeos continuos y la clase donde no se presenta alguna acción tuvieron la misma cantidad de clasificación errónea que SVM1.

Tabla 5.5: Accuracy de los modelos entrenados con el sujeto 8

Sujetos de entrenamiento	Sujeto de prueba	Modelo	Hiperparámetros	Accuracy
Sujetos 1-7, 9-21	Sujeto 8	Random Forest	Máx. divisiones: 100, Criterio de división: Gini	49.20 %
		SVM1	Kernel: Gaussiano, Escala Kernel: 4.6, Restricción de caja: 1, Método: uno contra uno	50.40 %
		SVM2	Kernel: Gaussiano, Escala Kernel: 5.6, Restricción de caja: 11, Método: uno contra uno	54.00 %




Figura 5.13: Matriz de confusión de cada modelo entrenado de el sujeto 8

En las matrices de confusión del sujeto 8 figura 5.13 nos muestra que la única clase que no presento muchos errores en la clasificación en cada uno de los tres modelos con los que se trabajo fue con la señal en donde no presentaba ninguna acción y la clase que clasifiko con mas errores en los tres modelos fue la de 3 parpadeos continuos.

Lo que nos da a entender que las señales de cada sujeto pueden variar por diversas razones, y una de las más probables, que no depende del sujeto en sí, es el dispositivo Emotiv utilizado. Esto se debe a que pueden surgir varios factores que afecten las señales durante el uso de estos dispositivos, estos podrían ser debido a un contacto deficiente de los electrodos en la cabeza de los sujetos, la falta de humedad en los electrodos de fieltro o la interferencia durante el estudio.

Una razón probable para la variabilidad en la precisión de los clasificadores entre los sujetos es la presencia de diferentes variables. Durante el estudio, se solicitó a los sujetos que intentaran mantener la menor cantidad de movimientos posible en las extremidades superiores e inferiores. Sin embargo, algunos sujetos no pudieron mantenerse completamente quietos durante la prueba y realizaron movimientos con los pies o las manos. Además, algunos sujetos podrían haber ejecutado las acciones de manera incorrecta, realizando más o menos acciones de los requeridos. Por ejemplo, al realizar las acciones de 3 parpadeos seguidos, fruncir el ceño o levantar las cejas, algunos sujetos pudieron haber ejecutado múltiples acciones simultáneamente, como por ejemplo hacer parpadeos mientras fruncían el ceño o levantaban las cejas.

Estas acciones adicionales no se trataron en el pre-procesamiento solo se eliminaron del estudio aquellas señales que presentaban grandes cantidades de ruido en la señal o fueron capturadas de una manera errónea, las demás señales con las que se trabajó no se les aplicó una eliminación de estas distorsiones ya que al aplicar las técnicas comunes de eliminación de estos artefactos como el análisis de componentes independientes (ICA, por sus siglas en inglés) o variantes de esta, se eliminarían las señales de interés para este trabajo. Por lo tanto solo se les aplicó a las señales un filtro pasa bandas para reducir la señal de alimentación y señales en frecuencias muy bajas por debajo de los 2 Hz.

Para visualizar la distribución de los porcentajes del Accuracy de cada sujeto en cada uno de los modelos, se gráfico de la siguiente manera (Figura 5.14). Esta figura muestra la dispersión del Accuracy de cada clasificación, en este caso, Random Forest y Support Vector Machine (SVM), con dos conjuntos diferentes de hiperparámetros (SVM1 y SVM2).




Figura 5.14: Gráfica de dispersión del Accuracy de cada sujeto en los 3 modelos entrenados (Con mediana inclusiva)

Se observa que las señales que definen los rangos máximos y mínimos del Accuracy de cada clasificador son las de los sujetos 5 y 8. Entre estos dos rangos se encuentran los datos del resto de los sujetos. Se puede notar que, en Random Forest, la mediana es más baja y hay una mayor dispersión de los porcentajes en comparación con los clasificadores SVM1 y SVM2. Sin embargo, en SVM2, se observa una menor dispersión en comparación con los otros dos modelos. Este análisis proporciona información sobre la variabilidad en la precisión del clasificador entre diferentes sujetos y modelos.

Por ende la clasificación de las señales mencionadas se llevó a cabo de manera efectiva, a pesar de las variabilidades individuales y los desafíos técnicos asociados con el dispositivo Emotiv utilizado. Aunque se reconoce la presencia de diferentes variables entre los sujetos, los resultados muestran una distribución significativa en la precisión del clasificador entre los modelos Random Forest y Support Vector Machine (SVM), con variaciones notables en la dispersión de los datos.

Este estudio marca el inicio de un trabajo futuro, donde estas acciones podrán ser empleadas para identificar y poder ser transformadas en comandos para ser utilizables en sistemas de Interfaz Cerebro-Computadora (BCI). La capacidad de clasificar con precisión estas clases abre nuevas posibilidades en la interacción hombre-máquina, promoviendo avances significativos en la accesibilidad y la tecnología de asistencial.

5.5. Dispersión del Accuracy entre hombres y mujeres.

Al separar los porcentajes de precisión del Accuracy entre hombres y mujeres, se obtiene la siguiente gráfica (Figura 5.15). En esta figura, se observa que el Accuracy en el clasificador de Random Forest para hombres tiene la mediana más baja, con un 63.50 % así como con un valor atípico que es del 86.90 %. Sin embargo, no se observa una diferencia significativa entre la clasificación de Random Forest en mujeres, pero si presentan una mayor dispersión en los datos teniendo un desempeño menos estable en comparación con los datos de los hombres que presentan una menor dispersión.




Figura 5.15: Gráfica de dispersión del Accuracy de cada sujeto en los 3 modelos entrenados dividido entre Hombres y Mujeres (Con mediana Inclusiva)

En contraste, se observa una diferencia en los clasificadores SVM1 y SVM2 entre mujeres y hombres. Los clasificadores SVM1M y SVM2M en mujeres muestran al menos un 75 % de precisión en el Accuracy, con valores por encima del 73.20 % y 73.10 %, respectivamente, y una menor dispersión en los datos. En comparación, los modelos SVM1H y SVM2H muestran que el 75 % de los datos están por encima del 62.90 % y 63.10 %, respectivamente, con una mayor dispersión en los datos. Esto sugiere que los clasificadores SVM1 y SVM2 obtienen una precisión mayor en mujeres y presentan una menor dispersión en los datos, lo que sugiere que los modelos SVM en mujeres son más consistentes y confiables que en hombres.

Se destaca que en un sujeto hombre (Sujeto número 5), con el clasificador SVM1H, se obtuvo un Accuracy de casi el 90 % (89.70 %). Aunque este modelo logró una clasificación exitosa del 90 % para la detección de 3 parpadeos continuos, levantar las cejas y la señal sin alguna acción, así como la identificación de rangos de frecuencia

entre los 8 y 13 Hz (para ojos cerrados) y entre los 25 y 35 Hz (para la acción de morder) independientemente de los clasificadores, es importante notar que los datos del Accuracy presentaron una mayor dispersión. Esto sugiere que aunque el modelo logró un alto nivel de precisión en algunos casos, también hubo casos en los que la clasificación fue menos precisa.

En la literatura, no hay muchos trabajos relacionados que se enfoquen en la clasificación de estas acciones (3 parpadeos, fruncir el ceño, morder, levantar las cejas y ojos cerrados) en conjunto. Sin embargo, existen estudios que identifican algunas de estas acciones, como en Giudice et al. (2020) [58], donde se utiliza una CNN para la identificación de parpadeos voluntarios, obteniendo una precisión del 97.2 % +/- 4.85 % en una población de 4 sujetos. En [59], se propone un algoritmo para la identificación de parpadeos voluntarios en una población de 12 sujetos, utilizando SVM para la clasificación, logrando un 96.90 % de precisión en la detección de parpadeos en el ojo izquierdo y derecho, y un 93.8 % de precisión en la detección de parpadeos en ambos ojos. Además, en [62] y [61], se presentan trabajos que se centran en la detección de parpadeos para el control de dispositivos, generando comandos mediante la combinación de parpadeos cortos y largos, así como para la comunicación con la ayuda de un teclado virtual, utilizando los parpadeos para seleccionar letra por letra lo que se quiere decir.

En la literatura, también hay numerosos trabajos que se enfocan en la detección de gestos faciales, como Hassouneh et al. (2020) [64], Mutawa et al. (2024) [65], y Kumarg et al. (2022) [66], pero estos se centran en la clasificación de gestos faciales con imágenes, detección de emociones a través de los rasgos faciales y el uso de cámaras para la detección de estos gestos. Además, en la mayoría de los trabajos relacionados con BCI, se aplican diversas formas para la eliminación de las acciones propuestas en este estudio, como se presenta en Dash et al. (2023) [67], Rashida et al. (2023) [68], y Mumtaz et al. (2021) [69].

De acuerdo al trabajo de [70], la selección de los canales para identificar de mejor forma las señales que provienen de las acciones de levantar las cejas son los canales F7 y F8, así como los movimientos oculares verticales fueron los canales AF3, AF4, F7 y F8, lo cual se llegó a la misma conclusión en este trabajo. En estos canales es más fácil identificar y visualizar estos gestos faciales (ver Figuras 4.4 y 4.2), así como el gesto de fruncir el ceño (ver Figura 4.11). Aunque el trabajo menciona que la acción de sonreír y abrir la boca se identifica en la posición de los electrodos FC5 así como en la posición FC6.

En este trabajo no se trabajó con esas acciones, pero sí con la acción de morder y, según la visualización de los resultados obtenidos (ver Figura 4.5), se puede observar que en esos canales mencionados se alcanza a apreciar con más intensidad esta acción. Será necesario analizar más a fondo esos canales mencionados para futuros trabajos. En este trabajo realizado no se estudiaron esos canales (FC5 y FC6), ya que los canales en los que se presentaba una frecuencia entre los 25 y 35 Hz al ejercer esta

acción de morder fueron los canales O1 y O2, los cuales presentaban estas frecuencias en ambos canales al mismo tiempo, como se muestra en la figura 5.17.

Si bien el trabajo [70] se enfoca en la creación de una red neuronal artificial para detectar los gestos derivados de expresiones faciales, no muestra un Accuracy en la detección de estos gestos anteriormente mencionados, ya que los autores se centraron en desarrollar un método para seleccionar una función de activación para capas individuales de una red neuronal artificial, mencionando que en trabajos a futuro se busca adaptar e modelo para el reconocimiento de los gestos faciales simultáneos ya que se enfocaron en identificarlos por pares de canales, en el trabajo propuesto se obtuvo un Accuracy del 44.97 % \pm 6.76 % (con el modelo de SVM) en la calcificación de los gestos faciales como parpadeos, fruncir ceño, levantar las cejas, morder y señal sin alguna acción, en 6 canales (AF3, AF4, F7, F8 O1, y O2) y quitando dos acciones (Fruncir ceño y morder) así como dos canales (O1 y O2), se obtuvo un Accuracy del 72.84 % \pm 9.63 %.

Para identificar las acciones de ojos cerrados y morder, se desarrolló un algoritmo basado en la frecuencia de las señales EEG. La acción de cerrar los ojos se asocia comúnmente con un estado de relajación, manifestado por señales sinusoidales en los canales occipitales, representadas por la frecuencia alfa, que oscila entre 8 y 12 Hz como se muestra en la figura 5.16.




Figura 5.16: Visualización cuando un sujeto se encuentra con los ojos cerrados con la representación de la señal Alfa en uno de los canales Occipitales

El algoritmo toma los 6 canales de interés y recorre las señales en segmentos de 5 segundos con una superposición de 3 segundos, aplicando un pre-procesamiento que incluye un filtro pasa banda de 2 a 40 Hz. Luego, se calcula la frecuencia predominante en cada canal para obtener la frecuencia por canal figura 5.17.

Se implementa un bloque condicional que verifica si los canales occipitales presentan una frecuencia dentro del rango de 8 a 12 Hz, lo que indica la presencia de la señal alfa. En caso afirmativo, despliega un mensaje a la ventana de comandos indicando la detección de la señal alfa en ambos canales figura 5.17.

Si esta condición no se cumple, se evalúa si ambos canales presentan una frecuencia entre 25 y 35 Hz, lo que sugiere la presencia de la señal asociada con la acción de morder. En caso afirmativo, despliega un mensaje a la ventana de comandos indicando la detección de esta señal en ambos canales figura 5.17.

Si ninguna de las dos condiciones se cumple, no manda ningún mensaje a la ventana de comandos. Este enfoque permite identificar las acciones de ojos cerrados y morder en las señales EEG figura 5.17.

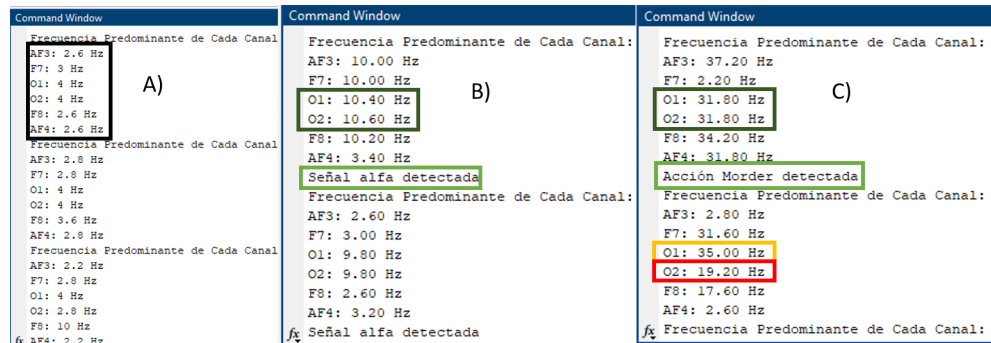


Figura 5.17: A) Frecuencia en los 6 canales seleccionados, B) En verde se muestra los canales Occipitales y el mensaje que se despliega cuando en estos dos canales se encuentra la frecuencia de 8 a 12 Hz, C) En verde se muestran los canales Occipitales y el mensaje que se despliega cuando estos dos canales se encuentran en las frecuencias entre 25 a 35 Hz y en las partes naranjas y rojas muestra que cuando en los dos canales no se encuentran en estas frecuencias no muestra ningún mensaje de detección.

Identificando así las siguientes clases que son 3 Parpadeos continuos, levantar las cejas y señal normal sin alguna acción con los clasificadores de Random Forest y Suport Vector Machine con dos diferentes hiperparametros, y con un código aparte de análisis de frecuencia se pudieron identificar la señal de Ojos cerrados y la acción de morder, en las frecuencia de 8 a 12 Hz que se representa con la señal alfa y de 25 a 35 Hz respectivamente. Como se muestra en la tabla 5.6 proponiendo así que comando podría representar cada acción identificada.

Tabla 5.6: Acciones que se podrían asociar a cada acción identificada

Comando	Descripción	Acción
Activar/Desactivar	Activar o desactivar el sistema	Ojos cerrados
Hacia adelante	Hacer la acción de despulsarse hacia adelante	Morder
Dar vuelta Izquierda	Girar hacia la izquierda	3 Parpadeos
Dar vuelta Derecha	Girar hacia la derecha	Levantar cejas

Capítulo 6

Conclusiones

En este trabajo de tesis se desarrolló un protocolo para obtener señales EEG de 25 sujetos, así como para analizar y clasificar eventos oculares continuos, gestos faciales, y la acción de morder, además de identificar el estado de ojos cerrados, de acuerdo con los objetivos establecidos. Sin embargo, de los datos obtenidos de los 25 sujetos, finalmente se trabajó únicamente con los datos de 21 sujetos (11 hombres y 10 mujeres). Esto se debió a que durante el proceso de obtención y análisis de las señales EEG, se descartaron aquellos datos que presentaron una gran cantidad de problemas.

En particular, se contribuyó inicialmente al desarrollo de un método de clasificación de señales EEG que abarcaba 6 canales, tanto en la parte frontal como occipital, con el objetivo de identificar acciones como 3 parpadeos, fruncir el ceño, morder, levantar las cejas, y una señal que no implicaba ninguna acción específica. Estas acciones fueron propuestas como los principales comandos para controlar ciertos dispositivos, tales como avanzar, retroceder, girar a la derecha y girar a la izquierda. Además, se sugirió un comando adicional para encender el dispositivo, de manera que una vez detectada la acción correspondiente (ojos cerrados), el clasificador iniciaría la detección de las acciones previamente mencionadas relacionadas con los comandos anteriores.

A pesar de que la precisión (Accuracy) fue baja en la primera prueba de los modelos de clasificación de Random Forest y SVM con diferentes conjuntos de hiperparámetros, se logró obtener un Accuracy promedio del 39.51 % \pm 6.80 %, 44.90 % \pm 6.63 %, y 44.68 % \pm 7.27 %, respectivamente. Esto se realizó excluyendo la clasificación de la señal alfa, la cual se manifiesta cuando el sujeto se encuentra en un estado de relajación con los ojos cerrados, y es fácilmente identificable mediante el análisis de la frecuencia en los canales occipitales.

Posteriormente, al realizar una eliminación de los canales O1 y O2, así como de las acciones de las señales (fruncir el ceño y acción de morder), que causaban que el modelo de clasificación tuviera un bajo rendimiento, se observó un aumento en el Accuracy en la segunda prueba de los modelos de clasificación. Este aumento fue significativo, de entre el 20 y el 30 %. Los resultados fueron los siguientes: en el modelo de Random Forest se obtuvo un Accuracy del 66.50 % \pm 10.92 %, en SVM 1 del 72.48 %

+/-10.03 % y, finalmente, en SVM2 del 72.84 % +/-9.69 %. Este incremento considerable en la precisión abre nuevas oportunidades para investigar más a fondo estas acciones.

Además de esto, se desarrolló un algoritmo para detectar las señales alfa y la acción de morder. Esto sienta las bases para la implementación de comandos basados en estas acciones, así como las acciones de 3 parpadeos continuos y levantar las cejas. Este avance es significativo para su potencial aplicación en sistemas de interfaz cerebro-computadora para una variedad de aplicaciones, como navegar a través de una interfaz de usuario y convertir estas acciones en comandos direccionales, lo que los hace más accesibles y con períodos de entrenamiento más cortos.

Por último, aunque no estuviera dentro de los objetivos originales de este trabajo, en los resultados finales se pudo observar que los modelos de SVM aplicados a mujeres mostraron una diferencia en comparación con los modelos de SVM aplicado a hombres. Aunque no se comprobó de manera estadística una diferencia significativa entre ambos resultados de los modelos de SVM, los modelos entrenados con datos de mujeres obtuvieron una mediana más alta que los modelos entrenados con datos de hombres. Además, se observó una menor dispersión de los datos en los modelos de SVM aplicados a mujeres en comparación con los modelos aplicados a hombres.

Cabe mencionar que en el transcurso de la elaboración de este trabajo, se publicó un trabajo previo [71], que sirvió como base para el presente estudio.

6.1. Trabajo a futuro

Para futuras investigaciones, sería interesante poner a prueba los modelos de clasificación entrenados en este trabajo en tiempo real para evaluar su desempeño. Esto proporcionaría información valiosa sobre la aplicabilidad y generalización de los modelos en situaciones prácticas.

Además, se podría considerar probar los datos iniciales con modelos de clasificación más robustos y especializados, como redes neuronales convolucionales, lógica difusa o algoritmos genéticos, para identificar las acciones propuestas en este trabajo. Esto permitiría explorar si el uso de estos modelos más avanzados podría aumentar la precisión del clasificador (Accuracy).

Por otro lado, se podría mejorar la robustez de la extracción de características y evaluar el tiempo de reacción en la clasificación de las señales en tiempo real. Esto implicaría evaluar si se requiere un entrenamiento extenso para cada sujeto y comparar las señales entre sujetos sanos y aquellos con limitaciones en las extremidades superiores e inferiores. Este enfoque proporcionaría información valiosa sobre la generalización del modelo en diferentes contextos y poblaciones.

Bibliografía

- [1] Instituto Nacional de Estadística y Geografía, “<https://www.inegi.org.mx/programas/ccpv/2020/>, visitado por última vez el 28/07/2023,” 2020.
- [2] M. Bear, B. Connors, and M. Paradiso, “Neurociencia la exploración del cerebro 3a. ed,” 2008.
- [3] E. C. Leuthardt, G. Schalk, J. Roland, A. Rouse, and D. W. Moran, “Evolution of brain-computer interfaces: going beyond classic motor physiology,” *Neurosurgical focus*, vol. 27, no. 1, p. E4, 2009.
- [4] R. Shriram, M. Sundhararajan, and N. Daimiwal, “Eeg based cognitive workload assessment for maximum efficiency,” *Int. Organ. Sci. Res. IOSR*, vol. 7, pp. 34–38, 2013.
- [5] J. A. Rodrigo, “Máquinas de vector soporte (svm) con python,” 2020.
- [6] J. A. Rodrigo, “Árboles de decisión con python: regresión y clasificación,” *Ciencia de Datos*, 2020.
- [7] R. Raj, S. Deb, and P. Bhattacharya, “Brain computer interfaced single key omni directional pointing and command system: a screen pointing interface for differently-abled person,” *Procedia Computer Science*, vol. 133, pp. 161–168, 2018. International Conference on Robotics and Smart Manufacturing (RoS-Ma2018).
- [8] J. G. Lau, L. Cordova-Alvarez, D. Vélez-Díaz, J. Alcalá-Rodríguez, S. Charre-Ibarra, D. Guzmán-Moya, *et al.*, “La diadema emotiv epoc+ y los gestos faciales,” *XIKUA Boletín Científico de la Escuela Superior de Tlahuelilpan*, vol. 7, no. 14, pp. 1–10, 2019.
- [9] H. A. Costa, “Desarrollo de un servicio de accesibilidad para dispositivos móviles comandado mediante una interfaz cerebro-computadora portable,” B.S. thesis, Universidad Nacional de Córdoba. Facultad de Ciencias Exactas, Físicas y
- [10] A. Kawala-Sterniuk, N. Browarska, A. Al-Bakri, M. Pelc, J. Zygarlicki, M. Sidikova, R. Martinek, and E. J. Gorzelanczyk, “Summary of over fifty years with brain-computer interfaces—a review,” *Brain Sciences*, vol. 11, no. 1, 2021.

- [11] L. Alonso-Valerdi, M. Arreola-Villarruel, and J. Argüello-García, “Interfaces cerebro-computadora: conceptualización, retos de rediseño e impacto social,” *Revista mexicana de ingeniería biomédica*, vol. 40, no. 3, 2019.
- [12] M. M. Morín-Castillo, A. Santillán-Guzmán, S. L. Sainos González, and J. J. Oliveros-Oliveros, “A wheel chair prototype moved by means of eye blinks,” *Revista Mexicana de Ingeniería Biomedica*, vol. 40, p. 1–13, Dec. 2018.
- [13] K. L. Moore, A. F. Dalley, and A. M. Agur, *Moore anatomia orientada para a clínica*. Guanabara koogan, 2014.
- [14] W. H. Organization, *Global report on health equity for persons with disabilities*. World Health Organization, 2022.
- [15] F. F. Manes and M. Niro, *Usar el cerebro*. Planeta Argentina, 2014.
- [16] M. S. L. Permuy, *Manual de bases biológicas del comportamiento humano*. José Enrique Rodó 1827 - Montevideo CP: 11200: Universidad de la República, 1 ed., 2011.
- [17] L. V. Romero, *Anatomía y Fisiología del sistema nervioso*. XinXii, 2015.
- [18] M. S. L. Permuy, “Manual de bases biológicas del comportamiento humano,” *Unidad de Comunicación de la Universidad de la República (UCUR)*, 2011.
- [19] M. Pérez Frutos, “Adquisición y tratamiento de señales eeg: caso de aplicación en java,” 2019.
- [20] F. N. Jamaluddin, S. A. Ahmad, S. B. M. Noor, and W. Z. W. Hasan, “Flexible bio-signals channels acquisition system for ecg and emg application,” in *2014 IEEE Student Conference on Research and Development*, pp. 1–4, IEEE, 2014.
- [21] M. Hanani, “Satellite glial cells in sensory ganglia: from form to function,” *Brain research reviews*, vol. 48, no. 3, pp. 457–476, 2005.
- [22] P. Pindado Herráez *et al.*, “Integración del dispositivo emotiv epoc en una aplicación brain computer interfaze (bci) asociada al control de un exoesqueleto,” 2021.
- [23] M. A. Rahman, A. B. Siddik, T. K. Ghosh, F. Khanam, and M. Ahmad, “A narrative review on clinical applications of fnirs,” *Journal of Digital Imaging*, vol. 33, pp. 1167–1184, 2020.
- [24] J. J. Vidal, “Toward direct brain-computer communication,” *Annual review of Biophysics and Bioengineering*, vol. 2, no. 1, pp. 157–180, 1973.
- [25] V. Jurcak, D. Tsuzuki, and I. Dan, “10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems,” *Neuroimage*, vol. 34, no. 4, pp. 1600–1611, 2007.

- [26] E. U. Oxford University Press, ed., *Campos eléctricos del cerebro: la neurofísica del EEG*. 2006.
- [27] G. M. Martínez de la Teja, “Ergonomía e interfaces de interacción humano-computadora,” in *IX Congreso Internacional de la Ergonomía, México, DF*, vol. 8, 2007.
- [28] Emotiv, “Emotiv - brain data measurement and insights,” 2023. Accessed: 2023-07-28.
- [29] S. N. Abdulkader, A. Atia, and M.-S. M. Mostafa, “Brain computer interfacing: Applications and challenges,” *Egyptian Informatics Journal*, vol. 16, no. 2, pp. 213–230, 2015.
- [30] E. P. Zambalde *et al.*, “Ssvep-based bci with visual stimuli from lcd screen applied for wheelchair control: Offline and online investigations,” 2018.
- [31] Y. Zhou, S. He, Q. Huang, and Y. Li, “A hybrid asynchronous brain-computer interface combining ssvep and eeg signals,” *IEEE Transactions on Biomedical Engineering*, vol. 67, no. 10, pp. 2881–2892, 2020.
- [32] A. M. Pedrón, “Potenciales evocados auditivos de estado estable a múltiples frecuencias: valoración de los estudios sobre localización de sus generadores cerebrales,” *Medisan*, vol. 15, no. 9, pp. 1268–1279, 2011.
- [33] N. Alonso and L. Fernando, “Clasificación de características de electroencefalogramas en sistemas brain computer interface basados en ritmos sensoriomotores,” 2012.
- [34] D. X. Osma Molina and G. C. Naranjo Gaona, “Estudio comparativo de los métodos de adquisición de las señales cerebrales para las interfaces cerebro computadora para personas con esclerosis lateral amiotrófica,” 2021.
- [35] A. Adam, N. Mokhtar, M. Mubin, Z. Ibrahim, and M. Shapiai, “Evaluation of different peak models of eye blink eeg for signal peak detection using artificial neural network.,” *Neural Network World*, no. 1, 2016.
- [36] U. Heute and A. S. Guzmán, “Removing “cleaned” eye-blinking artifacts from eeg measurements,” in *2014 International Conference on Signal Processing and Integrated Networks (SPIN)*, pp. 576–580, IEEE, 2014.
- [37] A. Zhang, B. Yang, and L. Huang, “Feature extraction of eeg signals using power spectral entropy,” in *2008 international conference on BioMedical engineering and informatics*, vol. 2, pp. 435–439, IEEE, 2008.
- [38] B. Medina, J. E. SIERRA, and A. B. ULLOA, “Técnicas de extracción de características de señales eeg en la imaginación de movimiento para sistemas bci,” *Revista ESPACIOS*, vol. 39, no. 22, 2018.

- [39] S. Huang and X. Wu, "Feature extraction and classification of eeg for imagery movement based on mu/beta rhythms," in *2010 3rd International Conference on Biomedical Engineering and Informatics*, vol. 2, pp. 891–894, IEEE, 2010.
- [40] A. Ravi, N. Heydari, and N. Jiang, "User-independent ssvep bci using complex fft features and cnn classification," in *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, pp. 4175–4180, 2019.
- [41] K. Nakayama, Y. Kaneda, and A. Hirano, "A brain computer interface based on fft and multilayer neural network - feature extraction and generalization -," in *2007 International Symposium on Intelligent Signal Processing and Communication Systems*, pp. 826–829, 2007.
- [42] V. J. Samar, A. Bopardikar, R. Rao, and K. Swartz, "Wavelet analysis of neuroelectric waveforms: a conceptual tutorial," *Brain and language*, vol. 66, no. 1, pp. 7–60, 1999.
- [43] S. Chaudhary, S. Taran, V. Bajaj, and S. Siuly, "A flexible analytic wavelet transform based approach for motor-imagery tasks classification in bci applications," *Computer Methods and Programs in Biomedicine*, vol. 187, p. 105325, 2020.
- [44] H. Göksu, "Bci oriented eeg analysis using log energy entropy of wavelet packets," *Biomedical Signal Processing and Control*, vol. 44, pp. 101–109, 2018.
- [45] B. Xu, L. Zhang, A. Song, C. Wu, W. Li, D. Zhang, G. Xu, H. Li, and H. Zeng, "Wavelet transform time-frequency image and convolutional network-based motor imagery eeg classification," *IEEE Access*, vol. 7, pp. 6084–6093, 2019.
- [46] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu, "The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis," *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, vol. 454, no. 1971, pp. 903–995, 1998.
- [47] L. Marple, "Computing the discrete-time 'analytic' signal via fft," *IEEE Transactions on Signal Processing*, vol. 47, no. 9, pp. 2600–2603, 1999.
- [48] R. J. Martis, U. R. Acharya, J. H. Tan, A. Petznick, R. Yanti, C. K. Chua, E. Ng, and L. Tong, "Application of empirical mode decomposition (emd) for automated detection of epilepsy using eeg signals," *International Journal of Neural Systems*, vol. 22, no. 6, 2012. Cited by: 222.
- [49] R. J. Oweis and E. W. Abdulhay, "Seizure classification in eeg signals utilizing hilbert-huang transform," *Biomedical engineering online*, vol. 10, pp. 1–15, 2011.
- [50] V. Bajaj and R. B. Pachori, "Separation of rhythms of eeg signals based on hilbert-huang transformation with application to seizure detection," in *Convergence and Hybrid Information Technology: 6th International Conference, ICHIT*

- 2012, Daejeon, Korea, August 23-25, 2012. *Proceedings 6*, pp. 493–500, Springer, 2012.
- [51] K. Fu, J. Qu, Y. Chai, and Y. Dong, “Classification of seizure based on the time-frequency image of eeg signals using hht and svm,” *Biomedical Signal Processing and Control*, vol. 13, pp. 15–22, 2014.
- [52] P. Shenoy, M. Krauledat, B. Blankertz, R. P. Rao, and K.-R. Müller, “Towards adaptive classification for bci,” *Journal of neural engineering*, vol. 3, no. 1, p. R13, 2006.
- [53] A. Sharma, “Machine learning 101: Decision tree algorithm for classification,” *ANALYTICS VIDHYA (February 25, 2021) available at <https://www.analyticsvidhya.com/blog/2021/02/machine-learning-101-decisiontree-algorithm-for-classification>*, 2021.
- [54] M. Del Castillo, J. Serrano, S. Lerma, I. Martínez, and E. Rocon, “Evaluación neurofisiológica del entrenamiento de la imaginación motora con realidad virtual en pacientes pediátricos con parálisis cerebral,” *Revista Iberoamericana de Automática e Informática industrial*, vol. 15, no. 2, pp. 174–179, 2018.
- [55] S. Dash, R. K. Tripathy, G. Panda, and R. B. Pachori, “Automated recognition of imagined commands from eeg signals using multivariate fast and adaptive empirical mode decomposition based method,” *IEEE Sensors Letters*, vol. 6, no. 2, pp. 1–4, 2022.
- [56] A. A. Torres-García, C. A. Reyes-García, L. Villaseñor-Pineda, and G. García-Aguilar, “Implementing a fuzzy inference system in a multi-objective eeg channel selection model for imagined speech classification,” *Expert Systems with Applications*, vol. 59, pp. 1–12, 2016.
- [57] J. S. García-Salinas, L. Villaseñor-Pineda, C. A. Reyes-García, and A. A. Torres-García, “Transfer learning in imagined speech eeg-based bcis,” *Biomedical Signal Processing and Control*, vol. 50, pp. 151–157, 2019.
- [58] M. L. Giudice, G. Varone, C. Ieracitano, N. Mammone, A. R. Bruna, V. Tomaselli, and F. C. Morabito, “1d convolutional neural network approach to classify voluntary eye blinks in eeg signals for bci applications,” in *2020 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–7, IEEE, 2020.
- [59] I. Rejer and Ł. Cieszyński, “Rveb—an algorithm for recognizing voluntary eye blinks based on the signal recorded from prefrontal eeg channels,” *Biomedical Signal Processing and Control*, vol. 59, p. 101876, 2020.
- [60] W. C. Francis, C. Umayal, and G. Kanimozhi, “Brain-computer interfacing for wheelchair control by detecting voluntary eye blinks,” *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, vol. 9, no. 2, pp. 521–537, 2021.

- [61] D. Harshini, M. Ranjitha, R. Jadon, *et al.*, “A single electrode blink for text interface (bci),” in *2020 IEEE International Conference for Innovation in Technology (INOCON)*, pp. 1–5, IEEE, 2020.
- [62] S. P. Zavala, S. G. Yoo, and D. E. V. Tituana, “Controlling a wheelchair using a brain computer interface based on user controlled eye blinks,” *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 6, 2021.
- [63] L. Kanungo, N. Garg, A. Bhobe, S. Rajguru, and V. Baths, “Wheelchair automation by a hybrid bci system using ssvep and eye blinks,” in *2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 411–416, IEEE, 2021.
- [64] A. Hassouneh, A. Mutawa, and M. Murugappan, “Development of a real-time emotion recognition system using facial expressions and eeg based on machine learning and deep neural network methods,” *Informatics in Medicine Unlocked*, vol. 20, p. 100372, 2020.
- [65] A. Mutawa and A. Hassouneh, “Multimodal real-time patient emotion recognition system using facial expressions and brain eeg signals based on machine learning and log-sync methods,” *Biomedical Signal Processing and Control*, vol. 91, p. 105942, 2024.
- [66] S. Kumar G S, N. Sampathila, and T. Tanmay, “Wavelet based machine learning models for classification of human emotions using eeg signal,” *Measurement: Sensors*, vol. 24, p. 100554, 2022.
- [67] S. Dash, P. Gajbhiye, P. Sawangjai, G. Sawadwuthikul, T. Sudhawiyangkul, R. K. Tripathy, and R. B. Pachori, “Dyadic boundary points based empirical wavelet transform for the elimination of eye movement and eye blink-based ocular artifacts from eeg signals,” *Biomedical Signal Processing and Control*, vol. 85, p. 104996, 2023.
- [68] M. Rashida and M. A. Habib, “Quantitative eeg features and machine learning classifiers for eye-blink artifact detection: A comparative study,” *Neuroscience Informatics*, vol. 3, no. 1, p. 100115, 2023.
- [69] W. Mumtaz, S. Rasheed, and A. Irfan, “Review of challenges associated with the eeg artifact removal methods,” *Biomedical Signal Processing and Control*, vol. 68, p. 102741, 2021.
- [70] A. Kubacki, L. Sawicki, and P. Owczarek, “Detection of facial gestures artefacts created during an eeg research using artificial neural networks,” in *2016 21st International Conference on Methods and Models in Automation and Robotics (MMAR)*, pp. 783–787, IEEE, 2016.
- [71] D. M. C. Peña, M. V. Miranda, L. V. Pineda, C. A. R. García, and A. S. Guzmán, “Eeg signal-based eye blink classifier using random forest for bci systems,” in

2022 *IEEE International Conference on Engineering Veracruz (ICEV)*, pp. 1–5, 2022.

- [72] A. E. Pereda, “Electrical synapses and their functional interactions with chemical synapses,” *Nature Reviews Neuroscience*, vol. 15, no. 4, pp. 250–263, 2014.
- [73] D. E. Sadava, D. M. Hillis, and H. C. Heller, *Life: the science of biology*, vol. 2. Macmillan, 2009.
- [74] B. W. Connors, “transmisión sináptica en el sistema nervioso,” *Fisiología médica*, p. 306, 2017.
- [75] E. B. Zuleta, *El sistema nervioso: desde las neuronas hasta el cerebro humano*. Universidad de Antioquia, 2007.

Apéndice A

Carta de consentimiento informado

Carta de consentimiento informado

DESARROLLO DE UNA INTERFAZ CEREBRO COMPUTADORA CON SEÑALES EEG USANDO PARPADEOS Y OJOS CERRADOS

Responsable: Biol. David Manuel Carmona Peña, Maestría en Ciencias y Tecnologías Biomédicas, INAOE

Puebla, PUE., a _____ de 2023

Participante: _____

El objetivo de este estudio es capturar las señales EEG que van a servir para una interfaz cerebro computadora para el reconocimiento de señales EEG y artefactos.

Duración aproximada del estudio: de 20 a 25 minutos.

Antes de acudir a la grabación de señales EEG le solicitamos seguir las siguientes recomendaciones:

- Llegar con el cabello seco y al peinarse no usar fijador, gel, cera, acondicionador en el cabello, ya que podría afectar las mediciones.
- Bañarse un día antes del estudio ya que si el cabello se encuentra mojado o con algún producto para el cabello afectaría la señal.
- Dormir bien y horario normal de sueño
- Horario normal de comida (dejar pasar 1 hora después de su última comida)
- No haber consumido cafeína antes del estudio
- Llegar 10 minutos antes de la hora solicitada al lugar donde se realizará el estudio
- No realizar actividad física 8 horas antes del estudio
- No haber consumido bebidas alcohólicas las 12 horas antes del estudio

El estudio se realizará por personal capacitado, por favor, seguir las recomendaciones e instrucciones

Procedimiento:

- Se le colocara al participante el dispositivo EEG.
- Permanecerá con los ojos abiertos por 20 segundos.
- Permanecerá con los ojos cerrados por 20 segundos.
- Hacer 3 parpadeos continuos y luego 5 segundos sin parpadeos, esto continuamente hasta completar un minuto aproximadamente.
- Fruncir el ceño mantenerlo por 5 segundos y después 5 segundos de descanso, se repetirá hasta cumplir un minuto aproximadamente.
- Morder por 5 segundos y después 5 segundos relajado, esto se repetirá hasta completar un minuto aproximado.

- Levantar las cejas y mantenerlas por 5 segundos y después 5 segundos de descanso, se repetirá hasta cumplir aproximadamente un minuto.
- Finalmente hacer 5 parpadeos y luego 5 segundos sin parpadeos, esto hasta completar un minuto de prueba.
- Entre cada actividad habrá un descanso de 10 segundos.
- Las actividades se van a repetir 3 veces, después de cada ciclo se procederá a cerrar los ojos por 15 segundos.
- Acabando estos tres ciclos se harán dos actividades extra que consistirán en: fruncir el ceño 3 veces seguidas y después un descanso de 5, la otra actividad es levantar la ceja 3 veces seguidas y 5 segundos de descanso, estas dos actividades se repetirán hasta tener 15 repeticiones
- Finalmente permanecer con los ojos cerrados por 15 segundos.
- Se procederá a retirar el dispositivo EEG.

El estudio no provoca dolor ni molestias.

Yo _____ he leído y comprendido la información anterior. Reconozco haber sido informado (a) de forma clara y sencilla de los detalles sobre el procedimiento al que voluntariamente voy a participar, que el estudio no tiene ningún riesgo, no tiene costo y tampoco recibiré beneficio económico por mi participación y acuso de haber recibido respuestas satisfactorias a todas las preguntas que hubiere formulado. Además, entiendo que los resultados obtenidos en el estudio pueden ser publicados o difundidos con fines científicos.

MANIFIESTO QUE HE SIDO INFORMADO (A) Y QUE COMPRENDO LOS PROCEDIMIENTOS Y LAS ESPECIFICACIONES DE LA PRUEBA EEG, TAL COMO SE DESCRIBEN EN ESTE DOCUMENTO.

Firma y nombre del participante

Apéndice B

Tablas de los resultados obtenidos por cada sujeto

Tabla 1 Resultado obtenidos del Test por cada sujeto y por cada modelo de clasificación entrenado.

Sujetos con el que se entrenó el modelo	Modelo entrenado	Hiperparametros del modelo	Sujeto con el que se probó el modelo	Accuracy Test	Datos a quitar del entrenamiento
Sujetos del 1 al 20	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 21	49.50%	los últimos 126
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 21	57.50%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 21	57.90%	
Sujetos del 2 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 1	42.20%	los primeros 126
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 1	44.60%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 1	46.70%	

Sujeto 1 y del 3 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 2	36.30%	del 126 al 252
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 2	42.50%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 2	42.20%	
Sujeto 1, 2 y del 4 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 3	32.70%	del 252 al 378
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 3	37.80%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 3	37.80%	
Sujeto del 1 al 3 y del 5 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 4	41.90%	del 348 al 504

	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 4	43.20%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 4	44.10%	
Sujeto del 1 al 4 y del 6 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 5	39.80%	del 504 al 630
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 5	46.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 5	45.90%	
Sujeto del 1 al 5 y del 7 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 6	38.70%	del 630 al 756
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 6	48.10%	

	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 6	45.40%	
Sujeto del 1 al 6 y del 8 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 7	41.10%	del 756 al 882
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 7	49.20%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 7	48.60%	
Sujeto del 1 al 7 y del 9 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 8	40.50%	del 882 al 1008
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 8	40.30%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 8	40.80%	

Sujeto del 1 al 8 y del 10 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Gini	Sujeto 9	42.00%	del 1008 al 1134
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 9	46.30%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 9	45.10%	
Sujeto del 1 al 9 y del 11 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Gini	Sujeto 10	39.50%	del 1134 al 1260
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 10	43%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 10	42.70%	
Sujeto del 1 al 10 y del 12 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Gini	Sujeto 11	44%	del 1260 al 1386

	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 11	52.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 11	54.40%	
Sujeto del 1 al 11 y del 13 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 12	28.10%	del 1386 al 1512
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 12	34%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 12	34%	
Sujeto del 1 al 12 y del 14 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 13	34.90%	1512 al 1638
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 13	38.70%	

	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 13	37.50%	
Sujeto del 1 al 13 y del 15 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 14	32.10%	del 1638 al 1764
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 14	42.40%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 14	41.10%	
Sujeto del 1 al 14 y del 16 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 15	43.20%	del 1764 al 1890
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 15	45.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 15	46%	

Sujeto del 1 al 15 y del 17 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 16	51.10%	del 1890 al 2016
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 16	54.40%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 16	51.70%	
Sujeto del 1 al 16 y del 18 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 17	27.30%	del 2016 al 2142
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 17	35.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 17	31.90%	
Sujeto del 1 al 17 y del 19 al 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 18	38.60%	del 2142 al 2268

	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 18	47.10%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 18	49%	
Sujeto del 1 al 18 y 20, 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 19	33.30%	del 2268 al 2394
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 19	36.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 19	35.90%	
Sujeto del 1 al 19 y el 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 20	53%	del 2394 al 2520
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 20	56.30%	

	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 20	59.50%	
--	------	--	-----------	--------	--

Tabla 2 Promedio obtenido por cada modelo y su desviación estándar así como la Mediana obtenida.

Modelo	Promedio	Desviación estándar (+/-)	Mediana
Random Forest	39.51%	6.80%	39.80%
SVM1	44.90%	6.63%	44.60%
SVM2	44.68%	7.32%	45.10%

Tabla 3 Resultado obtenidos del Test por cada sujeto y por cada modelo de clasificación entrenado, solo con tres clases y 4 canales seleccionados.

Sujetos con el que se entrenó el modelo	Modelo entrenado	Hiperparametros del modelo	Sujeto con el que se probó el modelo	Accuracy test	Datos a quitar del entrenamiento
SUJETOS DEL 1 AL 20	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Gini	Sujeto 21	82.10%	los últimos 126
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 21	82.50%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 21	82.10%	
SUJETOS DEL 2 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Gini	Sujeto 1	62.70%	los primeros 126
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 1	71%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 1	71.40%	
SUJETO 1 Y DEL 3 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Gini	Sujeto 2	54.80%	del 126 al 252

	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 2	58.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 2	57.10%	
SUJETO 1, 2 Y DEL 4 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 3	60.70%	del 252 al 378
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 3	65.50%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 3	64.30%	
SUJETO DEL 1 AL 3 Y DEL 5 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 4	64.70%	del 378 al 504
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 4	72.60%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11	Sujeto 4	70.20%	

		Método multiclase: One vs One			
SUJETO DEL 1 AL 4 Y DEL 6 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 5	86.90%	del 504 al 630
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 5	89.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 5	88.50%	
SUJETO DEL 1 AL 5 Y DEL 7 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 6	50%	del 630 al 756
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 6	60.30%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 6	61.90%	
SUJETO DEL 1 AL 6 Y DEL 8 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 7	72.20%	del 756 al 882

	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 7	77%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 7	78.20%	
SUJETO DEL 1 AL 7 Y DEL 9 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 8	49.20%	del 882 al 1008
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 8	50.40%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 8	54%	
SUJETO DEL 1 AL 8 Y DEL 10 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 9	64.30%	del 1008 al 1134
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 9	71%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11	Sujeto 9	73.80%	

		Método multiclase: One vs One			
SUJETO DEL 1 AL 9 Y DEL 11 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 10	63.50%	del 1134 al 1260
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 10	66.70%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 10	69%	
SUJETO DEL 1 AL 10 Y DEL 12 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 11	69.40%	del 1260 al 1386
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 11	75.80%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 11	76.20%	
SUJETO DEL 1 AL 11 Y DEL 13 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 12	73.40%	del 1386 al 1512

	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 12	82.10%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 12	81.70%	
SUJETO DEL 1 AL 12 Y DEL 14 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 13	69.40%	1512 al 1638
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 13	72.20%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 13	72.20%	
SUJETO DEL 1 AL 13 Y DEL 15 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 14	58.30%	del 1638 al 1764
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 14	61.90%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11	Sujeto 14	64.70%	

		Método multiclase: One vs One			
SUJETO DEL 1 AL 14 Y DEL 16 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 15	73%	del 1764 al 1890
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 15	78.60%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 15	77.40%	
SUJETO DEL 1 AL 15 Y DEL 17 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 16	86.10%	del 1890 al 2016
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 16	86.10%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 16	87.30%	
SUJETO DEL 1 AL 16 Y DEL 18 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 17	52.80%	del 2016 al 2142

	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 17	76.20%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 17	75.80%	
SUJETO DEL 1 AL 17 Y DEL 19 AL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 18	76.20%	del 2142 al 2268
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 18	83.30%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 18	85.30%	
SUJETO DEL 1 AL 18 Y 20, 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 19	57.90%	del 2268 al 2394
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 19	63.10%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11	Sujeto 19	61.50%	

		Método multiclase: One vs One			
SUJETO DEL 1 AL 19 Y EL 21	Random Forest	Número máximo de divisiones: 100 Criterio de la división: Ginis	Sujeto 20	68.80%	del 2394 al 2520
	SVM1	Función de del Kernel: Gaussian Escala del kernel: 4.6 Nivel de restricción de caja: 1 Método multiclase: One vs One	Sujeto 20	77.40%	
	SVM2	Función de del Kernel: Gaussian Escala del kernel: 5.6 Nivel de restricción de caja: 11 Método multiclase: One vs One	Sujeto 20	77%	

Tabla 4 Promedio obtenido por cada modelo, así como el promedio obtenido en hombres y mujeres y su desviación estándar así como la Mediana obtenida.

Modelo	Promedio	Desviación estándar	Mediana	Hombres	Desviación estándar	Mediana	Mujeres	Desviación estándar	Mediana
Random Forest	66.50%	10.92%	64.70%	63.49%	10.64%	63.50%	69.80%	10.78%	71.20%
SVM1	72.48%	10.03%	72.60%	68.97%	10.51%	71.00%	76.34%	8.31%	78.00%
SVM2	72.84%	9.69%	73.80%	69.51%	9.92%	70.20%	76.50%	8.41%	77.20%

Apéndice C

Visualización de cada acción en los respectivos canales seleccionados y proceso que se llevo acabo en cada acción

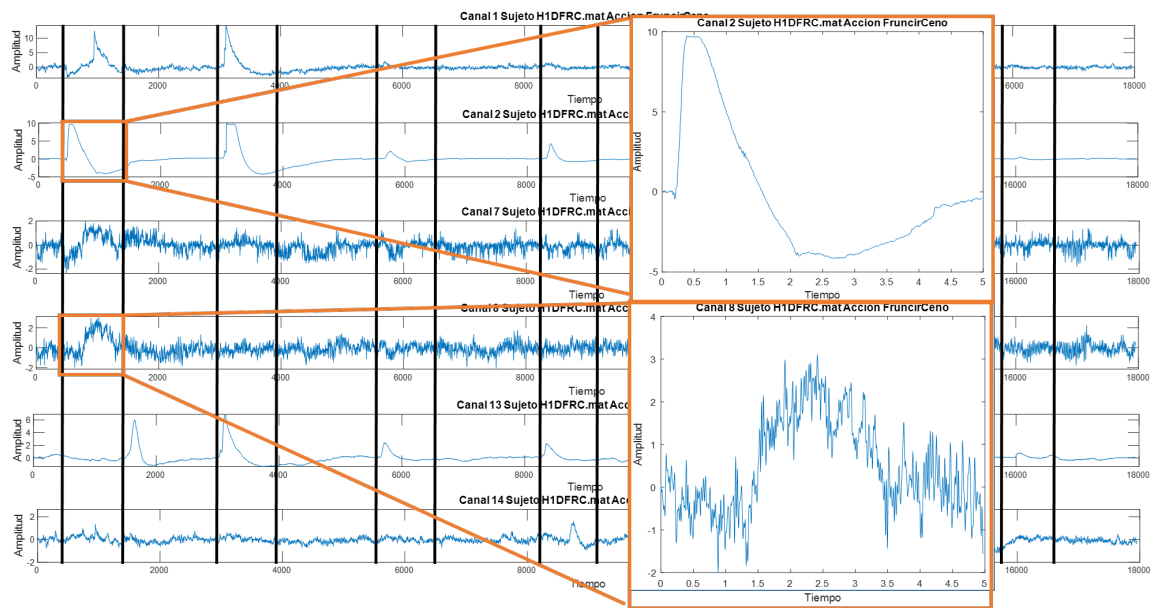


Figura C.1: Cortes de cada canal mostrando cada sección de Fruncir el Ceño, acercando una sección de un canal frontal y un canal occipital.




Figura C.2: Cortes de cada canal mostrando cada sección de Levantar Cejas, acercando una sección de un canal frontal y un canal occipital.




Figura C.3: De Izquierda a derecha, Señal sin filtro de la acción Levantar las cejas, señal con filtro pasa bandas de 2 a 40Hz y señal después de la eliminación de ruido con Wavelet db4.

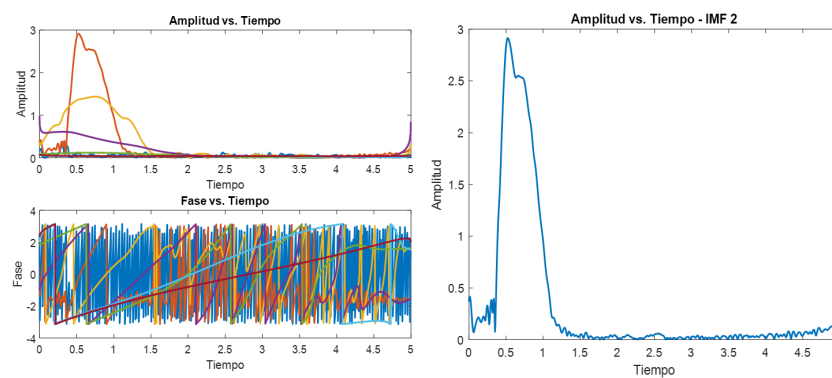


Figura C.4: De Izquierda a derecha, transformada de Hilbert Amplitud vs tiempo y fase vs tiempo, segundo dato del resultado de Hilbert. Acción Levantar las Cejas.

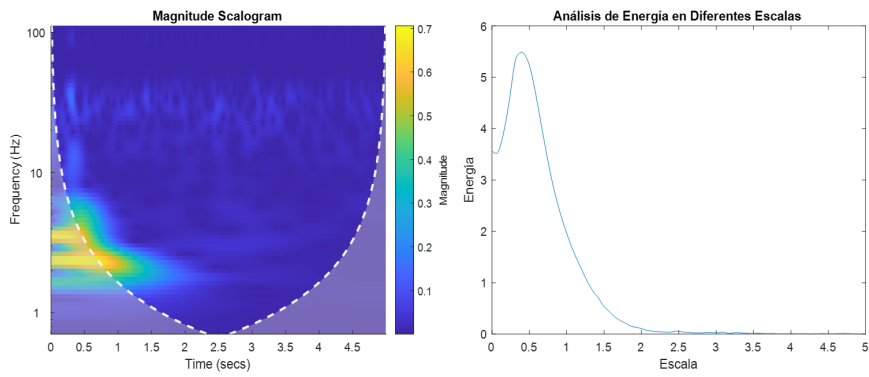


Figura C.5: De Izquierda a derecha, escanograma de CWT energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo. Acción Levantar las Cejas




Figura C.6: De Izquierda a derecha, Señal sin filtro de la acción Morder, señal con filtro pasa bandas de 2 a 40Hz y señal después de la eliminación de ruido con Wavelet db4.

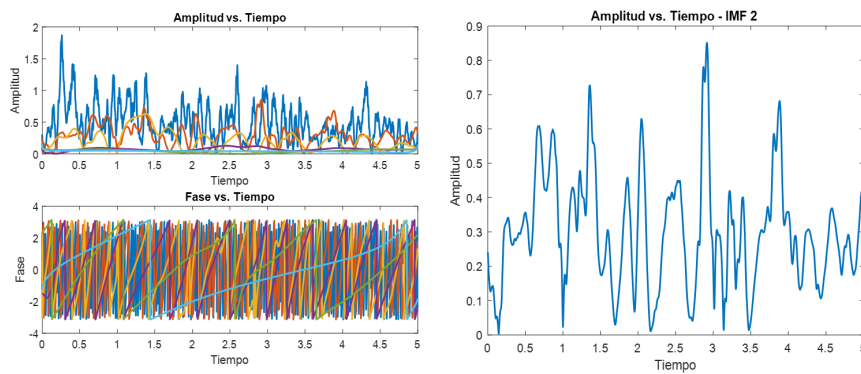


Figura C.7: De Izquierda a derecha, trasformada de Hilbert Amplitud vs tiempo y face vs tiempo, segundo dato del resultado de Hilbert. Acción Morder.

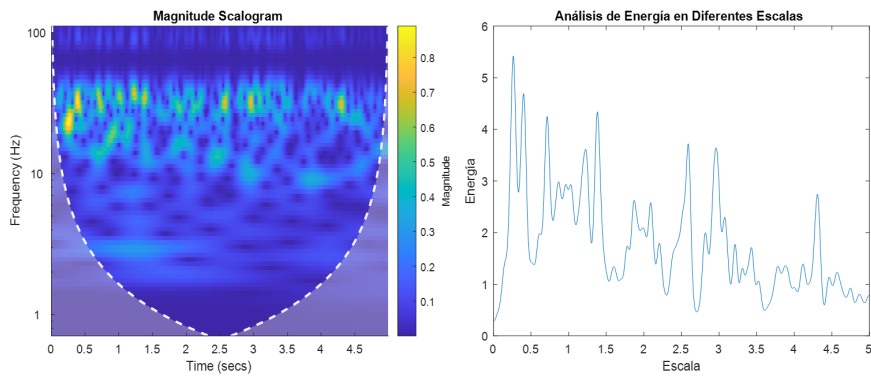


Figura C.8: De Izquierda a derecha, escanograma de CWT energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo. Acción Morder




Figura C.9: De Izquierda a derecha, Señal sin filtro de la acción FruncirCeño, señal con filtro pasa bandas de 2 a 40Hz y señal después de la eliminación de ruido con Wavelet db4.

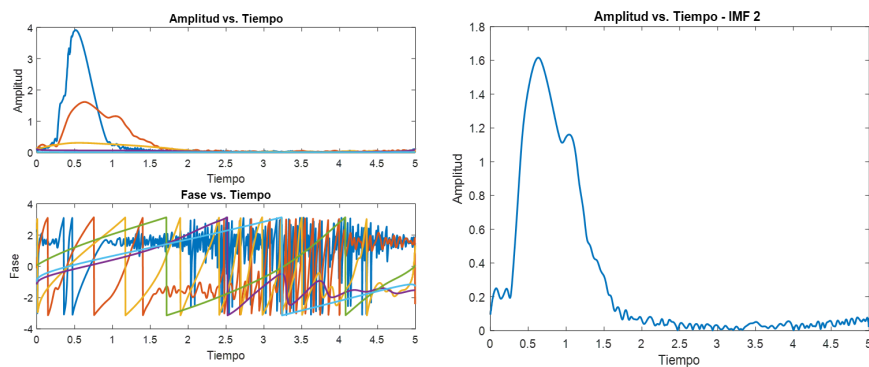


Figura C.10: De Izquierda a derecha, transformada de Hilbert Amplitud vs tiempo y fase vs tiempo, segundo dato del resultado de Hilbert. Acción Fruncir Ceño.

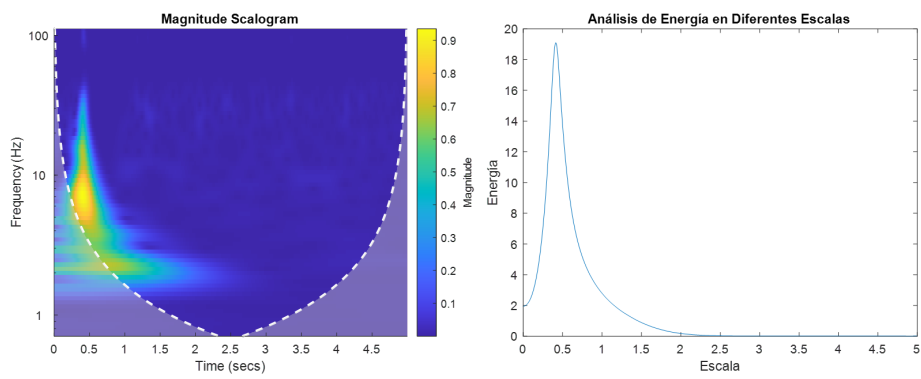


Figura C.11: De Izquierda a derecha, escanograma de CWT energía calculada de la suma de la magnitud cuadrada a lo largo del tiempo. Acción Fruncir Ceño