

Caracterización de gestos faciales y oculares mediante EEG utilizando SVM

Juan Sebastián Ovalle Silva

**Fundación Universitaria Los Libertadores
Facultad De Ingenierías
Programa De Ingeniería Electrónica
Bogotá, D. C.
2018**

Caracterización de gestos faciales y oculares mediante EEG utilizando SVM

Juan Sebastián Ovalle Silva

Trabajo de grado para optar El Título de Ingeniero Electrónico

Director:

John Petearson Anzola Anzola
Ingeniero Electrónico

Codirector:

Alexander García Mariaca
Ingeniero Mecánico

Fundación Universitaria Los Libertadores
Facultad De Ingenierías
Programa De Ingeniería Electrónica
Bogotá, D. C.
2018

Contenido

Pág.

Resumen.....	11
1 Introducción.....	12
2 Problema de investigación.....	13
2.1 Planteamiento del problema	13
2.2 Objetivos	13
2.2.1 Objetivo General	13
2.2.2 Objetivos específicos	13
2.3 Justificación.....	14
3 Marco de referencia	14
3.1 Antecedentes del problema.....	14
3.1.1 Control de movimiento robótico con detección cognitiva y facial mediante Emotiv EEG.....	14
3.1.2 Lower Body Segmental Dynamics Control Using Eye Blinking Activity	17
3.1.3 Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas [14].....	19
3.1.4 Classification of EEG Signals in a Brain-Computer Interface System [8]	21
3.1.5 Emotiv EPOC BCI with Python on a Raspberry pi	26
3.1.6 Controlling a Robot Using Brain Waves	30
3.2 Marco Conceptual	33
3.2.1 Técnicas de medición de la actividad cerebral.....	33
3.2.2 Sistema Internacional 10-20.....	33
3.2.3 Transformada rápida de Fourier (FFT)	35

3.2.4	Funciones de ventana	36
3.2.5	Densidad espectral de potencia	37
3.2.6	Convolución	37
3.2.7	Correlación	37
3.2.8	Máquinas de soporte vectorial (SVM)	37
3.2.9	Validación cruzada	39
4	Diseño metodológico	40
4.1	Tipo y enfoque de la investigación	41
4.2	Corpus de investigación	41
4.3	Instrumentos	42
4.3.1	Hardware	42
4.3.2	Software	44
5	Desarrollo ingenieril	44
6	Toma de datos	49
7	Análisis de resultados	52
7.1	Procesamiento de señales	52
7.1.1	Eliminación de Offset DC	53
7.2	Extracción de características	57
7.3	Caracterización de gestos faciales	64
7.3.1	Convolución y Correlación	64
7.3.2	Máquinas de soporte vectorial (SVM)	69
	Conclusiones	77
	Bibliografía	78
	Anexos	80

Lista de figuras

Pág.

Figura 1. Arquitectura del sistema. [6].....	15
Figura 2. Instancias para el manejo del robot. [6].....	16
Figura 3. Diadema Neurosky. [13].....	17
Figura 4. Interfaz gráfica. [13]	18
Figura 5. Resultado de la investigación. [13].....	19
Figura 6. Pasos de toma de datos [14].....	19
Figura 7. PSD estimado de cada electrodo usado [14].....	20
Figura 8. Principales componentes del sistema diseñado [8].....	21
Figura 9. Interfaz gráfica BrainMonitor [8]	22
Figura 10. Arquitectura de la red neuronal [8].....	24
Figura 11. Sistema final de prueba [8]	25
Figura 12. Diagrama del BCI [15]	26
Figura 13. Espectrograma de todas las acciones [15]	27
Figura 14. Diagrama principal de los procesos [15]	29
Figura 15. Brazo robótico utilizado con sus respectivos movimientos [15].....	30
Figura 16. Arquitectura del proyecto [16].....	31
Figura 17. Circuito final del proyecto [16]	32
Figura 18. Electrodo de la diadema Emotiv EPOC+ con respecto al sistema internacional 10-20.[17].....	34
Figura 19. Vista lateral de hemisferio cerebral con visualización de la ubicación de cada lóbulo. [18].....	35
Figura 20. Ejemplo de ventana de superficie plana [19].....	36
Figura 21. Explicación grafica de la convolución [20].....	37
Figura 22. Validación cruzada de 4 iteraciones (K=4) [22].....	40
Figura 23. Metodología general de la investigación	41

Figura 24. Dispositivo Emotiv EPOC+ [24].....	42
Figura 25. Ubicación específica de cada sensor del Emotiv EPOC+ [17].....	43
Figura 26. Puerto Micro USB de la diadema EPOC+ [25].....	45
Figura 27. Hidratación de los electrodos [25].....	45
Figura 28. Instalación de los sensores [25].....	46
Figura 29. Emparejando la diadema EPOC+ [25].....	46
Figura 30. Colocación de la diadema (primera fase) [25].....	47
Figura 31. Colocación de la diadema (segunda fase) [25].....	48
Figura 32. Mapa de los electrodos con sus posibles estados de contacto. [25].....	49
Figura 33. Mapa de los electrodos en el estado deseado para cada toma de datos. [25].....	50
Figura 34. Ejemplo de prueba cuando el sujeto mueve los ojos a la derecha.....	51
Figura 35. Ejemplo de prueba cuando el sujeto parpadea.....	52
Figura 36. Datos brutos exportados de la diadema EPOC+ en formato .CSV.....	53
Figura 37. Datos originales y datos resultantes mediante el método de la mediana. (S3)...	54
Figura 38. Ventana plana utilizada.....	55
Figura 39. Diagrama de flujo del procesamiento de señales.....	56
Figura 40. Resultado de las señales después del uso de la ventana plana. (S3).....	57
Figura 41. Resultado de la transformada rápida de Fourier (S3).....	58
Figura 42. Resultado del uso de densidad espectral de potencia. (S3).....	59
Figura 43. Resultado del uso de diagrama de cajas (S3).....	60
Figura 44. Diagrama de flujo para procesos de FFT, PSD y diagrama de cajas.....	61
Figura 45. Señal entrante con su resultante en FFT y PSD (S12).....	63
Figura 46. Diagrama de flujo del proceso de correlación y convolución.....	65
Figura 47. Señales organizadas y normalizadas para la convolución. (S4, S3 y S9).....	66
Figura 48. Respuesta de cada electrodo F8 de cada individuo en el gesto de levantamiento de las dos cejas.....	67
Figura 49. Resultado de la convolución y correlación.....	68
Figura 50. Electrodos normalizados y divididos en sus diferentes gestos faciales (S8).....	70
Figura 51. Validación cruzada con cada núcleo.....	71
Figura 52. Validación cruzada con menor red de búsqueda.....	72

Figura 53. Validación cruzada resultante de la eliminación de S4 y S5	74
Figura 54. Validación cruzada sin un gesto facial	75
Figura 55. Gráfico de porcentajes de clasificación	77
Figura 56. Electrodo normalizado y dividido en sus diferentes gestos faciales (S1)	88
Figura 57. Electrodo normalizado y dividido en sus diferentes gestos faciales (S2)	89
Figura 58. Electrodo normalizado y dividido en sus diferentes gestos faciales (S3)	90
Figura 59. Electrodo normalizado y dividido en sus diferentes gestos faciales (S4)	91
Figura 60. Electrodo normalizado y dividido en sus diferentes gestos faciales (S5)	92
Figura 61. Electrodo normalizado y dividido en sus diferentes gestos faciales (S6)	93
Figura 62. Electrodo normalizado y dividido en sus diferentes gestos faciales (S7)	94
Figura 63. Electrodo normalizado y dividido en sus diferentes gestos faciales (S9)	95
Figura 64. Validación cruzada con datos resultados de FFT	96
Figura 65. Validación cruzada con datos resultantes de PSD	97

Lista de tablas

Pág.

Tabla 1. Electrodoos que más se manifiestan en las pruebas realizadas, con su porcentaje de detección. (Hombres) 62

Tabla 2. Electrodoos que más se manifiestan en las pruebas realizadas, con su porcentaje de detección. (Mujeres)..... 62

Tabla 3. Correlación de cada electrodo en su respectivo gesto facial..... 68

Tabla 4. Correlación total de cada electrodo y el número de veces manifestado con respecto a cada gesto fácil y ocular 69

Tabla 5. Porcentaje de clasificación de cada sujeto 73

Tabla 6. Porcentaje de clasificación de cada sujeto 74

Tabla 7. Porcentaje de clasificación de cada gesto facial 74

Tabla 8. Porcentaje de clasificación tomando con los C y gamma de la Figura49 (1) y Figura 50 (2) 76

Lista de ecuaciones

	Pág.
Ecuación 1	35
Ecuación 2	37
Ecuación 3	38
Ecuación 4	38
Ecuación 5	38
Ecuación 6	38
Ecuación 7	40

Glosario

ELECTROENCEFALOGRAMA (EEG): El Electroencefalograma es un método de medición y monitoreo que graba la actividad cerebral, mediante electrodos conectados al cuero cabelludo, el cual, dependiendo del sistema hace ciertos filtros y amplificaciones para obtener una salida constante en mili voltios.

ELECTRODO: Es un tipo de conductor eléctrico que tiene contacto con un medio, dependiendo de su uso lleva o recibe una corriente eléctrica.

PERIODOGRAMA: Herramienta grafica para la examinación de características de señales en términos de frecuencia, también es usada para características de filtros y funciones de ventana.

TOMOGRAFIA: Técnica radiográfica que permite diagnosticar una sección de un plano de un órgano mediante imágenes por secciones.

ELECTROMIOGRAFIA (EMG): Es una técnica que diagnostica el estado de salud en los músculos, y los nervios que los controlan, representando sus resultados en registros gráficos para la observación de la actividad eléctrica producida.

ESPECTROGRAMA: Es una representación gráfica que determina las características de frecuencias de una señal en particular, normalmente usado para frecuencia altas que están en los límites del oído humano.

BCI (INTERFAZ CEREBRO COMPUTADOR): La Interfaz Cerebro Computador es una composición entre señales cerebrales y dispositivos de alta tecnología, que permiten realizar alguna acción o actividad a partir de resultados cerebrales, esta interfaz tiene diferentes resultados dependiendo de su estructura y composición.

FRECUENCIA: Describe la cantidad de ondas que aparecen en un periodo de tiempo o espacio determinado, su unidad internacional de medición es Hertz (Hz), nombrada así a honor al físico alemán Rudolf Hertz.

AMPLITUD: Análisis de una señal en un único periodo, normalmente ubicado en el plano vertical de una señal, identifica los cambios de oscilaciones eléctricas que esta posee.

GIROSCOPIO: Dispositivo usado para la medición y navegación de la velocidad angular, indicando las alteraciones que esta tiene en el eje a que esta corresponde.

Resumen

Este documento tiene como fin describir el desarrollo implementado para la caracterización de gestos faciales y oculares mediante el uso del método de electroencefalograma, usando una diadema Emotiv EPOC+. Esta caracterización fue desarrollada a través de grabaciones de datos brutos (EEG) con distintos sujetos variantes en edad y sexo, analizando cada dato obtenido mediante procesos estadísticos y procesamiento de señales digitales, comprobando sus diferentes respuestas mediante una clasificación por máquinas de soporte vectorial, con el fin de evaluar si la diadema podría ser una opción de uso y aplicación en personas con discapacidades motoras en sus extremidades.

1 Introducción

Se han realizado avances tecnológicos para el entendimiento de las áreas del cuerpo humano, sea para medicina [1], entretenimiento y educación [2]. Un área del cuerpo en la cual se ha hecho un gran avance tecnológico en la última década ha sido el encéfalo, en donde la mayor atención que se ha mostrado en esa área ha sido para ayudar a las personas con algún tipo de parálisis o discapacidad física, o incluso para uso de las grandes industrias de videojuegos [3].

Hoy en día existe un gran avance en el reconocimiento de ondas cerebrales, actividad eléctrica cerebral [4], detección de emociones [5] y gestos faciales [6], todo esto mediante PET (por las siglas en inglés de Positron Emission Tomography) [7], FMRI (por las siglas en inglés de Functional Magnetic Resonance Imaging) [7], EEG (Electroencefalograma) [8], entre otras técnicas de detección [9]. Estos tipos de detecciones solamente han hecho análisis científicos y experimentales, las aplicaciones realizadas hasta la actualidad han sido verdaderamente pocas comparado con la capacidad que estas mediciones pueden brindar al mundo de la tecnología.

Para poder caracterizar diferentes gestos faciales y oculares, se realizaron diferentes mediciones de señales con el método EEG, con la ayuda de distintos tipos de personas, con diferencias en edad, sexo y ámbito social. Con estos datos, se realizó un procesamiento de señal para obtener datos más puros y exactos. De igual manera, se realizó este procesamiento para la obtención de diferentes características de las señales, tales como sus resultados base en amplitud, frecuencia y potencia; para la verificación de las mejores características, se usaron diversos métodos estadísticos (convolución, correlación, diagramas de cajas), haciendo su comprobación mediante un clasificador de máquinas de soporte vectorial, observando y analizando diferentes porcentajes de clasificación para las características halladas.

2 Problema de investigación

2.1 Planteamiento del problema

Se han realizado diversos avances tecnológicos en las últimas décadas, ya sea avances de los computadores, tecnología móvil, hardware, software e incluso en diferentes mediciones medicas de diferentes partes del cuerpo[10], que pueden ser utilizados para el beneficio de las personas que más limitaciones tienen en su actividad diurna [11]. Los métodos de mediciones mediante electroencefalograma han tenido cambios drásticos en toda su historia, ya que con unos pequeños dispositivos se pueden hacer mediciones exitosas a comparación con máquinas previamente inventadas, que eran más costosas y grandes [12]; lastimosamente, este tipo de tecnologías no han sido aplicadas a su máxima capacidad, ya que no tiene un atractivo comercial como lo tiene otras tendencias tecnológicas mencionadas, además de ser un análisis de una de las partes más desconocidas del cuerpo humano. En este documento se usará la tecnología moderna del electroencefalograma para demostrar que este tipo de método pueden servir para diversas aplicaciones médicas y sociales.

2.2 Objetivos

2.2.1 Objetivo General

Caracterizar diferentes gestos faciales y oculares (levantamiento de cejas, masticar, mirar a la izquierda, mirar a la derecha, parpadear, cerrar los ojos) con la adquisición de señales EEG, haciendo su comprobación mediante un clasificador de máquinas de soporte vectorial.

2.2.2 Objetivos específicos

- Realizar una base de datos de señales EEG sobre 13 sujetos de prueba con diferentes rasgos físicos y psicológicos.
- Resaltar las diferentes características de las señales grabadas (amplitud, frecuencia, potencia, tiempo) y explorar su similitud mediante diagrama de cajas, convolución y correlación.
- Comprobar las características obtenidas mediante máquinas de soporte vectorial.

2.3 Justificación

El trabajo de grado fue propuesto para determinar si el uso de señales EEG permitirían la caracterización de diferentes gestos fáciles y oculares: levantamiento de las cejas, masticar, observar a la derecha, observar a la izquierda, cerrar ambos ojos y parpadeo; para evaluar una futura aplicación en personas con un estado de discapacidad motora en sus extremidades. Se han realizado diferentes tipos de aplicaciones con esta misma técnica; para mover objetos [6], mover un personaje de un videojuego [8] o incluso manejar una silla de ruedas [13]. Aun así, en las investigaciones realizadas no se han abordado algunos gestos faciales que pueden servir para una clasificación más amplia.

3 Marco de referencia

3.1 Antecedentes del problema

A continuación, se dará a conocer los trabajos realizados con EEG, enfocando en aquellos que tratan de la obtención y caracterización de diferentes movimientos musculares y mentales a partir de diademas de diferentes fabricantes, tales como Emotiv EPOC+, Emotiv Insight y Neurosky, junto con sus métodos, metodologías y técnicas utilizadas.

3.1.1 Control de movimiento robótico con detección cognitiva y facial mediante Emotiv EEG

Se pueden lograr diversas aplicaciones con diademas de electroencefalograma, como se puede evidenciar en el artículo titulado “Control de movimiento robótico con detección cognitiva y facial mediante Emotiv EEG” [6]; este artículo se centra en la creación de una interfaz cerebro-computador (por las siglas en inglés de BCI) usando la diadema Emotiv EPOC+, obteniendo diferentes gestos faciales y comprobando cada acción mediante el movimiento en un robot.

El procedimiento descrito en el artículo para obtener los resultados deseados fue mediante entrenamiento de datos de diferentes gestos fáciles y movimiento musculares que los autores seleccionaron, tomaron sujetos de edades similares y diferentes sexos para el componente cognitivo y de adquisición de datos. Concluyeron que para los gestos fáciles no era necesario ningún entrenamiento, ya que estos tipos de movimientos son genéricos. Para cada acción que fueron adquiriendo hicieron un promedio y analizaron en cuál electrodo de la diadema se podía observar un cambio notorio, midiendo las salidas brutas de dicho instrumento.



Figura 1. Arquitectura del sistema. [6]

En la arquitectura del sistema mostrada en la Figura 1, se mencionó anteriormente la implementación de un BCI, la arquitectura manejada fue mediante lenguaje C# y para la interfaz de programación de aplicaciones (API) se manejó Aforge.NET. Detallaron en Hardware que era necesario un computador con conexión Bluetooth para la comunicación serial con el robot de prueba, en el caso de la diadema, esta tiene su propio conector Bluetooth genérico que se conecta mediante USB.

Para el movimiento del robot implementaron una arquitectura por eventos, explican que el robot no funciona con el API, sino con una clase exclusiva del mismo llamada NXTBrick, el cual crea una instancia para llamar las funciones y poder hacer los movimientos correspondientes del robot, esto es necesario para lograr una toma de datos y una respuesta en el robot en tiempo real. Lo anterior se evidencia en la Figura 2.

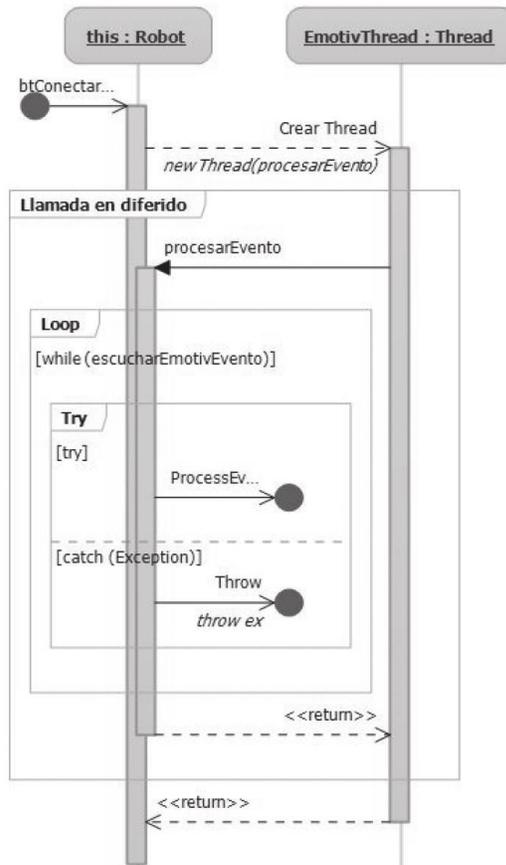


Figura 2. Instancias para el manejo del robot. [6]

Para la detección de las acciones escogidas se tiene que hacer un entrenamiento previo en cuanto al pensamiento. Se tomaron dos actos cognitivos, ya que tomando más de este valor el aprendizaje es más extenso, y para los gestos faciales (musculares) ya que son señales genéricas, no fue necesario hacer un tipo de entrenamiento. Tomaron a seis sujetos de edades similares tanto hombres como mujeres, sacaron el porcentaje de reconocimiento de cada individuo para observar qué tanta precisión tenían a su disposición para las pruebas finales con el robot. Se observó una gran diferencia entre los resultados cognitivos y los resultados faciales, teniendo un reconocimiento más alto en los gestos fáciles que en las acciones cognitivas, concluyendo que es más favorable el uso de acciones musculares que de pensamientos para las pruebas de movimiento con el robot.

En la prueba de movimiento del robot con las conclusiones halladas en la prueba de reconocimiento se tomaron cinco gestos faciales, los resultados de la prueba entre lo que se desea realizar y lo que en verdad se realiza esta en un margen de 70% promedio de concordancia, todo esto debido a los análisis hechos, algunos movimientos musculares son parecidos en la salida de algunos electrodos, haciendo

interferencia o confusión en el software realizado, y finalmente hay interferencias externas y diademas de tipo EGG son vulnerables ante cualquier movimiento.

3.1.2 Lower Body Segmental Dynamics Control Using Eye Blinking Activity

Hay otros trabajos centrados en pocos gestos faciales con otro tipo de diademas. En un artículo llamado “Lower Body Segmental Dynamics Control Using Eye Blinking Activity” [13], muestra la utilización de la diadema Neurosky (Figura 3) que está constituida de un electrodo que va posicionado en la frente de la persona, la misión de este trabajo es el movimiento de una silla de ruedas de acuerdo a la intensidad de parpadeo de una persona.



Figura 3. Diadema Neurosky. [13]

Se explica detalladamente que los autores seleccionaron específicamente el parpadeo ya que la diadema tiene la capacidad de brindar tres señales específicas, una de estas naturalmente es el parpadeo. Para la sección de Hardware solamente fue necesaria la diadema con un computador que tenga conexión Bluetooth y para la sección de Software se especificó que usaron dos programas, SolidWorks para hacer diseños en 3D Y LabVIEW para el control e instrumentación de aplicaciones de diseño, los cuales son compatibles, por lo tanto, se realizó la simulación y comprobación de los datos de entrada de la diadema mediante estos dos softwares.



Figura 4. Interfaz gráfica. [13]

Ya que el objetivo de los autores era de hacer esta medición y ver sus resultados en tiempo real, se realizó una interfaz de maquina humana, se hizo la interfaz gráfica mediante LabVIEW como se puede observar en la Figura 4, teniendo en cuenta las siguientes condiciones, inicialmente se tiene que seleccionar el puerto, al cual, el computador y la diadema están conectados como esclavo/maestro para la recepción de datos, seguido de esto se puede iniciar la interfaz oprimiendo el botón START, cuando se realiza esta acción tanto el Software como el Hardware están trabajando en un ciclo en conjunto, este seguirá trabajando mientras la conexión entre el programa y la diadema sean estables.

Usando los componentes de simulación y los datos entrantes de la diadema Neurosky, se puede observar que hay un cambio positivo dependiendo de la intensidad de parpadeo (Figura 5), los ángulos de los motores simulados pueden ser variantes dependiendo del ángulo que la persona se encuentre, los autores explican que estos resultados pueden ser llevados a aplicaciones para personas que verdaderamente lo necesitan, específicamente gente que tenga parálisis muscular en la mayor parte de su cuerpo.

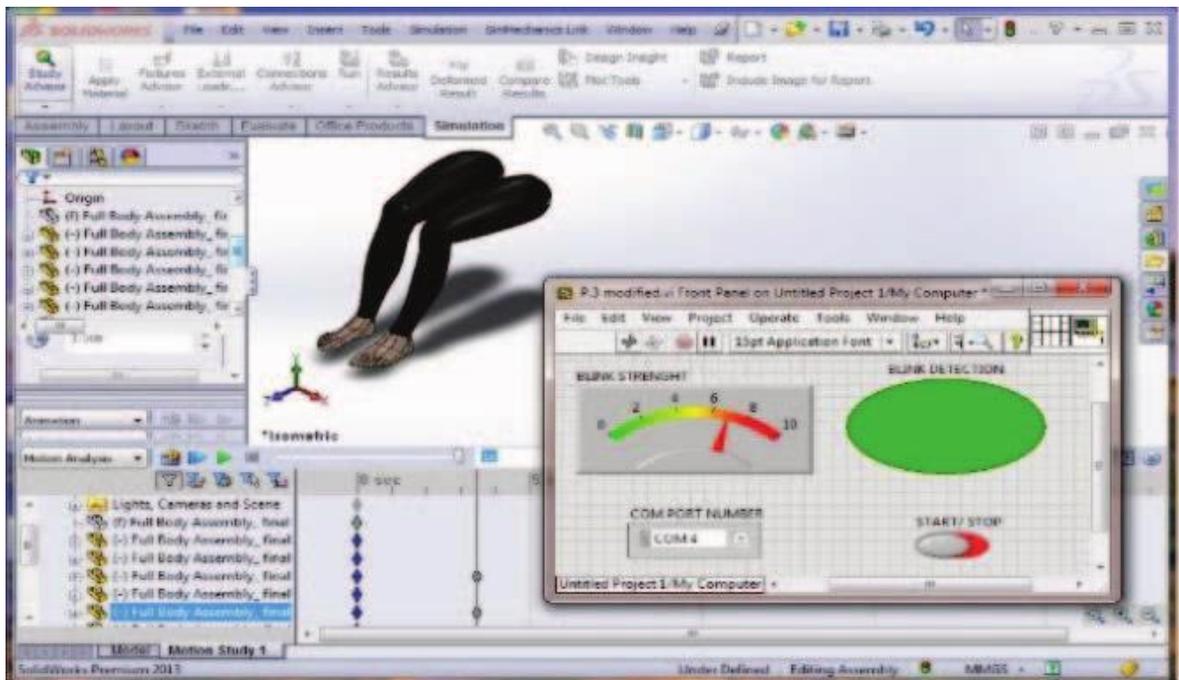


Figura 5. Resultado de la investigación. [13]

3.1.3 Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas [14]

Esta investigación se enfoca en la creación de una interfaz cerebro-computador con una diadema EPOC, determina que se centra en dos estímulos de visualización, derecha e izquierda, y que el individuo a ser evaluado debe de imaginar la acción visualizada en una pantalla por un tiempo limitado; observado en la Figura 6.

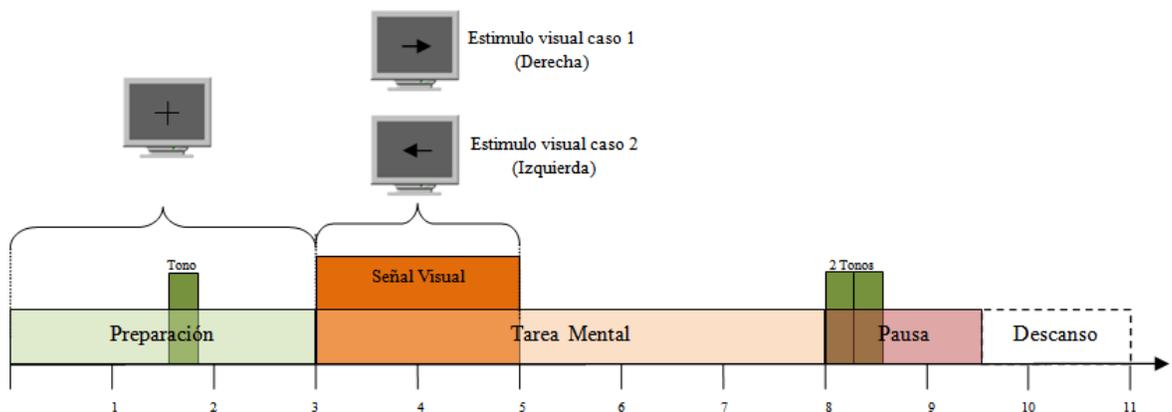


Figura 6. Pasos de toma de datos [14]

En esta investigación en particular, se usó una eliminación de DC justificado en el documento porque “el headset agrega un DC sobre los 4096 μV con el fin de garantizar que todos los datos sean un entero positivo”[14], junto métodos como ventana Hanning, filtro pasa banda y filtros espaciales para la disminución de datos basura, disminución de ruido por variación de posicionamiento del instrumento usado y eliminación de frecuencias bajas que son inútiles en la clasificación correspondiente.

Finalmente, para la clasificación correspondiente con la misión del documento se hizo mediante métodos de espectro de densidad de potencia (PSD) junto con máquinas de soporte vectorial (SVM) en electrodos que resaltaban mayores cambios en las tareas evaluadas, en este caso en particular fueron AF3 y AF4. Esto se evidencia en la Figura 7.

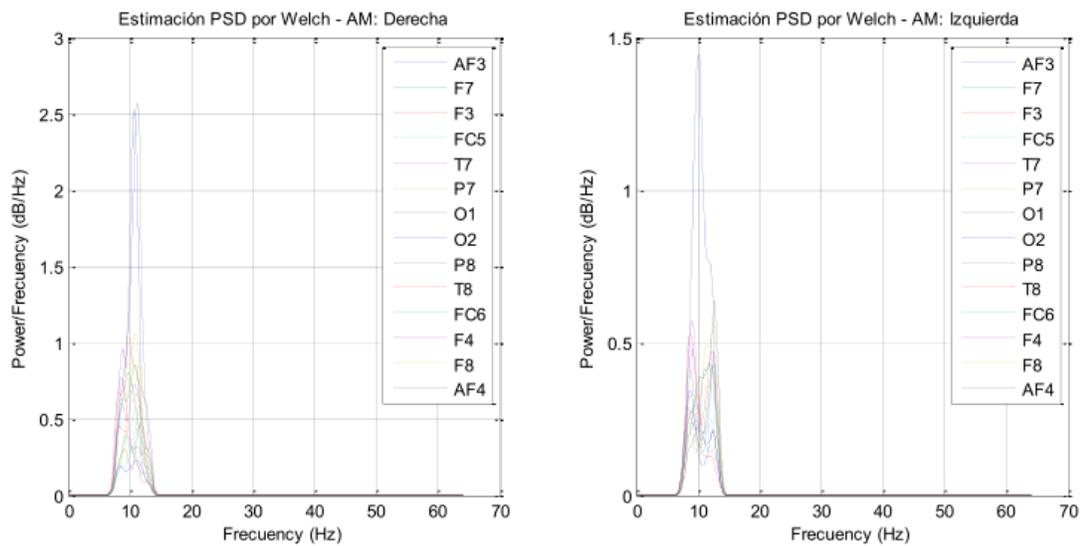


Figura 7. PSD estimado de cada electrodo usado [14]

Usando este tipo de métodos se obtuvo un porcentaje de precisión máximo a 87.84%, haciendo este tipo de método deseable para la caracterización propuesta en esta investigación. La autora igualmente hizo la clasificación usando la transformada de Hilbert y método PLV y se observó en el kernel lineal del documento que se obtuvo un porcentaje de precisión máximo a 95.01%, esto es debido a que el método PLV en comparación con el PSD maneja todas las sesiones de datos como datos individuales, al contrario del PSD que los maneja como los datos de los 14 electrodos usados en este documento de investigación.

3.1.4 Classification of EEG Signals in a Brain-Computer Interface System

[8]

Esta investigación realizada por Erik Andreas Larsen publicada en junio del 2011, muestra otros modos para hacer las clasificaciones de las señales EEG salientes de la diadema Neurosky. A comparación con el otro proyecto explicado con esta diadema, esta se centra en la clasificación de señales mediante el uso de redes neuronales, demostrando su resultado mandando instrucciones a un juego simple, como Snake.

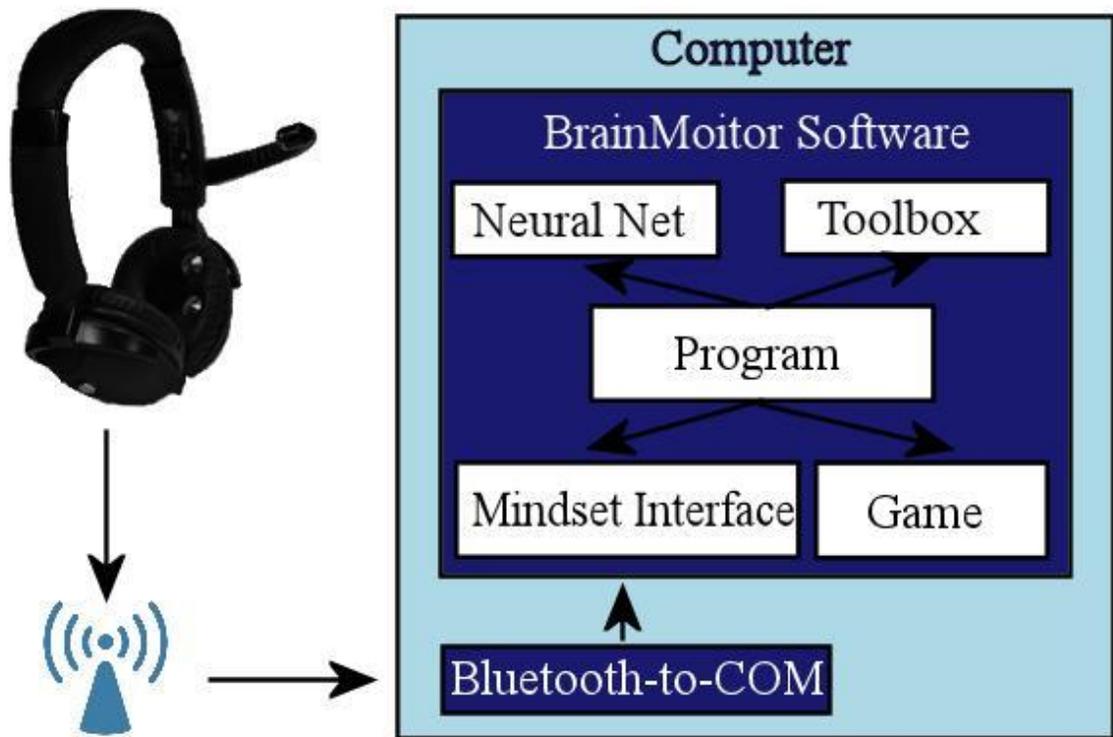


Figura 8. Principales componentes del sistema diseñado [8]

Mostrado en la Figura 8 se muestra como es la arquitectura principal de este proyecto, explica que todo el proyecto fue hecho a través de Visual Studio 2010, programando todo en lenguaje C#, en la imagen también se puede observar que tienen los mismos parámetros de conexión que el proyecto que uso este mismo tipo de diadema (Bluetooth a COM), debido a que este tipo de conexiones son más fáciles de usar para la comunicación con el dispositivo y la creación de una aplicación. Explican que se centran en cuatro procesos en específico: Señal de entrada, Procesamiento de la señal EEG, Clasificación de la señal EEG y Interacción con el computador.

Para obtener los mejores resultados posibles, especificaron los métodos que usaron, en este tipo de señales la utilización de FFT es fundamental para poder obtener una mejor comparación en la base de datos, de igual forma, estos tipos de datos deben ser un número total a un valor obtenido por el poder a la dos (8,16,32,64...), ya que en esta implementación si se usa un valor diferente no se puede realizar un análisis preciso. Realizaron la medición de las señales EEG mediante un programa llamado BrainMonitor, en donde también se puede observar de forma gráfica que acción en específico tiene mayor diferencia con respecto a las demás, el programa se puede observar en la Figura 9.

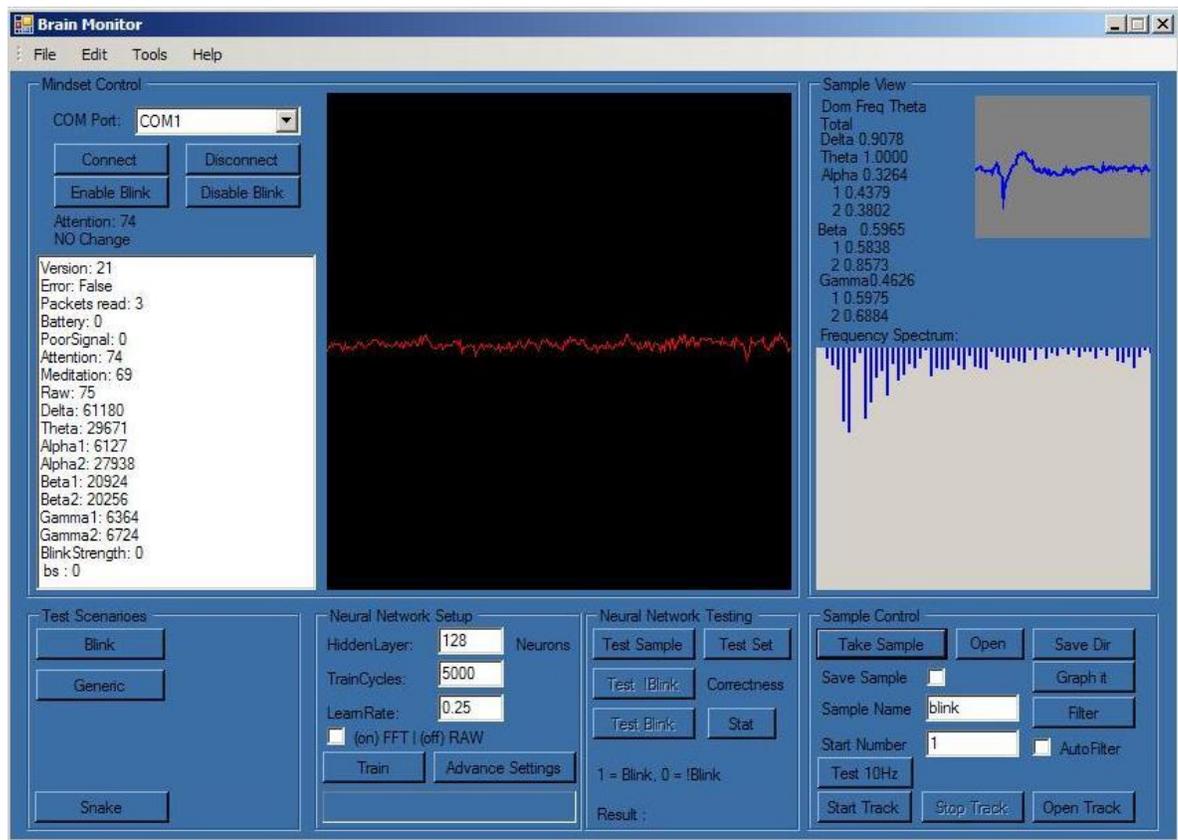


Figura 9. Interfaz gráfica BrainMonitor [8]

La red neuronal implementada fue mediante una solución hallada en NeuronDotNet, esta red neuronal se usó junto con una configuración en la interfaz gráfica la cual permite una configuración de sus parámetros, como lo son los ciclos de entrenamiento, número de nodos, la velocidad de entrenamiento, el tipo de activación y la cantidad de nodos ocultos. Finalmente, el juego utilizado para la prueba final fue Snake, este tipo de juego se encuentra disponible en códigos abiertos XNA, y es uno de los juegos más relajantes que se encuentran disponible para Visual Studio.

Centrándose en diferentes pruebas con diferentes sujetos, se observó que el parpadeo siempre será una acción ocular importante por la diadema utilizada, tomando en cuenta que solo es un electrodo y siempre estará centrada en la frente del individuo, tomándola como la primera opción para la red neuronal, su única entrada puede ser si el sujeto de prueba parpadea o no, haciendo que su implementación sea más fácil para la verificación de las salidas de la red neuronal. Otra característica usada fue una llamada base, donde la persona no piensa en nada, teniendo los ojos abiertos; similar a los proyectos mencionados hasta el momento, se realizó un escenario en donde se especifica que movimiento hacer y en qué tiempo hacerlo, para la correcta obtención de las señales EEG.

La red neuronal en este proyecto se especificó con una tasa de aprendizaje de 0.25 y 5000 ciclos de aprendizaje, sus entradas fueron las señales cerebrales más usadas en este tipo de investigaciones: Delta, Theta, Alpha, Beta y Gamma. Cada una simbolizando un rango de frecuencias en específico, obtenidas mediante el resultado del algoritmo FFT de las señales EEG de la base de datos, sus valores de entrada fueron escalados con respecto a la frecuencia más alta en cada sujeto, en otras palabras, fue normalizada para que todos los valores tengan un rango de 0 a 1. La arquitectura de la red neuronal es observada en la Figura 10, especificando la utilización de tres nodos ocultos y un parámetro de salida, en este caso en particular fueron dos parámetros, cero para todos los resultados base, y uno para todos los resultados de parpadeo, el entrenamiento fue realizado mediante un set de cada dato, cinco señales individuales del parpadeo y de la prueba base.

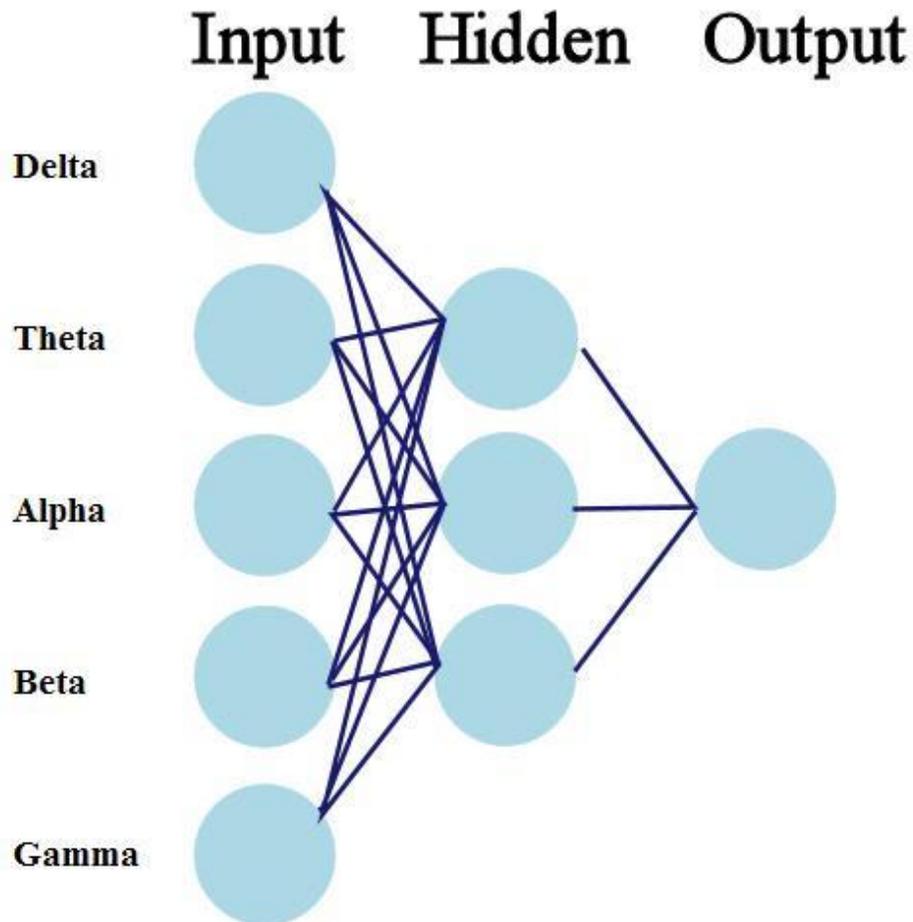


Figura 10. Arquitectura de la red neuronal [8]

Los resultados de la red neuronal fueron exitosos, con una tasa de clasificación para parpadeo de 99% y de base de 89%, se observó que en muchas pruebas se tenía un ruido por la sensibilidad del electrodo a los movimientos del sujeto excluyendo del principal, como mover las manos, la cabeza o incluso el ruido ambiental, esto hace que las pruebas base sean más difíciles de reconocer que las de parpadeo. Debido a esto se debió observar en los datos de frecuencias que características fundamentales cada una de ellas tienen; igualmente, para contrarrestar estos déficits, solamente se especifica al sujeto que no haga ningún movimiento además de los especificados en la toma de datos, para la prueba final este mismo proceso debe ser realizado.

Con los datos obtenidos en todo el procedimiento se realizó la prueba final con el juego Snake, este juego inicia con un cuadro que debe ser controlado, aumentando su tamaño cada vez que se come una manzana, la serpiente del juego se puede mover en tres direcciones: arriba, izquierda y derecha, y se

pierde el juego cuando la serpiente se toca a sí misma. Para controlar correctamente esta serpiente se especificó que esta tuviera un movimiento automático hacia adelante, y su cambio para la izquierda o derecha dependiera de los datos entrantes del EEG, el sistema final es observado en la Figura 11.

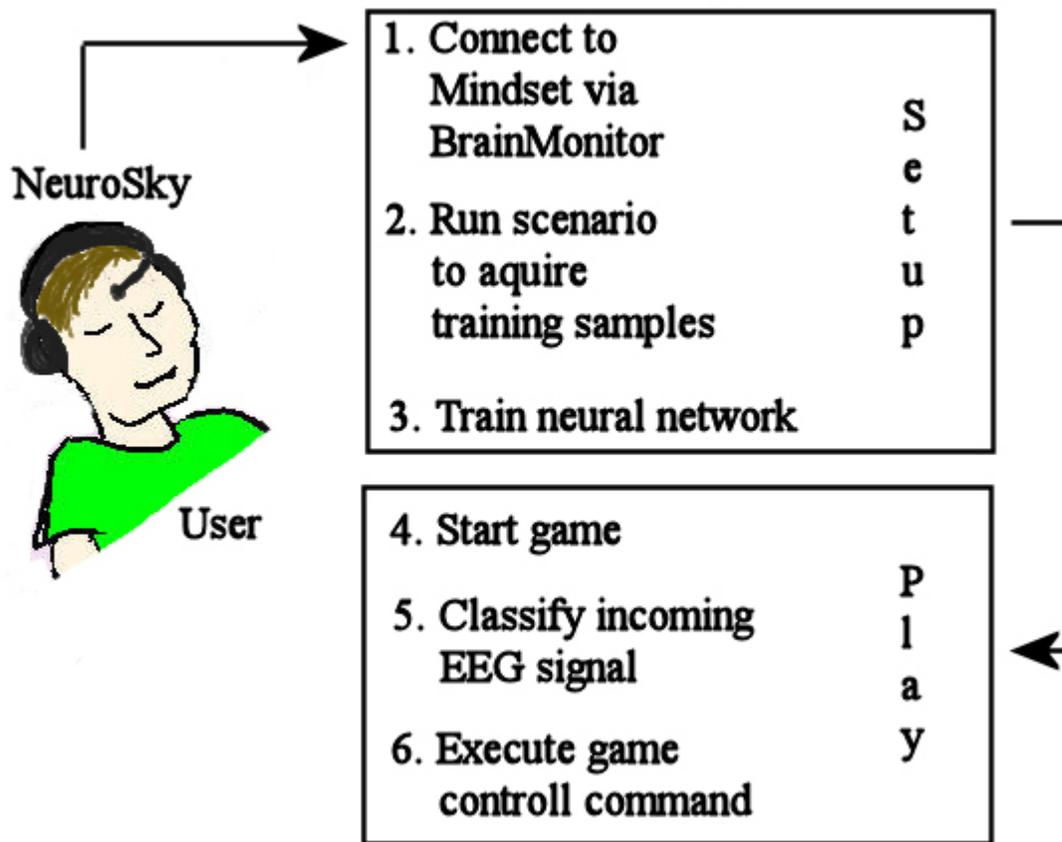


Figura 11. Sistema final de prueba [8]

Lastimosamente ya que se utiliza un estado mental (base), el juego debe ser pausado cada 20 segundos después de realizar la acción, por lo que, a comparación de un gesto ocular, un estado mental debe ser analizado con muchos datos, haciendo que su resultado para la acción en el juego sea demorado; el sistema entonces fue diseñado que para cuando haya un cambio notorio en las señales EEG, este pause automáticamente y haga el proceso de clasificación.

Cada prueba final del juego fue necesaria para el entrenamiento de la red neuronal, con cada prueba realizada la tasa de éxito en la clasificación fue aumentando hasta un 90%, se debe de tomar en cuenta que los sujetos de prueba ya tenían más experiencia en el modo de medición de esta diadema, si el sujeto fuera una persona diferente, esta no tendría una tasa de clasificación alta ya que se debe de tener una alta concentración, si esta no se tiene la clasificación puede bajar de un 30% a 40%. El autor

denota que el juego utilizado fue uno de los más relajantes para este tipo de actividad y que para futuros proyectos se debe de mejorar el método de clasificación para una mejor respuesta en tiempo real.

3.1.5 Emotiv EPOC BCI with Python on a Raspberry pi

Esta investigación muestra otra utilidad de la diadema Emotiv EPOC con Python a través de Raspberry Pi [15], en comparación con todos los proyectos anteriormente mencionados, ellos no se basan solamente en señales EEG, toman en cuenta otras salidas de la diadema tales como EMG y giroscopio para su extracción de características, que serán utilizadas en el BCI diseñado. Este proyecto tiene dos procesos, uno de procesamiento fuera de línea para la clasificación de las entradas de la diadema y un procesamiento en línea que tomara en cuenta los aspectos del proceso anterior para poder manipular un robot y mostrar de forma gráfica los resultados en una interfaz gráfica, el diagrama del proyecto puede ser observado en la Figura 12.

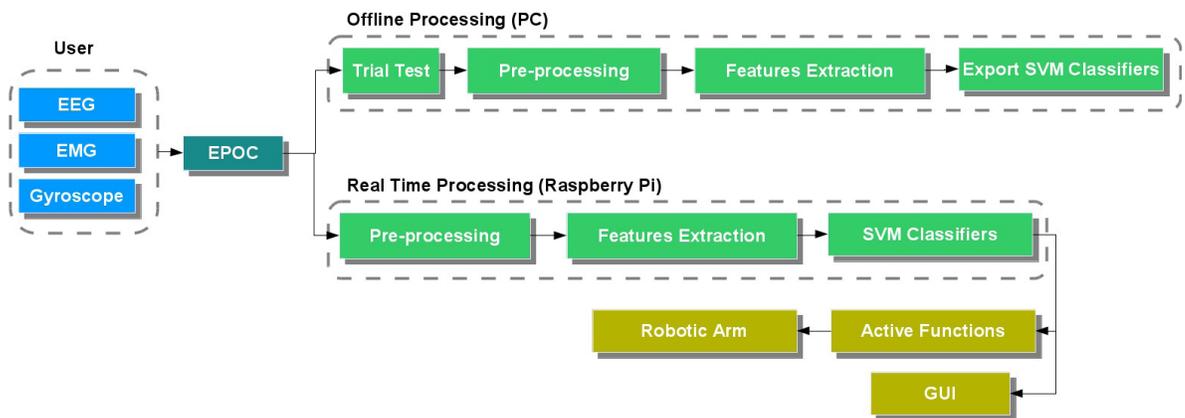


Figura 12. Diagrama del BCI [15]

Los autores comenzaron su análisis de señales con dos pruebas mentales: relajación y concentración, en donde los sujetos de prueba para el test de relajación cerraron los ojos para relajarse por un tiempo promedio de ocho segundos, mostrando un cambio significativo en la onda Alfa (8Hz a 12Hz) en el electrodo O2; en el test de concentración los participantes hicieron operaciones matemáticas durante dos minutos, observando que hubo un valor elevado en las ondas Beta (14Hz a 30Hz) y Gamma (31Hz a 45Hz) en el electrodo F8. Ya que el electrodo F8 será usado en el BCI, y su posicionamiento está cerca de la sección ocular del rostro humano, los autores realizaron la acción de parpadear con EMG y EEG, en donde el sujeto alterna el pestañeo en ambos lados del rostro cada dos segundos,

obteniendo una información confiable para no tener que hacer procesamiento de señales adicionales. Los resultados de estas pruebas pueden ser evidenciados en la Figura 13 a partir de un espectrograma.

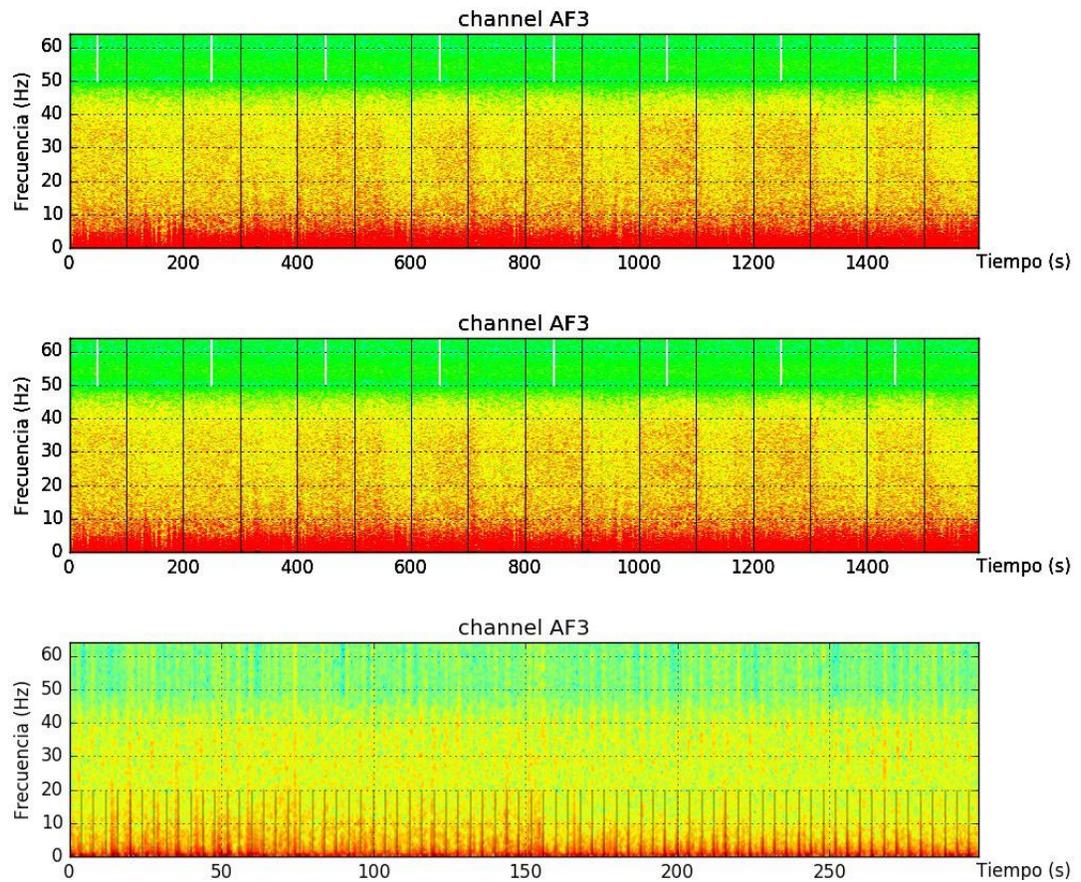


Figura 13. Espectrograma de todas las acciones [15]

Para el pre procesamiento en Python se usó la librería Numpy, esta librería proporciona las opciones necesarias que son requeridas para esta sección, las pruebas entrantes son transformadas de decimal a voltaje para luego ser entradas a un filtro Butterworth de quinto orden a 2Hz, este procedimiento es realizado para poder eliminar todo el ruido remanente que la diadema proporciona. Luego a esto se usaron las librerías de scikit-Learn para el procesamiento de señales, normalizando los datos y centrando los datos hacia la media y varianza unitaria.

Para la extracción de característica usaron funciones básicas basadas en la librería PyEEG, junto a el método de Welch para la densidad espectral de potencia, donde indica el radio de relación en frecuencia para Alfa. En el caso de las ondas Beta y Gamma se observó que se presentaron mayores dificultades para la detección por su baja magnitud a comparación de Alfa, los autores para poder utilizar estas ondas cerebrales utilizaron funciones con características lineales, cuasi-lineales y no

lineares tales como movilidad Hjorth, dimensión fractal Petrosiana y Hamadicharef. Finalmente, para el parpadeo se usó la norma de Frobenius y complejidad Hjorth, ya que esta acción es la más sencilla de caracterizar por ser una respuesta en voltaje y no en frecuencia.

Para la clasificación de las señales los autores usaron vectores de soporte de ScikitLearn, en donde esta librería usa funciones radiales de kernel y variables gama, junto a sistema de versus, que es conocida como clasificador binario donde certifica si la muestra está activa o no. Estos clasificadores fueron ajustados para dar la mejor respuesta posible, y definieron en su totalidad cuatro SVM para cada acción, donde determinan en resultados binarios (0 y 1) si pertenece o no a la clase activa o no activa de la acción.

Con estos procedimientos explicados, se realizó el procesamiento en tiempo real para observar su respuesta final, se usan ventanas para la restricción de tamaños, evitando así retrasos o latencias para poder obtener el mejor procesamiento de señales posible, se especifica que las tres acciones tienen procesamientos diferentes aunque la concentración y el pestañeo tengan la misma señal de entrada, su buffer de entrada se especificó a 64 muestra, para evitar la extracción constante de un mismo dato. Todo el diagrama de este proceso puede ser observado en la Figura 14.

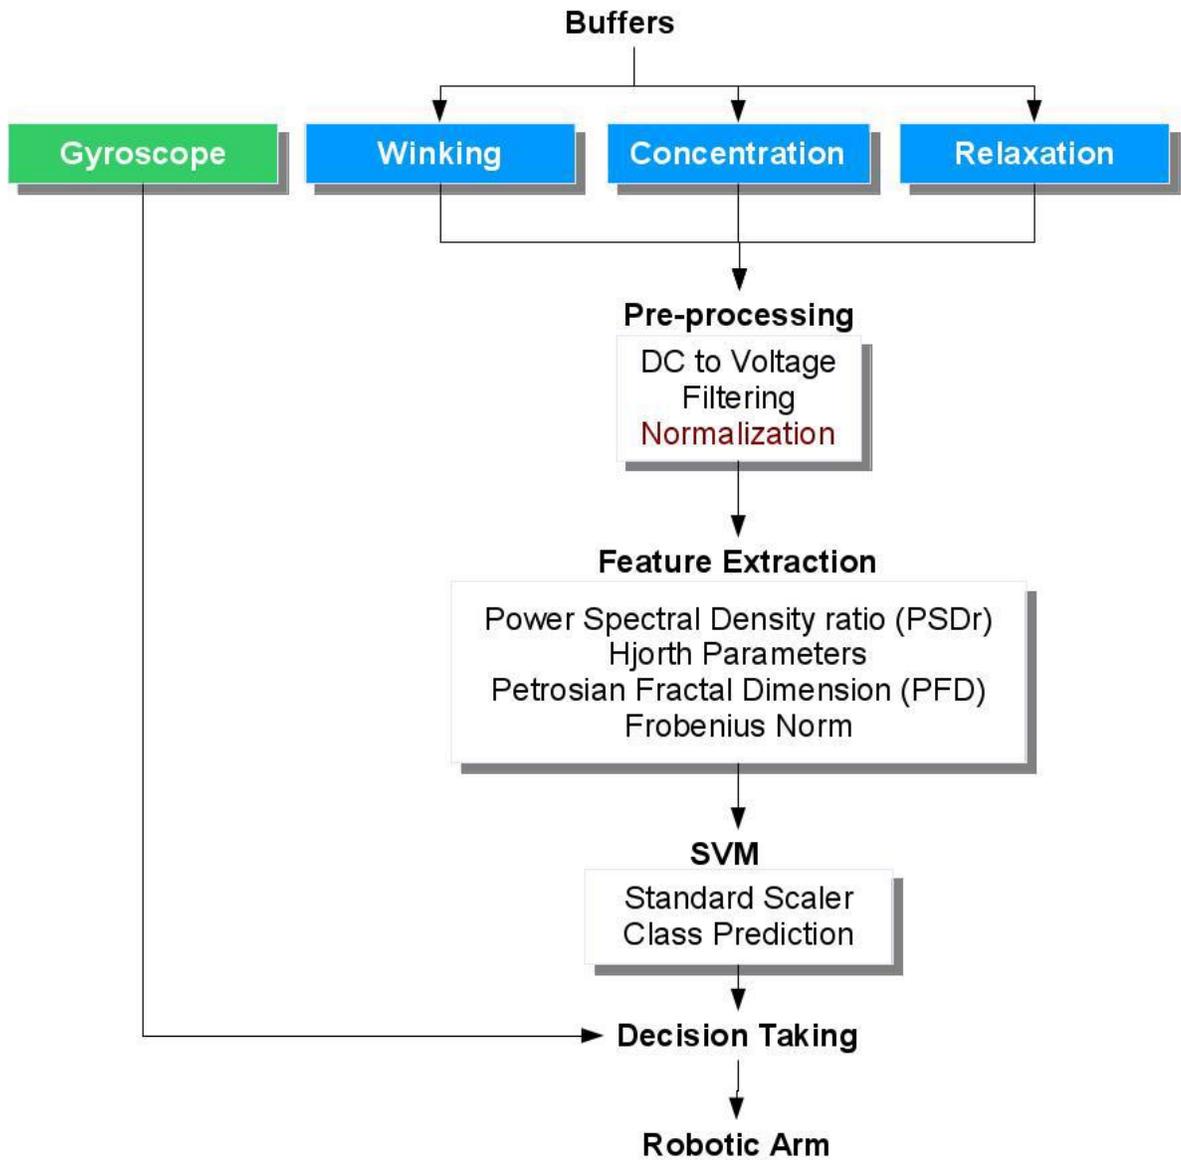


Figura 14. Diagrama principal de los procesos [15]

Observado en la Figura 14, posteriormente a los procedimientos descritos anteriormente, se continua en una toma de decisiones, que indicará el control de un brazo robótico dependiendo de su respuesta, esta respuesta es indicada si el resultado de la clasificación es 0 o 1, dependiendo igualmente de cuales acciones fueron realizadas. La conexión con el brazo robótico fue mediante la Raspberry Pi utilizando módulos XBee con conexiones seriales para la transmisión y recepción de los datos de la diadema EPOC, el brazo robótico actuó como un control maestro con protocolo serial Pololu a 9600 baudios.

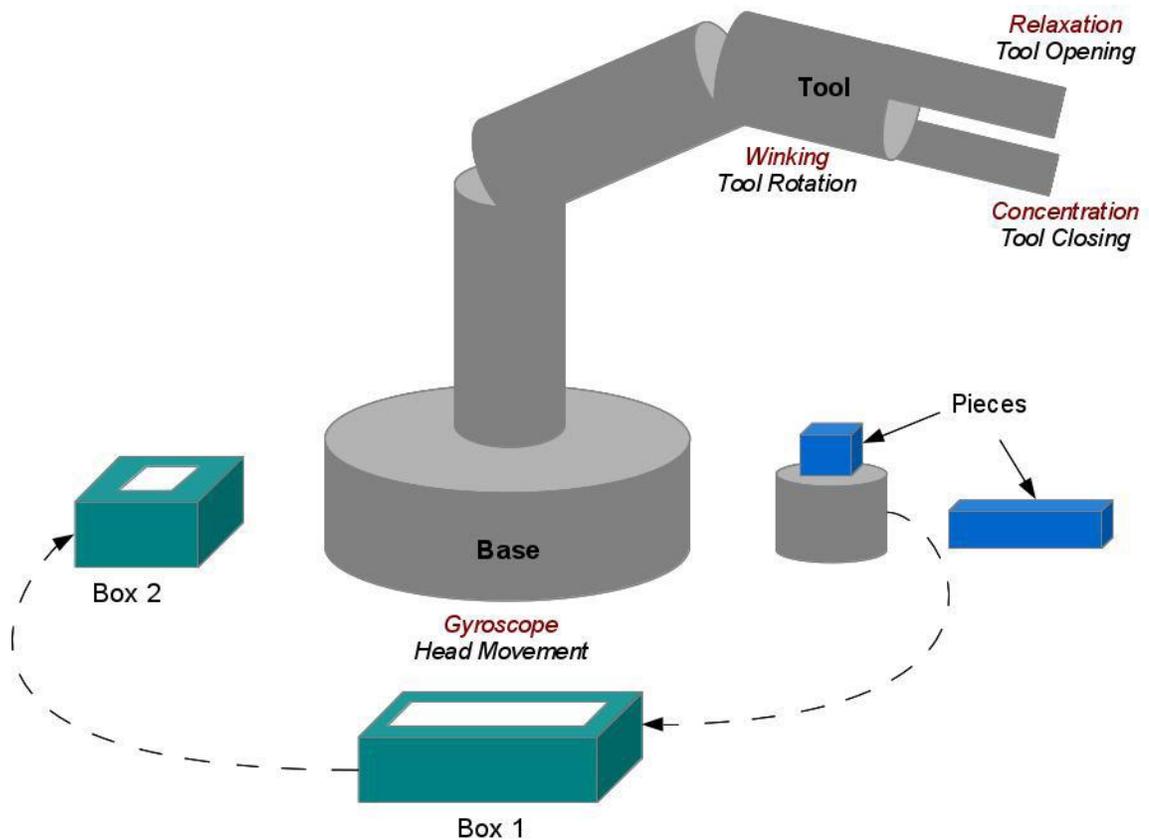


Figura 15. Brazo robótico utilizado con sus respectivos movimientos [15]

Observado en la Figura 15, el brazo tiene diferentes movimientos dependiendo de la respuesta que el usuario da desde la diadema, los resultados finales fueron exitosos ya que las acciones fueron simples de realizar, un test de prueba pudo mover dos piezas de forma correcta hacia las diferentes cajas descritas en la Figura 15. Finalmente, se realizó un ajuste para la utilización del giroscopio, dándole así más libertad en el movimiento de la cabeza al sujeto, así pudo mantener la vista concentrada en el brazo durante todo el transcurso de la prueba.

3.1.6 Controlling a Robot Using Brain Waves

Esta investigación muestra de forma sencilla la utilización de la diadema Neurosky para el movimiento de un robot mediante una interfaz cerebro computador [16], el diagrama principal de este proyecto puede ser observado en la Figura 16, en donde especifica paso a paso el procedimiento que se hizo para cumplir con el objetivo de este proyecto.

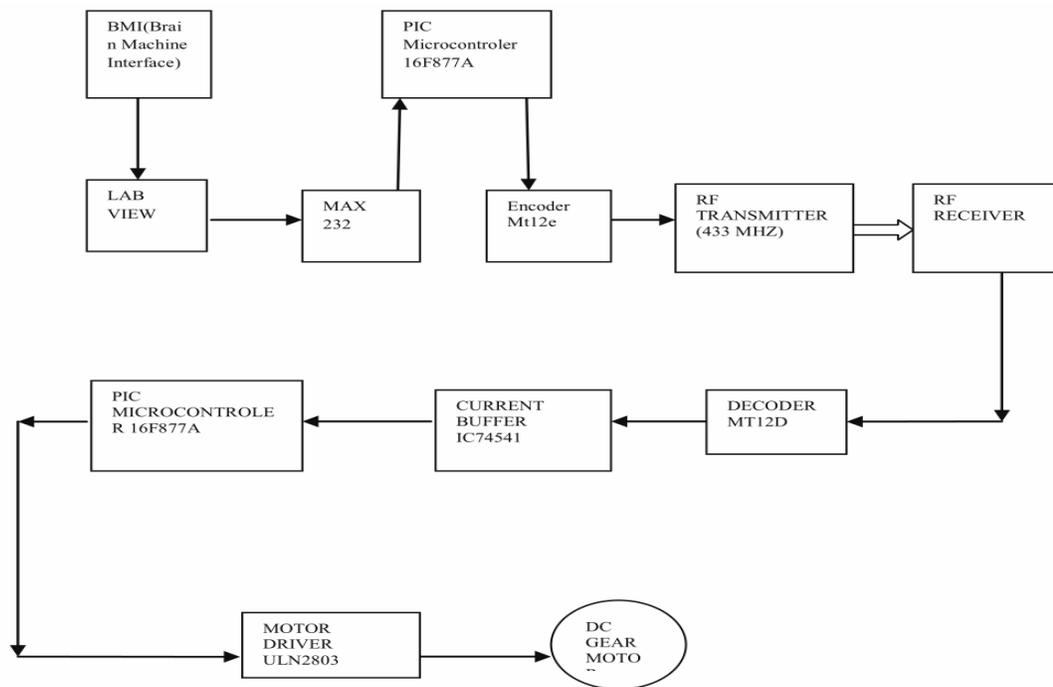


Figura 16. Arquitectura del proyecto [16]

El autor especifico el uso de la diadema Neurosky por su precio y uso sin agua salada o algún componente extra que se debe usar en los electrodos, como en el caso de la Emotiv EPOC. La diadema es la encargada de dar la información de diferentes señales, como lo son el pestañeo y nivel de atención para este proyecto, estas señales son procesadas mediante LabView para luego ser usadas en el movimiento del robot; estos datos entrantes del simulador son convertidos a datos seriales para ser transmitidos a componentes electrónicos, se convierte las variantes de -15 a +15 voltios AC a voltajes DC de rangos 0 a +5 voltios, estos valores específicos de voltaje son necesarios ya que los microcontroladores que harán el proceso de comunicación con el robot no soportan más de los rangos DC descritos, el proceso de conversión lo hace el componente IC MAX232.

El microcontrolador después envía las señales modulantes a un codificador MT12E, que codifica los datos a 4 bits, la transformación a señal digital de bits es necesaria para ser enviadas a un receptor RF, este receptor RF debe estar a una distancia lo suficientemente cercana para que reciba las señales sin ningún tipo de ruido o perdida. Este receptor RF envía los datos entrantes a un descifrador MT12D que codifica nuevamente los datos originales para que sean usados en los motores DC del robot usado, ya que las señales son de rangos de 0 a 5 voltios, se necesitó ampliar su amplitud para poder notar alguna diferencia en las acciones resultantes de los motores, por lo cual se usó un ULN

2803 que incremento el voltaje máximo un 60% (5 voltios a 12 voltios), lo necesario para que el motor funcionara de moda adecuada.



Figura 17. Circuito final del proyecto [16]

Finalmente, observado en la Figura 17 se nota el circuito impreso final del proyecto, en donde el autor especifica que las pruebas fueron exitosas, pero que en muchos casos por falta de procesamiento de señales los resultados no estaban dando lo que el sujeto de prueba estaba realizando, los trabajos futuros que este autor sugiere es una independización de controles manuales, para que este tipo de aplicaciones sea de gran uso para personas con alguna discapacidad motora.

3.2 Marco Conceptual

3.2.1 Técnicas de medición de la actividad cerebral

3.2.1.1 Electroencefalograma (EEG)

El EEG es un método de medición y monitoreo que graba la actividad cerebral, mediante electrodos conectados al cuero cabelludo, el cual, dependiendo del sistema, hace ciertos filtros y ampliaciones para obtener una salida constante en valores de voltios de acuerdo con el resultado obtenido del encéfalo. Este es un método popular para la medición de actividad cerebral ya que no es invasiva, y los implementos son más fáciles de transportar y de usar que las otras técnicas en particular.

3.2.1.2 Tomografía por emisión de positrones (TEP)

Este tipo de tomografía sirve para el análisis de la actividad cerebral en un punto específico del cerebro, en donde se determina mediante uso de una sustancia radioactiva inyectada que áreas del cerebro son las más activas.

3.2.1.3 Imagen por resonancia magnética (MRI/fMRI)

Es una técnica que permite la obtención de imágenes de la actividad del cerebro mientras se realiza una tarea en específico, todo esto a partir del uso de ondas de radio en un campo magnético en el que se posiciona la cabeza de la persona a evaluar, este es un método particularmente popular en la psicología y neurociencias.

3.2.2 Sistema Internacional 10-20

La colocación de los electrodos en el cabeza de un sujeto siempre tiene en cuenta el sistema internacional 10-20, y especifica que la distancia de cada electrodo debe ser del 10% al 20% en referencia craneana. En cada sujeto pueden ser diferente las dimensiones de su cráneo, pero las proporciones son constantes, lo que proporciona que este sistema unifique la colocación de los electrodos y la terminología internacional, por esta razón el Sistema Internacional 10-20 es el más utilizado en la actualidad. Su uso en la diadema propuesta en esta investigación se observa en la Figura 18.

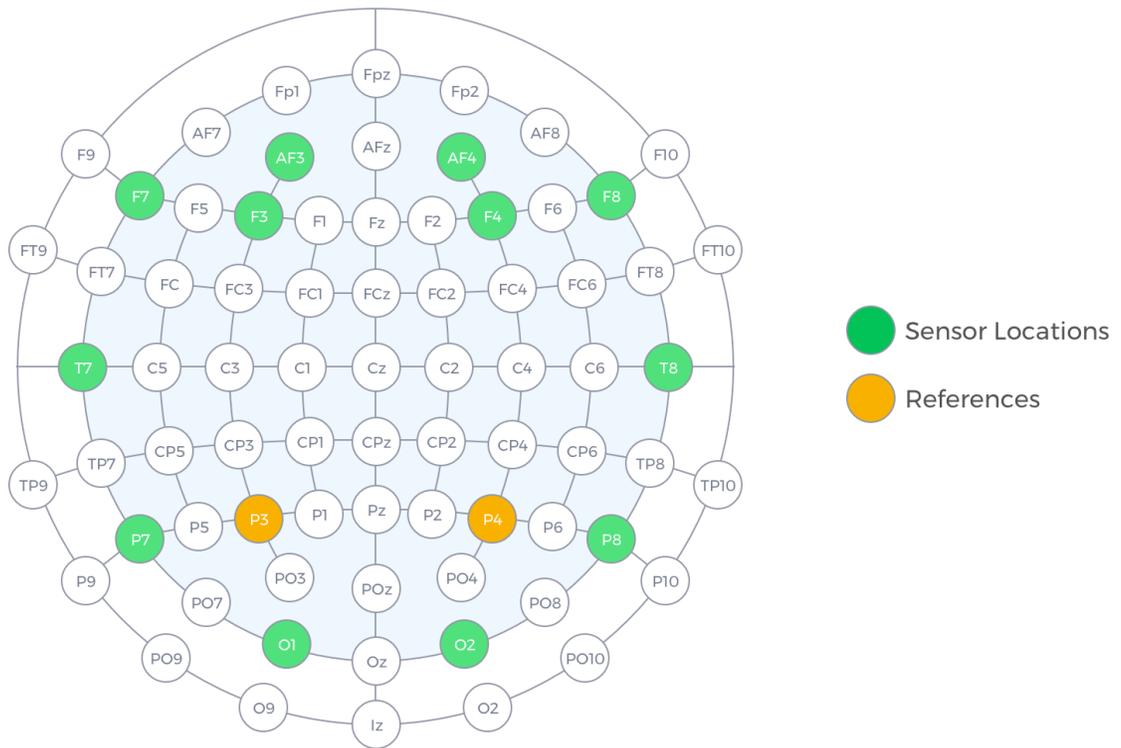


Figura 18. Electrodo de la diadema Emotiv EPOC+ con respecto al sistema internacional 10-20.[17]

Los nombres de cada electrodo dan a referencia a los lóbulos cerebrales (Figura 19) y la ubicación en el hemisferio cerebral, las letras son determinadas de la siguiente manera: F: Frontal, T: Temporal, O: Occipital, P: Parietal. Las demás letras y números dan ocupación a cada ubicación en el hemisferio, especificado a continuación: Z: Línea media, C: Línea horizontal, Número par: Electrodo en el hemisferio derecho, Número impar: Electrodo en el hemisferio izquierdo.

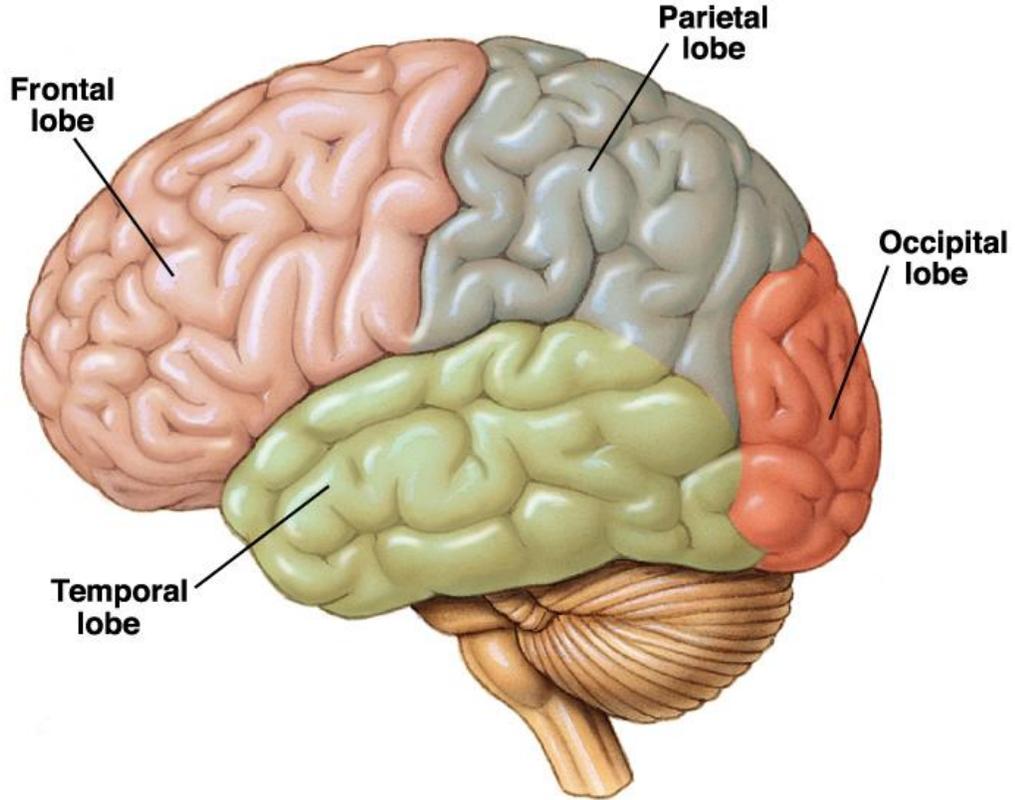


Figura 19. Vista lateral de hemisferio cerebral con visualización de la ubicación de cada lóbulo. [18]

3.2.3 Transformada rápida de Fourier (FFT)

Es un método matemático que permite la transformación de una función en términos del tiempo a una función en términos de la frecuencia, es un algoritmo del cálculo de la transformada discreta de Fourier (DST), el cual obtiene un cálculo más rápido y con mayor precisión en contra de cálculos repetitivos y errores que tiene el DST. Este método es usado para el tratamiento de señales o filtrado digital. Las fórmulas en las que se fundamenta este método (y las que utiliza MATLAB para su cálculo) son la siguientes:

$$X(k) = \sum_{j=1}^N x(j)w_N^{(j-1)(k-1)}, \quad x(j) = \frac{1}{N} \sum_{k=1}^N x(k)w_N^{-(j-1)(k-1)}$$

Ecuación 1

$$\text{donde } w_N = \exp\left(-\frac{2\pi i}{N}\right)$$

3.2.4 Funciones de ventana

En los cálculos relacionados con la utilización de la transformada FFT para la observación de los componentes de frecuencia de una señal, se están usando una cantidad finita de datos; normalmente la transformada FFT relaciona todos los datos entrantes como una señal periódica, dando su resultado exitoso si la señal entrante tiene esta característica particular. Si la señal usada para este análisis no es una señal periódica, los resultados dados por la FFT darán una versión distorsionada en términos de frecuencia, conocido como fuga espectral.

Para poder obtener datos reales de la transformada FFT y poder contrarrestar los efectos mencionados anteriormente, se realiza algo llamado funciones de ventana. Estas funciones reducen las amplitudes de los extremos de los datos entrantes, y se realiza mediante la multiplicación de esta ventana con los datos que se desea utilizar para su análisis en frecuencia, dando un resultado continuo y sin cambios drásticos.

Existen diferentes tipos de funciones de ventana, su selección puede ser fácil o difícil dependiendo de los datos que se desean evaluar; en este caso en particular, como la señal de los gestos fáciles se lleva a cabo una vez, y sus datos antes y después de la acción son próximos a cero, se selecciona la ventana de superficie plana (Flat Top).

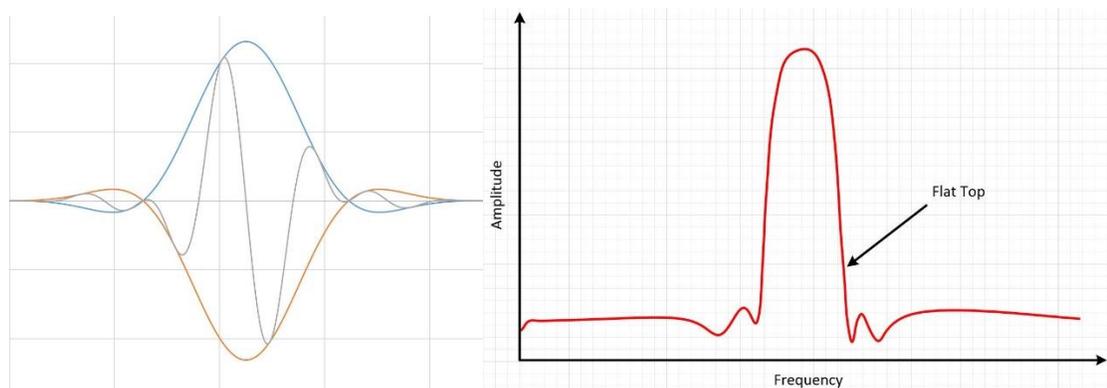


Figura 20. Ejemplo de ventana de superficie plana [19]

Esta ventana en particular, observada en la Figura 20 tiene un pico grande en el centro, dando una amplitud más valiosa que otro tipo de ventana, también tiene la ventaja de que, si se evalúa con las muestras tomadas de cada sujeto, los datos antes y después del centro tienden a cero, concluyendo que esta ventana es la más beneficiosa para este caso en particular.

3.2.5 Densidad espectral de potencia

La densidad espectral de potencia está dada por la transformada de Fourier y la auto correlación, esta muestra de forma gráfica cómo está constituida una señal en potencia, ya que esta depende de la transformada de Fourier. Los valores de potencia son mostrados equivalentemente al periodograma, en otras palabras, con respecto a las frecuencias que la señal está formada. Su fórmula característica está definida como:

$$\bar{W}_e = \frac{1}{T} \int_0^T x^2(t) dt = \frac{1}{T} \int_0^T \left(\sum_{-\infty}^{\infty} c_k e^{i\omega t} \right)^2 dt = \sum_{-\infty}^{\infty} |c_k|^2$$

Ecuación 2

3.2.6 Convolución

La convolución (Figura 21) es una operación que toma dos señales y las combina para obtener una tercera señal, este método es utilizado en estadística, teoría de la probabilidad, óptica, física e ingeniería, su uso es más común para análisis de señales en eléctrica y electrónica.

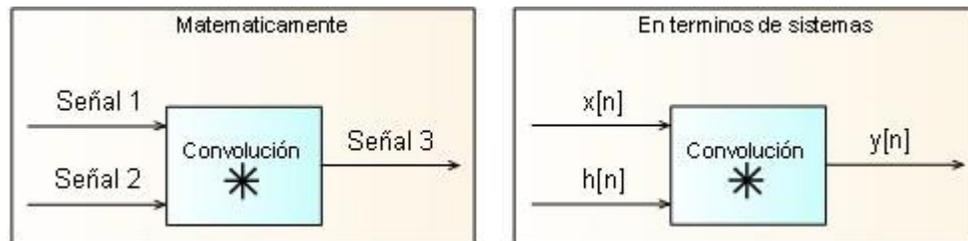


Figura 21. Explicación grafica de la convolución [20]

3.2.7 Correlación

Es una técnica estadística encargada de obtener la relación entre dos variables, esta relación se define mediante márgenes de -1 hasta 1, en donde los valores cercanos o iguales a 1 indican una relación positiva entre las variables, los valores cercanos o iguales a -1 indican una relación negativa, si el valor resultante se aleja de estos intervalos y se acerca a 0 simboliza que las dos variables no tienen relación alguna o que su relación es moderada/débil.

3.2.8 Máquinas de soporte vectorial (SVM)

Las máquinas de soporte vectorial es un método de aprendizaje estadístico para la clasificación lineal, pensado para resolver problemas binarios pero extendido mediante los años para múltiples problemas tales como agrupación o multclasificación, haciendo que sus usos se extendieran en diferentes campos de la ciencia e investigación.

Para hacer una clasificación usando SVM se deben separar los datos en datos de entrenamiento y datos de prueba, al contrario de otros métodos famosos para clasificaciones como redes neuronales, que su sistema puede usar los mismos datos de entrenamiento como datos de prueba. Cada instancia de datos en la sección de entrenamiento debe tener un objetivo general, o en términos generales una etiqueta (label), que expresa el valor a que se desea llegar, este valor puede ser binarios o números enteros, pero cada uno debe ser diferente del otro para una correcta clasificación. Las etiquetas deben tener atributos (features), que son datos que caracterizan a cada etiqueta, estos datos pueden ser datos fijos tales como peso, tamaño, distancia o datos grandes como señales digitales o grabaciones, cada dato debe tener un orden coherente con cada etiqueta.

Para esta investigación se usó una librería llamada LIBSVM, creada por Chih-Chung Chang y Chih-Jen Lin en el año 2003, una librería de código abierto frecuentemente actualizado para el aprendizaje mediante SVM, esta librería ofrece diferentes núcleos básicos para clasificaciones:

- Lineal:

$$K(x_i, x_j) = x_i^T x_j$$

Ecuación 3

- Polinomio:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$$

Ecuación 4

- Función de base radial (RBF):

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0$$

Ecuación 5

- Sigmoido:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$$

Ecuación 6

En donde, x_i es el vector de entrenamiento, x_j es el vector de etiquetas y γ , r y d son parámetros del núcleo.

El funcionamiento del SVM para cualquier núcleo se explica como : “Los vectores de entrenamiento serán mapeados en un espacio dimensional más alto (quizás infinito) por la función ϕ . SVM encuentra un hiperplano de separación lineal con el margen máximo en este espacio dimensional superior [21]”. Los usos de estos núcleos dependen de los datos que se tengan, dependiendo de las características de los datos, un núcleo puede servir más que los demás, pero el núcleo que más se ha caracterizado durante los años ha sido el RBF, este núcleo es el principal para una función del algoritmo llamada validación cruzada, y es el mejor para ser tomado como primera opción ya que este núcleo “mapea linealmente las muestras en un espacio dimensional más alto para que, a diferencia del núcleo lineal, pueda manejar el caso cuando la relación entre las etiquetas de clase y los atributos es no lineal. Este núcleo tiene menos dificultades numéricas [21]”.

Para obtener los mejores porcentajes de clasificación con este método se deben de escalar los datos de entrada en rangos entre -1 a 1 o 0 a 1, para así evitar que algunos atributos que tengan grandes valores numéricos dominen los que los tienen en pequeños rangos, así evitando a su vez dificultades en los cálculos. Igualmente, los autores de esta librería especifican que para obtener la mejor clasificación posible se deben de hacer dos métodos después del escalamiento: validación cruzada y rango de búsqueda.

El rango de búsqueda se utiliza para mejorar los resultados obtenidos por la validación cruzada; observado en la ecuación 5, el núcleo RBF tiene dos valores independientes C y gamma, estos valores son los que pueden mejorar o empeorar los resultados de clasificación, por lo cual se debe de identificar la mejor región de C y gamma para hacer un rango de búsqueda más fino, y así obtener mejores datos de clasificación.

3.2.9 Validación cruzada

La validación cruzada implica en la separación de los datos en dos secciones, una para el entrenamiento y otra para la prueba, haciendo que los datos de estas secciones en todo el proceso sean independientes; esta técnica divide los datos en particiones (folds) dependiendo de K iteraciones (K-fold), repitiendo el proceso hasta llegar hasta la última iteración, este proceso puede ser observado en la Figura 22.

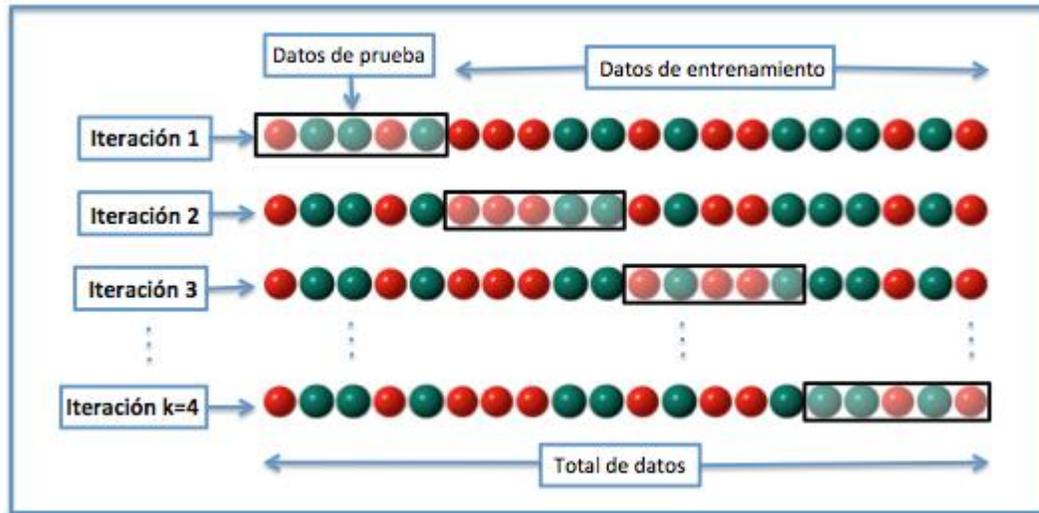


Figura 22. Validación cruzada de 4 iteraciones (K=4) [22]

Este método da como resultado un error, que es el promedio de los errores cometidos de todos los datos en todas las iteraciones, este se calcula mediante la media aritmética de los errores en cada iteración realizada para así obtener un solo resultado, su ecuación es la siguiente:

$$CV_{(k)} = \frac{1}{k} \sum_{i=1}^k MSE_i$$

Ecuación 7

Donde k es el número de iteraciones y MSE es la media aritmética.

4 Diseño metodológico

La estructura principal de esta investigación se puede observar en la Figura 23, comenzando con el sujeto de prueba utilizando la diadema EPOC+, teniendo una comunicación Bluetooth con un computador portátil mediante un transceptor USB que los fabricantes de la diadema le otorgan al usuario, luego se adquieren las señales para la creación de una base de datos para su análisis correspondiente.



Figura 23. Metodología general de la investigación

Cada instrumento (Hardware y Software) que es observado en la arquitectura es explicado más adelante, especificando sus características técnicas y la razón de su uso. De igual manera todos los procesos descritos serán explicados a detalle, de acuerdo al orden que se le dio en este diagrama.

4.1 Tipo y enfoque de la investigación

Para lograr los objetivos en este trabajo de grado, se usaron valores numéricos que tienen características de voltaje, frecuencia y densidad de potencia. Se usaron estos datos para comprobar las características fundamentales de los diferentes gestos fáciles y oculares, todo a partir de mediciones mediante el método del electroencefalograma, junto con diferentes modificaciones para obtener valores congruentes y valederos, por lo tanto el tipo de estudio de esta investigación es cuantitativo, ya que tiene todas las características de acuerdo a su definición general: “ El enfoque cuantitativo usa la recolección de datos para probar hipótesis, con base en la medición numérica y el análisis estadístico, para establecer patrones de comportamiento y probar teorías” [23].

4.2 Corpus de investigación

El corpus de esta investigación se caracterizó como muestreo por conveniencia. Los sujetos pertenecieron al programa de Ingeniería Electrónica de la Fundación Universitaria Los Libertadores y al programa de Psicología de la Universidad del Rosario, con disponibilidad de 15 minutos a 1 hora para la realización de las pruebas. El tamaño total de las muestras fue de 13 individuos, 4 mujeres y 9 hombres con un rango de edad entre 19 a 50 años (Media= 24,9).

4.3 Instrumentos

4.3.1 Hardware

Se explicará brevemente de las herramientas físicas usadas para la extracción y análisis de las señales por el método de electroencefalograma.

4.3.1.1 Emotiv EPOC+

Para la adquisición de datos se usará la diadema Emotiv EPOC+ (Figura 24), se usó este dispositivo y no otros de su misma categoría ya que esta diadema tiene los sensores suficientes para poder clasificar cada gesto de una manera exitosa (ver antecedentes) y es una de las diademas más usadas a nivel académico y de investigación.



Figura 24. Dispositivo Emotiv EPOC+ [24]

Este instrumento tiene catorce sensores/canales (AF3, AF4, F3, F4, FC5, FC6, F7, F8, T7, T8, P7, P8, O1, O2) EEG y dos sensores de referencia (CMS/DR) para la disminución de ruido, estos son mostrados en la Figura 25. El dispositivo tiene una entrada USB inalámbrica, esta se encarga de recibir las señales para su uso determinado, específicamente en este caso en obtener los datos necesarios para cumplir con el objetivo propuesto en la investigación.

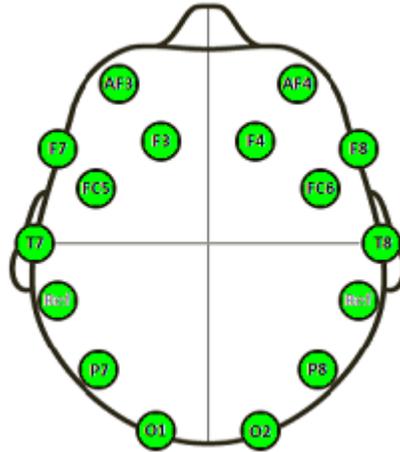


Figura 25. Ubicación específica de cada sensor del Emotiv EPOC+ [17]

4.3.1.2 Computador

Para la adquisición, exportación y análisis de las señales obtenidas por la diadema se usó un portátil Intel Core marca Hewlett Packard; se eligió esta herramienta ya que era necesario desplazarse en los lugares donde estaban ubicados cada sujeto de prueba y este equipo es lo suficientemente potente para poder hacer todas las acciones deseadas.

Las especificaciones técnicas del equipo son las siguientes:

- Marca: Hewlett Packard
- Procesador: Intel Core i3-5005U
- Núcleos: 2 Físicos, 2 Virtuales
- Velocidad: 2GHz
- Sistema operativo: Windows 10 Home Edition
- Disco duro: 500GB
- Memoria RAM: 6GB
- Pulgadas: 14 pulgadas

4.3.1.3 Celular

Se usó un celular Smartphone Samsung Galaxy S5 Active para indicar al sujeto mediante un tono saliente de este dispositivo cuando empezar la acción propuesta, este tono tiene una duración de 500ms y tiene una frecuencia de 1KHz, tiempo y frecuencia suficiente para que el sujeto pueda reaccionar correctamente.

4.3.2 Software

Para la adquisición de datos y su análisis correspondiente se usaron los siguientes programas descritos a continuación.

4.3.2.1 EmotivPRO

EmotivPRO es un software diseñado por la empresa Emotiv para la visualización de la secuencia en tiempo real de datos entrantes de la diadema que no son suministradas por Softwares gratuitos, tales como los datos de cada electrodo en valores de uV, datos de movimiento del giroscopio, calidad de contacto de cada sensor, paquetes de datos con su adquisición y pérdida correspondiente y análisis de frecuencias baja. Finalmente, este programa cuenta con grabación y exportación de todas las funciones mencionadas anteriormente.

4.3.2.2 Matlab

Matlab es una herramienta de Software para cálculos técnicos y visualización, contiene un lenguaje de programación propio llamado M, este brinda un entorno y prestaciones básicas fáciles de utilizar, las cuales han sido de gran atención para matemáticos e ingenieros; para esta investigación este Software será usado para la visualización, modificación y análisis de los datos resultantes de la diadema.

5 Desarrollo ingenieril

Para hacer todos los procedimientos correctamente se debe tener en primera estancia la diadema en un estado óptimo, empezando con la carga eléctrica que esta posee, este instrumento tiene una batería interna compuesta de polímero de litio a 650mAh, la cual toma un tiempo promedio de cuatro horas para cargar completamente, la carga de diadema se hace mediante una entrada mini USB que se conecta a un PC o a un conector de red eléctrica, observado en la Figura 26.

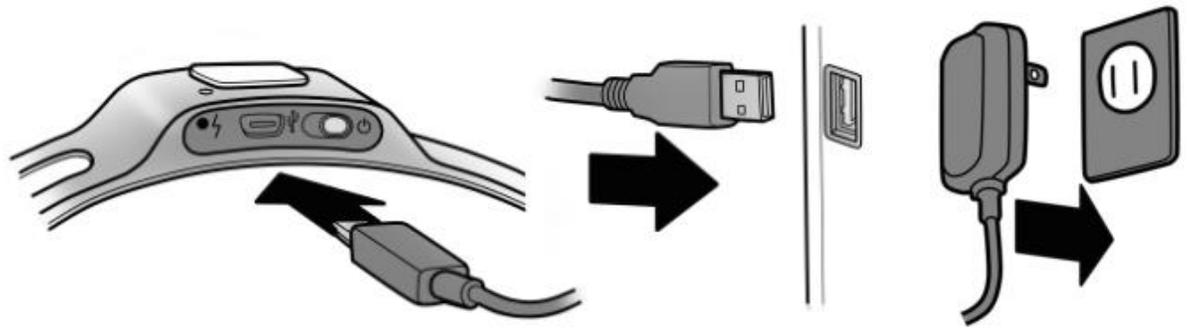


Figura 26. Puerto Micro USB de la diadema EPOC+ [25]

Los electrodos se encuentran separados de la diadema en un paquete de hidratación (Figura 27), estos sensores tienen que ser hidratados cada uno con solución salina para obtener un buen contacto con el cuero cabelludo de los sujetos a evaluar.

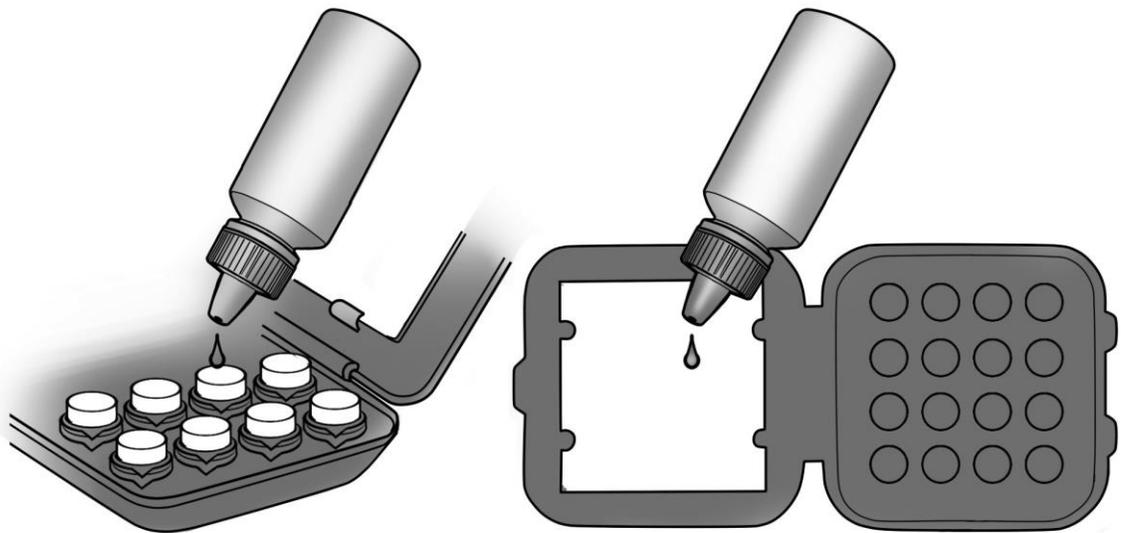


Figura 27. Hidratación de los electrodos [25]

Después del proceso de hidratación de los electrodos, se tienen que retirar cada uno con sus almohadillas de fieltro para ser insertadas en cada conector de la diadema, los sensores no tienen ningún punto de referencia, y por lo tanto se puede colocar cualquier electrodo en cualquier brazo de la diadema, cada uno debe ser puesto de acuerdo a las manecillas del reloj y tienen que estar firmemente puestos antes de encender la diadema como se observa en la Figura 28; cuando no están en uso deben ser colocados nuevamente en el paquete de hidratación para reducir su oxidación.

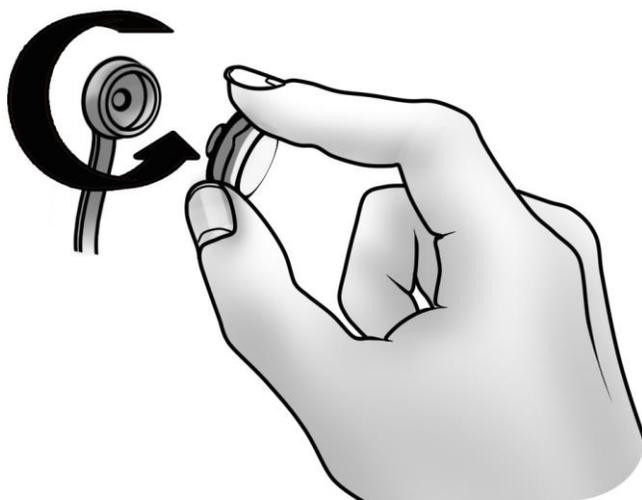


Figura 28. Instalación de los sensores [25]

Para la comunicación de la diadema con el computador, se debe emparejar la diadema con una llave transceptor USB que viene suministrada con la compra del dispositivo, esta debe ser colocada en un puerto USB del equipo a usar para la adquisición datos. Seguido a esto, se enciende la diadema cambiando de dirección el interruptor ubicado en el extremo inferior de la misma, manteniéndolo a una distancia aceptable del transceptor (Figura 29).

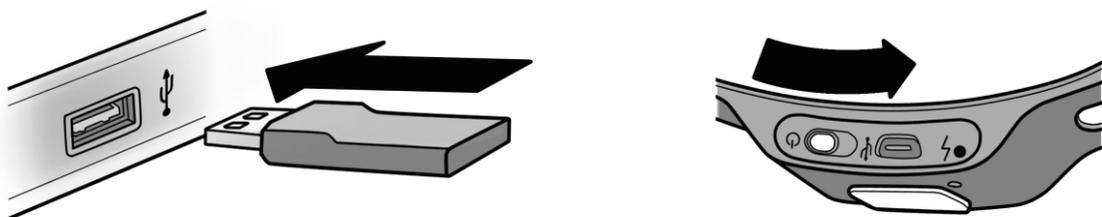


Figura 29. Emparejando la diadema EPOC+ [25]

Finalmente, el último paso es la colocación de la diadema al sujeto de prueba, esta debe ser deslizada cuidadosamente en la cabeza de la persona hasta que los dos sensores de referencia estén en el hueso detrás del lóbulo de la oreja (Figura 30), la posición de los sensores de goma (tierra) es sumamente importante ya que son los sensores de referencia de la diadema.

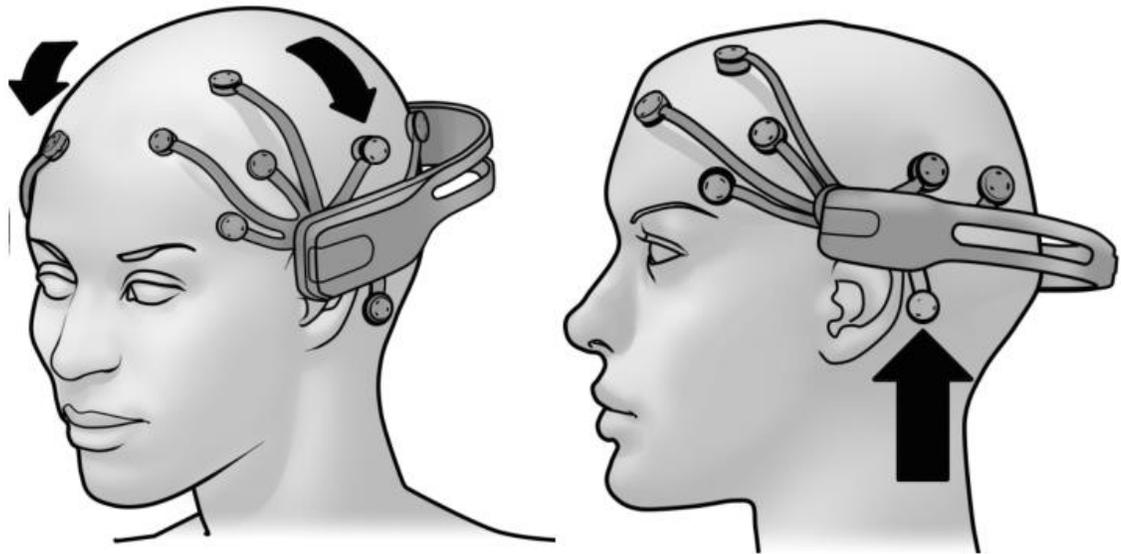


Figura 30. Colocación de la diadema (primera fase) [25]

Los dos sensores frontales deben estar aproximadamente a una distancia de 3 dedos sobre las cejas del sujeto (Figura 31), los otros sensores deben estar tocando el cuero cabelludo de una manera correcta. Después de hacer este paso de verificación se tiene que presionar los dos sensores de goma durante 20 segundos para poder empezar a obtener señales de entrada en el Software utilizado en esta investigación.

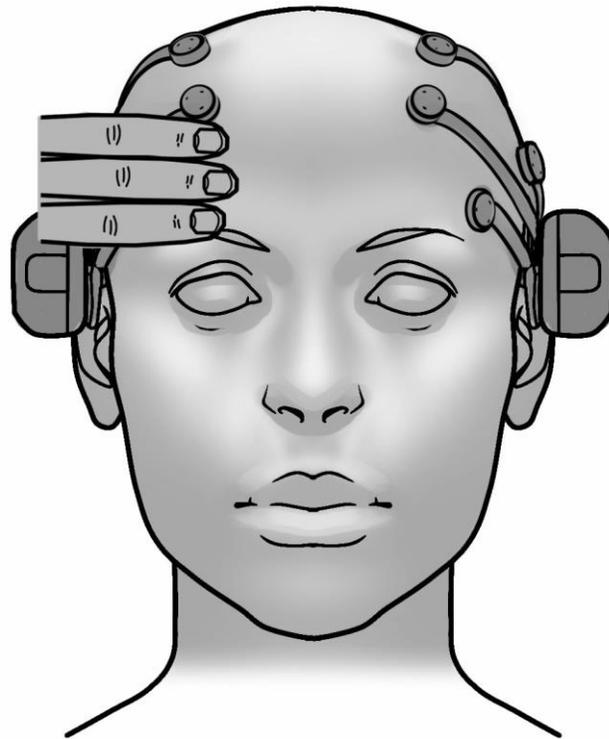


Figura 31. Colocación de la diadema (segunda fase) [25]

Se debe comprobar el estado de cada electrodo mediante el Software EmotivPRO, antes de que el Software muestre en tiempo real cualquier medición deseada, este automáticamente lleva al usuario a una interfaz indicando los estados de cada sensor utilizado, los electrodos pueden tener diferentes estados de contacto con respecto al cuero cabelludo del individuo, ilustrados en la Figura 32, estos estados indican lo siguiente:

- Negro: Contacto demasiado pobre o nulo
- Rojo: Contacto pobre
- Naranja: Contacto moderado
- Verde: Contacto bueno

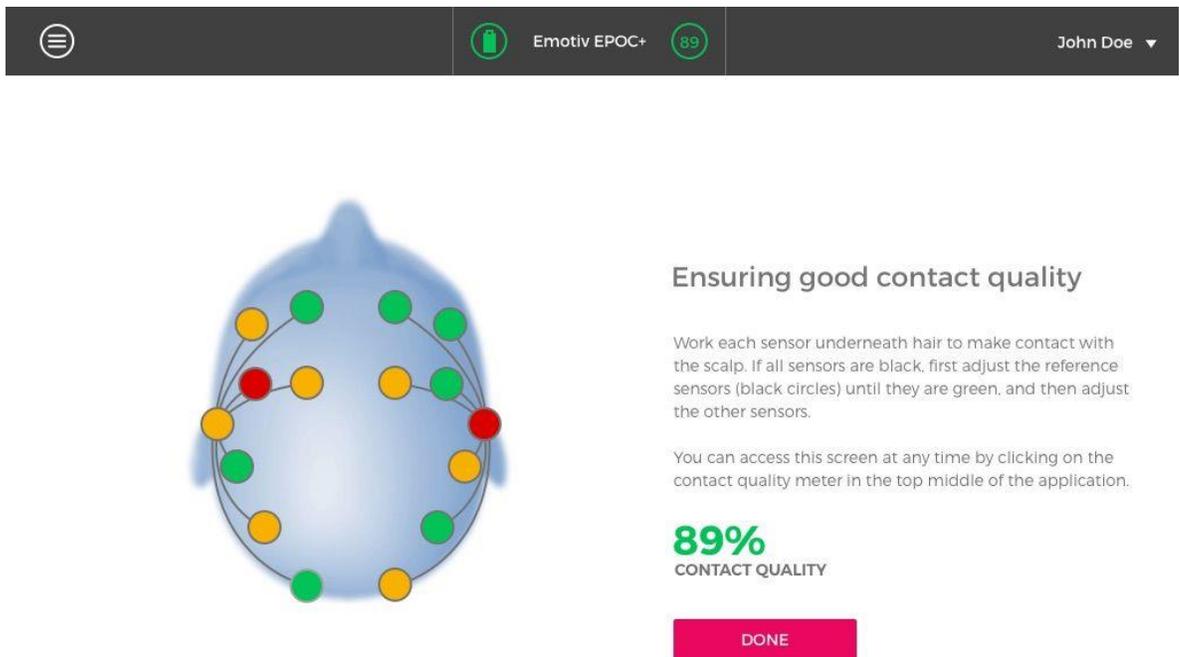


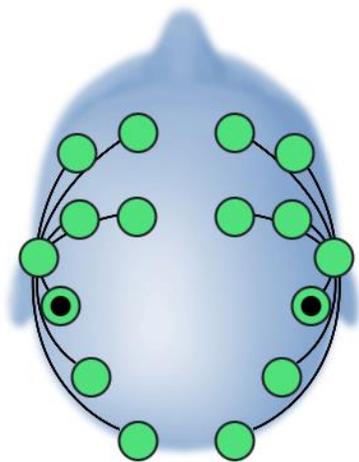
Figura 32. Mapa de los electrodos con sus posibles estados de contacto. [25]

Cuando todos los electrodos tengan un buen contacto con el individuo, se empieza a indicar a cada sujeto en que se consiste la prueba y que se debe hacer en cada gesto y posteriormente a esto se empieza con la toma de datos.

6 Toma de datos

La toma de datos se constituye en los siguientes pasos para cada sujeto de prueba:

A cada participante se le ayuda a colocar la diadema como se describe en la sección anterior y se toman entre cinco a quince minutos para que todos los sensores tengan una buena conductividad (Figura 33), en este intervalo de tiempo se le explica a cada sujeto en que consiste la prueba y las instrucciones correspondientes.



Ensuring good contact quality

Work each sensor underneath hair to make contact with the scalp. If all sensors are black, first adjust the reference sensors (black circles) until they are green, and then adjust the other sensors.

You can access this screen at any time by clicking on the contact quality meter in the top middle of the application.

100%
CONTACT QUALITY

DONE

Figura 33. Mapa de los electrodos en el estado deseado para cada toma de datos. [25]

Se le indica a cada participante que tiene treinta segundos para quedarse lo más estable posible y después de este tiempo se iniciará la prueba al comprobar que todos los electrodos están con una salida lineal y que tanto la diadema como el sujeto no tengan algún tipo de interferencia.

Cuando se verifique el paso anterior, se iniciará la toma de datos para el gesto correspondiente, se toman cinco segundos para comprobar nuevamente que la señal de salida es estable y después de este intervalo un sonido saliente de un celular indicara que tienen que hacer el movimiento deseado para la prueba.

En el momento que el sujeto haga el movimiento correspondiente, se toman otros cinco segundos para que las señales de la diadema se restablezcan, y así finalizar la toma de datos. Estos pasos son repetidos para todos los 6 gestos seleccionados; después de obtener todas las grabaciones estas pueden ser reproducidas para observar si es necesario volver a hacer la prueba o si es pasable, y después son guardadas en formato CSV (comma separated values) para su análisis correspondiente en Matlab.

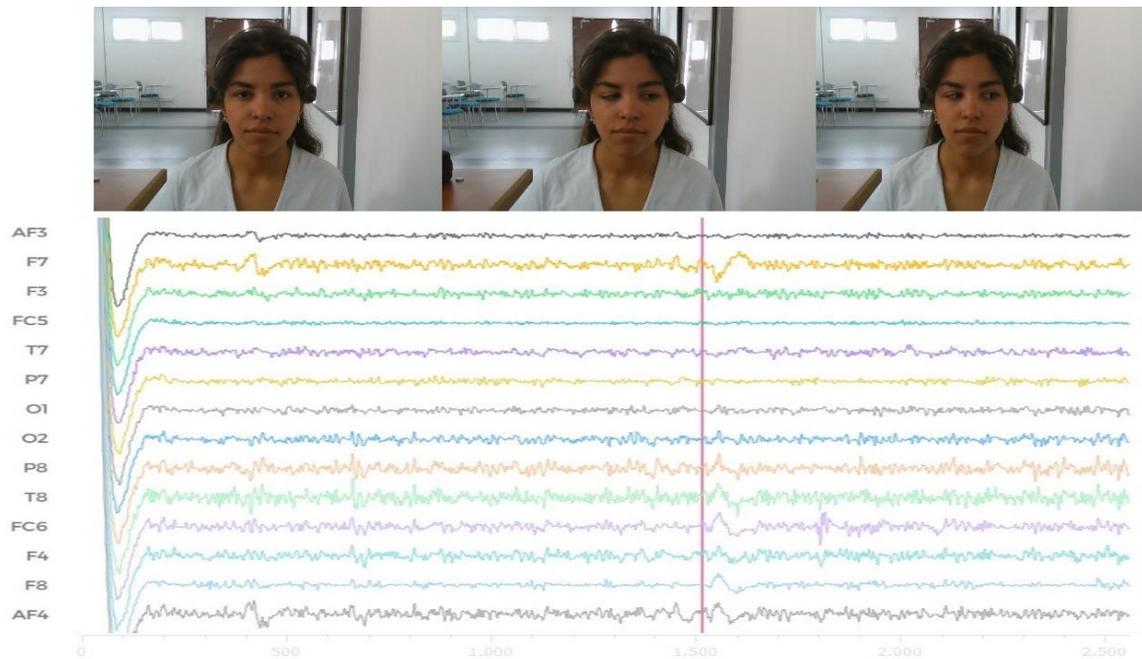


Figura 34. Ejemplo de prueba cuando el sujeto mueve los ojos a la derecha

En ciertos casos, observado en la Figura 34, el sujeto en la prueba cuando realiza el movimiento de los ojos hacia la derecha, se queda en el movimiento hecho después de la indicación, esto es razón a que si el sujeto mueve de nuevo los ojos a su posición original (mirando al frente), va a haber interferencias de señales y, por lo tanto, será difícil identificar la diferencia entre la señales reales y basura en la sección de análisis. En otros gestos fáciles esto no es problema, debido a que el movimiento es único y no cambia el estado inicial del sujeto después de hacerlo, ciertos ejemplos son cuando la persona mastica o parpadea, mostrado a continuación en la Figura 35.

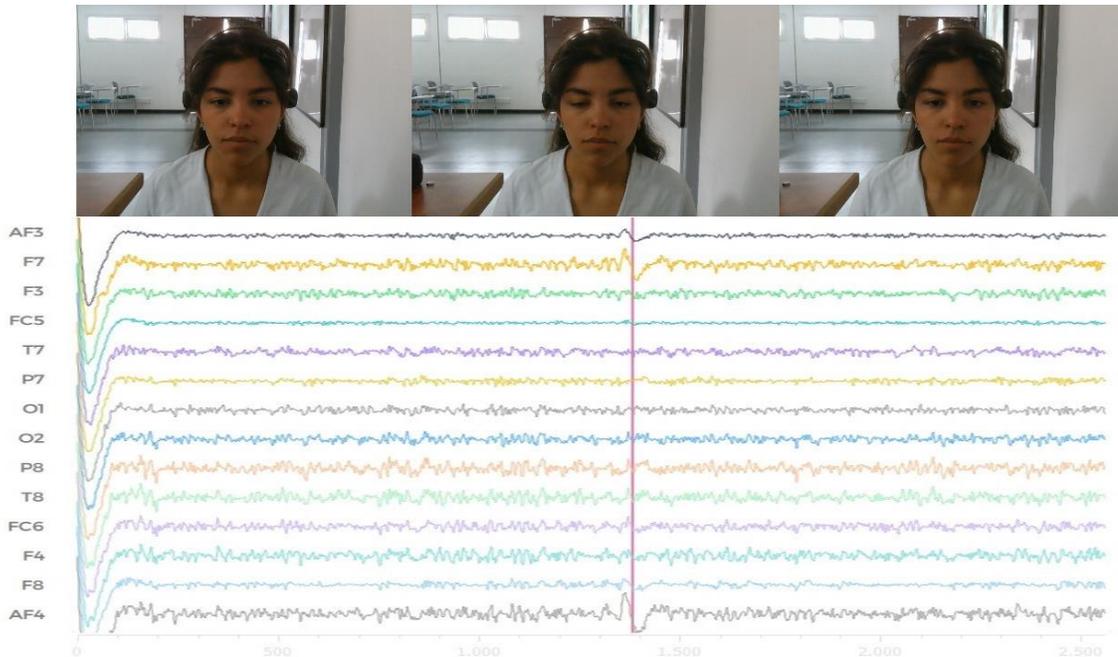


Figura 35. Ejemplo de prueba cuando el sujeto parpadea

Cuando se obtiene los datos correctos de cada gesto, se comienza a hacer su extracción y clasificación de cada prueba, dependiendo del movimiento realizado. La extracción consistió en la creación de una base de datos de cada prueba realizada, guardándola en formato CSV para hacer su análisis correspondiente en MATLAB.

7 Análisis de resultados

En esta sección se darán a conocer los pasos realizados y los resultados experimentales obtenidos para cada gesto registrado, esto se divide en tres etapas: Procesamiento de señal, extracción de características y caracterización de gestos faciales.

7.1 Procesamiento de señales

Cuando se exportan las señales medidas de cada sujeto en formato .CSV, ilustrado en la Figura 36, se hacen ciertos procedimientos para realizar un análisis más exacto, se observa que el programa EmotivPRO no solamente exporta los datos de los electrodos, sino que igualmente exporta datos como el muestreo de la señal, los datos obtenidos por el giroscopio de la diadema, aunque esta opción estuviera desactivada, entre otros datos no deseados para esta investigación.

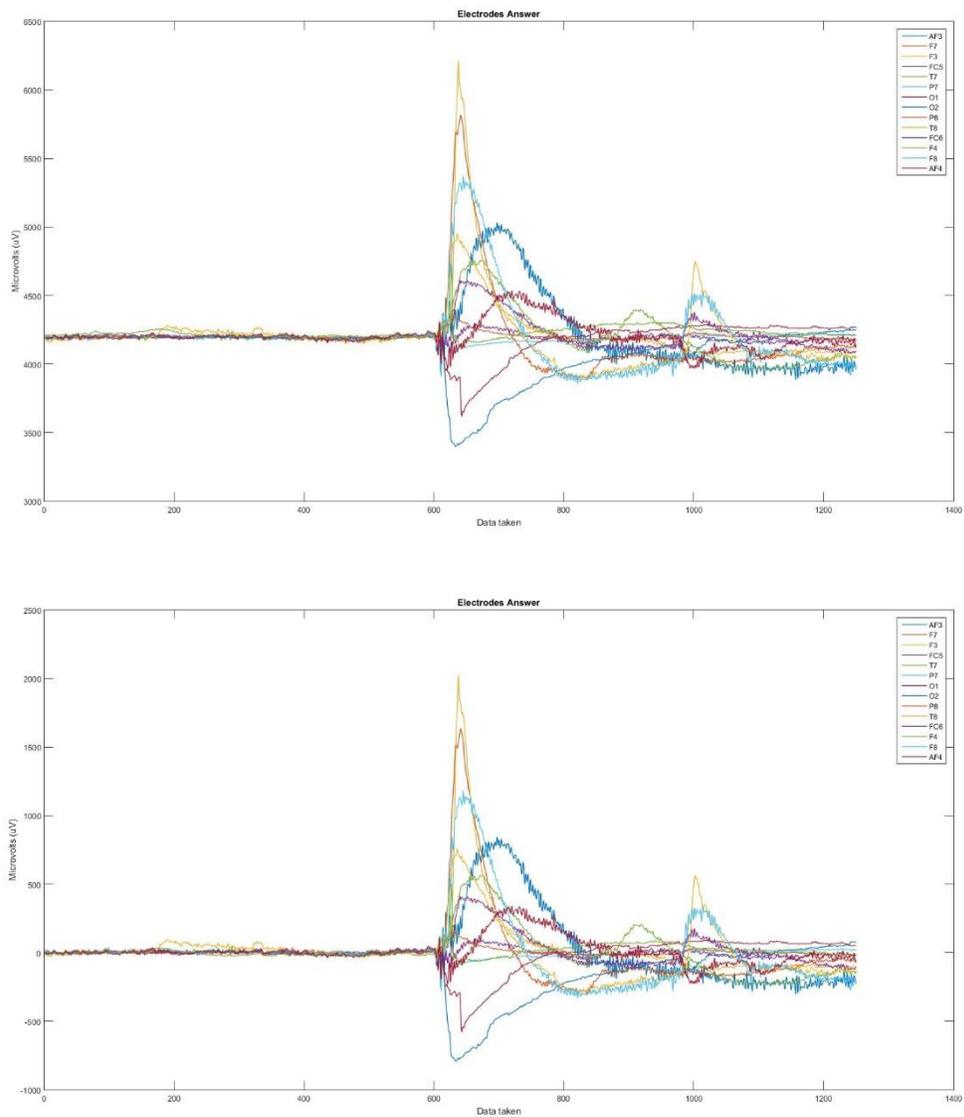


Figura 37. Datos originales y datos resultantes mediante el método de la mediana. (S3)

Observado en todo el procedimiento de la eliminación del Offset DC, en esta particular prueba hay ciertos picos en los electrodos un tiempo después de la acción realizada, para evitar que haya confusiones en la extracción de las características se hace el procedimiento de la ventana plana. Se crea este tipo de ventana con una longitud de 1250, que es valor exacto del valor total de datos de cada electrodo para todos los archivos, su resultado es observado en la Figura 38.

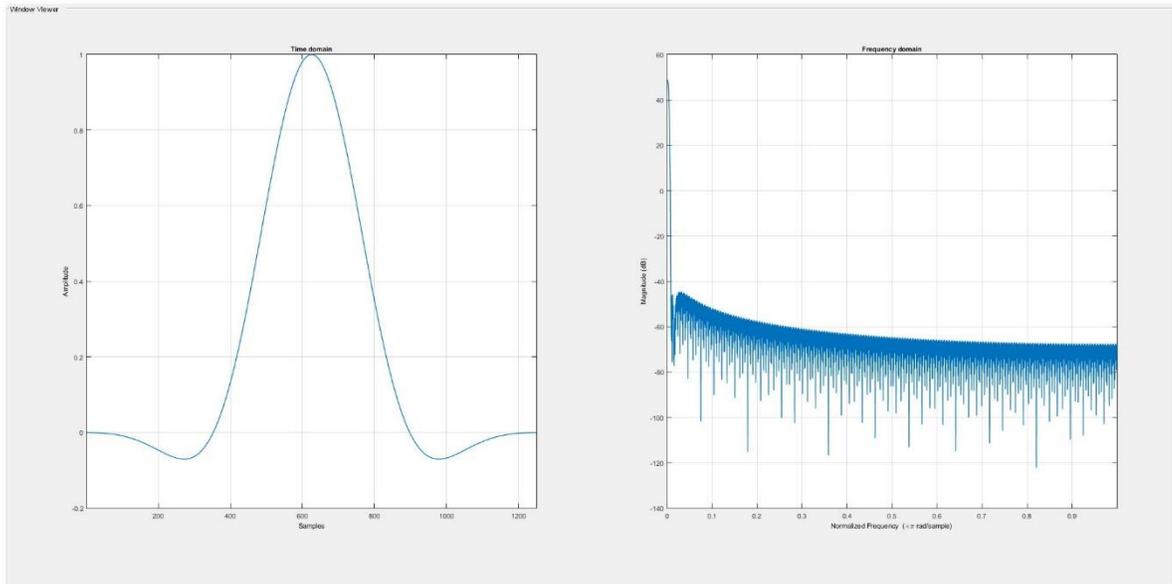


Figura 38. Ventana plana utilizada.

Se usó este tipo de ventana ya que a comparación con otro tipo de ventanas tales como Hanning o Blackman, este tiene una forma parecida a un seno gaussiano. Y hace que los picos de las señales no deseados en los tiempos menos y mayores a 625 no sean tan grandes comparado con los otros tipos de ventana mencionados, este tipo de ventanas son aconsejables para el análisis de señales tales como la transformada rápida de Fourier (FFT) y análisis espectrales.

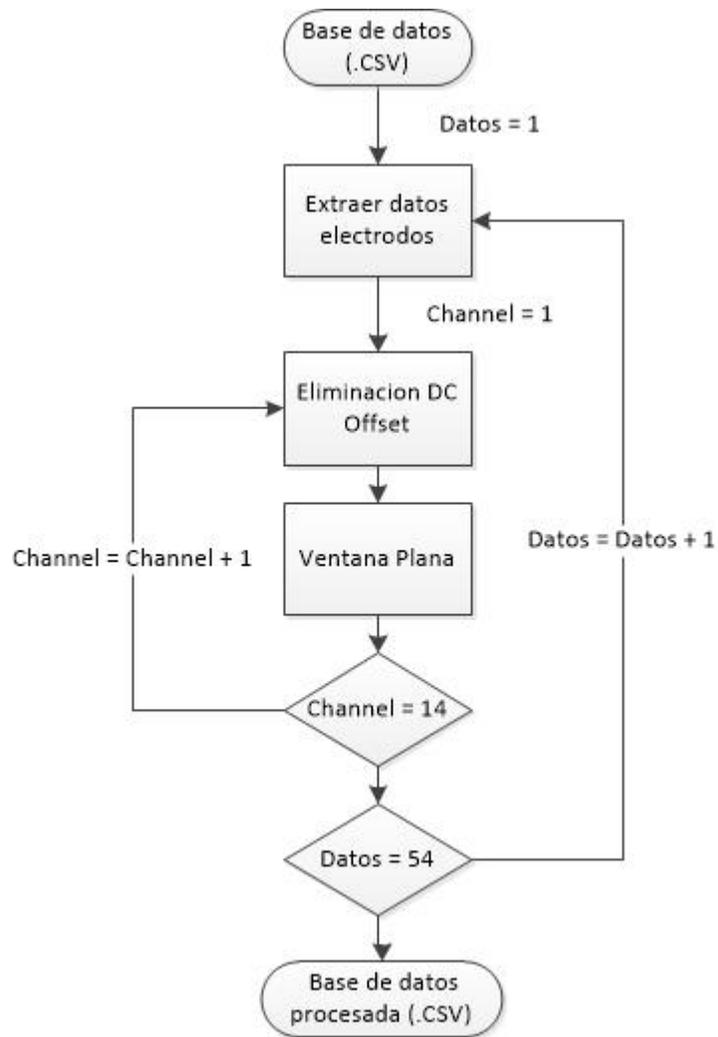


Figura 39. Diagrama de flujo del procesamiento de señales

En la realización de este código visto en la Figura 39, se especificó el número de electrodos (ver antecedentes) y la cantidad de datos en nuestra base de datos, más adelante se explicará porque la base de datos quedo con un total de 54 datos; debe de tenerse en cuenta que, para hacer las pruebas del código, fue necesario separar los datos entrantes y resultados en dos carpetas diferentes, para así no perder la base de datos original si se llegara a hacer una modificación en el futuro.

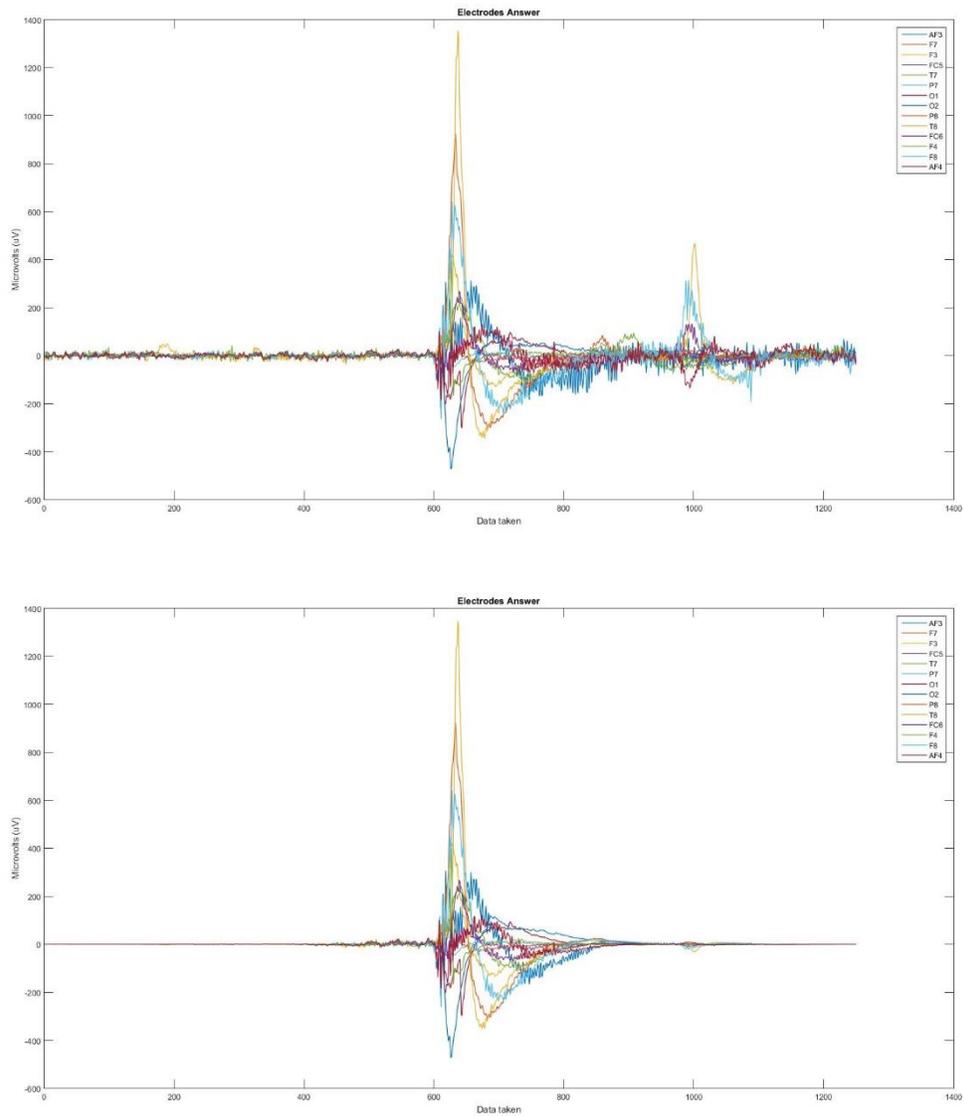


Figura 40. Resultado de las señales después del uso de la ventana plana. (S3)

Observado en la Figura 40, se puede distinguir notoriamente la diferencia de los resultados en señales cuando esta es procesada en una ventana plana con la señal original. Con la obtención de estos resultados, se comienza a realizar la extracción de características de las señales a evaluar.

7.2 Extracción de características

Cuando se obtienen todos los archivos con su eliminación de Offset y ventana plana correspondiente se hacen tres tipos de análisis para la extracción de características, ya que se usaron todos los catorce electrodos, se necesita saber con exactitud cuáles son los que más se pronuncian en cada gesto

realizado, para poder obtener los datos deseados con la mejor exactitud posible se hace primero una transformada rápida de Fourier (FFT) para observar las características de cada prueba en términos de frecuencia.

Para realizar este análisis, se realiza un algoritmo que tome todos los datos de cada electrodo y se hace su transformada a partir de la función `fft` de Matlab, en donde su frecuencia de muestreo (f_s) es 128Hz, para luego ser graficada en términos de la frecuencia. Se demostrará el resultado de la transformada rápida de Fourier con el mismo archivo que se usó para el procedimiento del ítem anterior, este gesto en particular es del levantamiento de las dos cejas, el resultado es mostrado a continuación en la Figura 41.

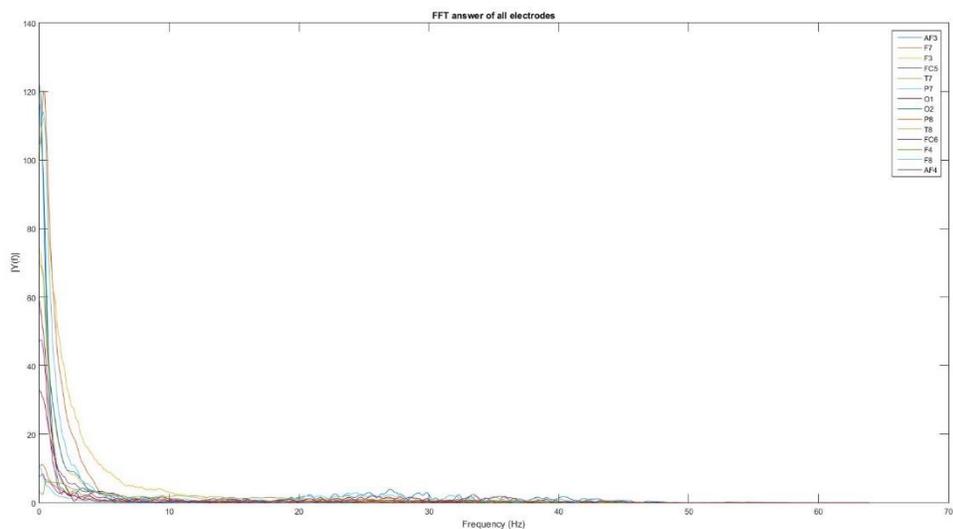


Figura 41. Resultado de la transformada rápida de Fourier (S3)

Se observa que su componente en frecuencia para todos los electrodos en este gesto en particular se manifiesta significativamente desde 1Hz hasta 10Hz, pero aun teniendo este dato en particular no se denota que electrodos tienen un cambio significativo para la clasificación correspondiente. Para la obtención de datos más exactos se realiza el método de densidad espectral de potencia (PSD). Esta función matemática muestra de una forma gráfica como está distribuida la potencia de las señales evaluadas con respecto a la frecuencia, tomando los resultados de esta función se desea hallar qué electrodos son los que más se manifiestan en cada gesto, haciendo un promedio de acuerdo a todas las personas que fueron evaluadas.

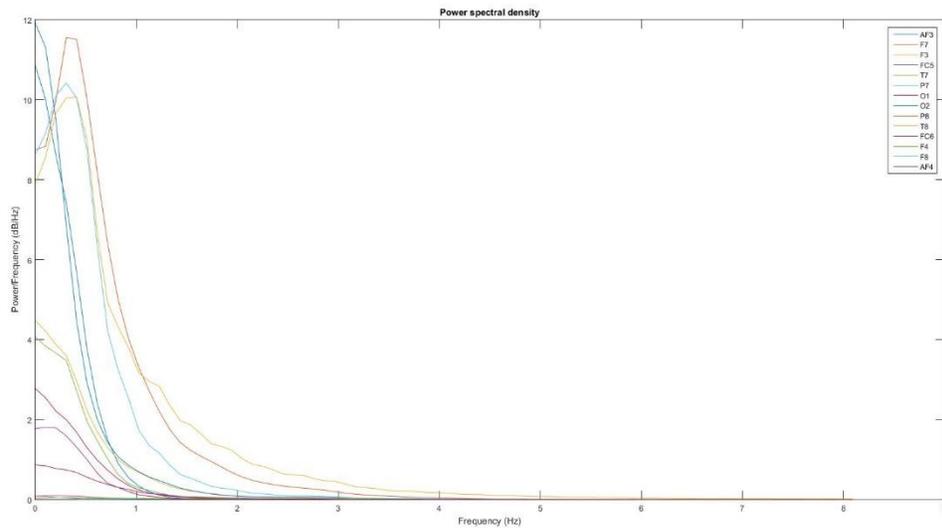


Figura 42. Resultado del uso de densidad espectral de potencia. (S3)

Según la Figura 42, se observa que tres electrodos tienen una potencia más alta que los demás, debido a que estos electrodos son los que más manifiestan cambio cuando se realiza la acción del levantamiento de las dos cejas; estos resultados no siempre serán los mismos en términos de amplitud, potencia, junto con activación de los electrodos. Cada persona tiene una forma de cráneo, cuero cabelludo, edad y sexo diferente y por esta razón los resultados no serán los mismos, aunque se realice el mismo gesto facial. En consecuencia, más adelante se mostrará que ciertos electrodos se manifiestan más que otros realizando la misma acción, teniendo una similitud en su respuesta base, que puede ser usada para obtener una señal piloto de referencia.

Para poder observar con mayor precisión qué electrodos son los que más potencia tienen, tomando en cuenta que gráficamente no es posible observar con exactitud estos cambios notorios en la amplitud, se hace un método estadístico llamado diagrama de cajas. El diagrama de cajas muestra los máximos, mínimos y mediana de un sistema en específico, usando este diagrama se puede observar de manera gráfica como es el cambio de cada electrodo comparándolos con los demás.

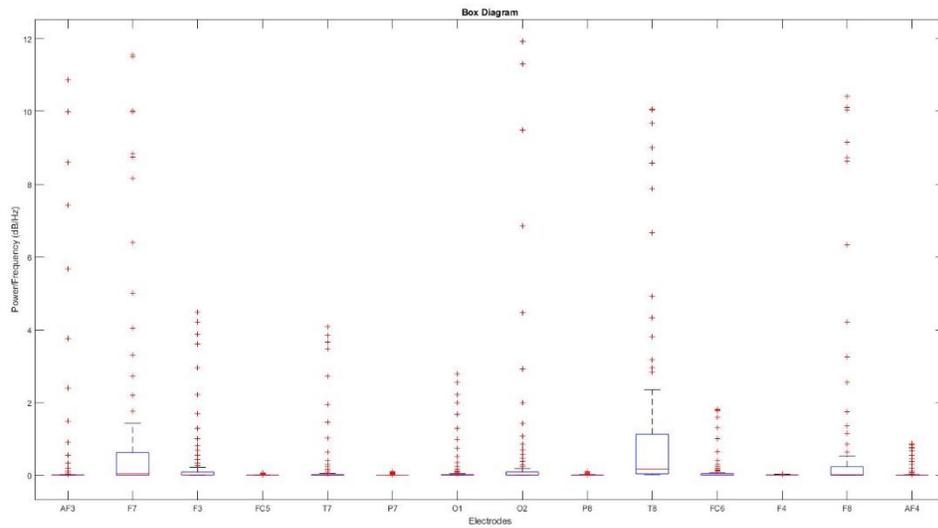


Figura 43. Resultado del uso de diagrama de cajas (S3)

Observado en la Figura 43, con el diagrama de cajas se puede observar con mayor exactitud qué cambios en términos de potencia tienen cada electrodo, la mediana total de cada sensor está por un valor cercano a cero indicando que no hay actividad alguna, en algunos electrodos en el rectángulo que indica los cuartiles de la mediana se muestra que está más amplio que otros, esto indica que el electrodo obtuvo valores de potencia constantes y de valores considerables en más de una frecuencia. Debido a que el diagrama muestra un resultado de potencia con respecto a la frecuencia, este no tiene teóricamente valores mínimos, los valores mínimos del sistema, que en su mayoría son valores negativos se convierten en valores positivos por la transformada rápida de Fourier, haciendo un cambio drástico en los cuartiles y en las amplitudes máximas del resultado de densidad espectral de potencia.

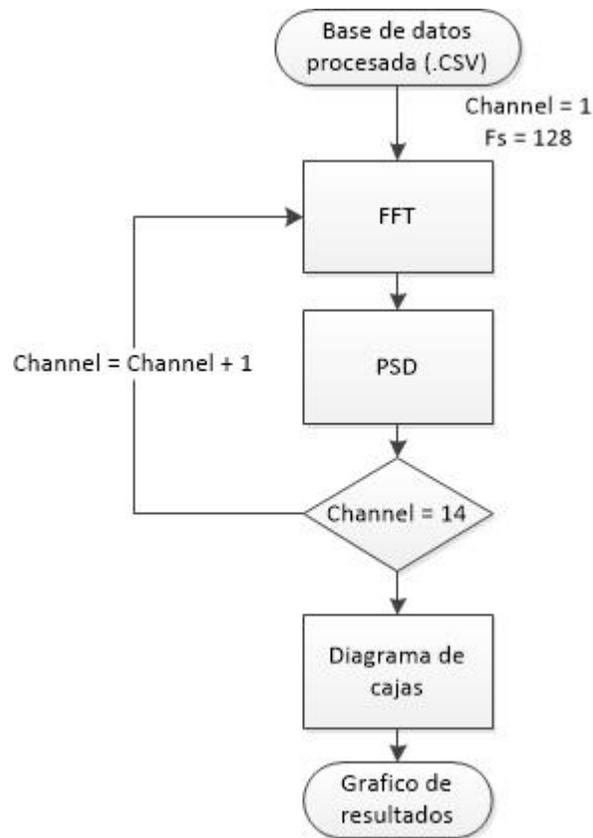


Figura 44. Diagrama de flujo para procesos de FFT, PSD y diagrama de cajas

El resultado del algoritmo para esta sección es mostrado en la Figura 44, se toma la base de datos procesada obtenida y se hace los procesos correspondientes; cada proceso de FFT y PSD debió ser realizado en cada electrodo (o canal) de la base de datos y el resultado del diagrama de cajas pudo ser graficado entre todos los canales.

Realizando estos pasos, se crean dos tablas con los resultados de los electrodos que más se manifestaron en la muestra de hombres y mujeres, tomando en cuenta tanto la señal base como los resultados de la transformada rápida de Fourier y densidad espectral de potencia.

Gesto Facial	Electrodos manifestados	Porcentaje de detección
Levante de la dos cejas	F7, F8	F7: 66.6% F8: 88.8%
Masticar	F7, T7, F8, FC5, FC6	F7: 77.7% T7: 77.7% F8: 88.8%, FC5: 77.7%, FC6: 88.8%
Mirar hacia la derecha	F7, T8, FC6, F8	F7: 77.7% T8: 55.5% F8: 100% FC6: 88.8%

Mirar hacia la izquierda	F7, F8, FC6	F7: 88.8% F8: 77.7% FC6: 55.5%,
Cerrar los ojos	AF3, F7, F8, AF4	AF3: 66.6% F7: 100% F8: 88.8%, AF4: 66.6%
Parpadeo	AF3, F7, F8, AF4	AF3: 77.7% F7: 88.8% F8: 77.7% AF4: 77.7%

Tabla 1. Electrodo que más se manifiesta en las pruebas realizadas, con su porcentaje de detección. (Hombres)

Con los datos observados en la Tabla 1, se puede observar que en la mayoría de los gestos faciales y oculares que cada sujeto realizó, los electrodos que están ubicados en la parte frontal son los que más se manifiestan con respecto a los demás, debido a que la mayor parte de movimiento muscular está siendo efectuado en el rostro del individuo, y solamente un gesto que tenga un cambio más brusco o significativo puede llegar a tener activación en otras locaciones de los electrodos de la diadema usada, como se puede observar con la acción de masticar, también siendo los otros electrodos no detectados mejor usados para aplicaciones más específicas, tales como el análisis de las ondas cerebrales (Gamma, Alpha, Beta, etc).

Gesto Facial	Electrodos manifestados	Porcentaje de detección
Levante de la dos cejas	F4, AF4	F4: 50% AF4: 75%
Masticar	F7, FC5, T8, AF4	F7: 75% FC5: 50% T8: 50% AF4: 75%
Mirar hacia la derecha	F7	F7: 50%
Mirar hacia la izquierda	F7, T8, F4, F8, AF4	F7: 50% T8: 50% F4: 50% F8: 50% AF4: 50%
Cerrar los ojos	O2, AF4	O2: 50% AF4: 50%
Parpadeo	T8, F4	T8: 50% F4: 50%

Tabla 2. Electrodo que más se manifiesta en las pruebas realizadas, con su porcentaje de detección. (Mujeres)

Observado en la Tabla 2, la razón principal de separar los datos resultantes de hombres y mujeres fue por el resultado que se obtuvieron en ambos casos, mientras que la base de datos de los hombres se notaba una gran similitud en las señales base de cada gesto facial y ocular, la base de datos de las mujeres no se notaba alguna similitud que pudiera ser utilizada para esta investigación, las señales salientes de la mayoría de los gestos tenían una amplitud demasiado baja y sin ningún tipo de forma senoidal a contrario de las señales de los hombres. Igualmente, su salida tanto en la transformada rápida de Fourier y en la densidad espectral de potencia pudo verificar que los datos no tenían alguna

coherencia en términos de frecuencia y potencia, un ejemplo de estos resultados es observado en la Figura 45.

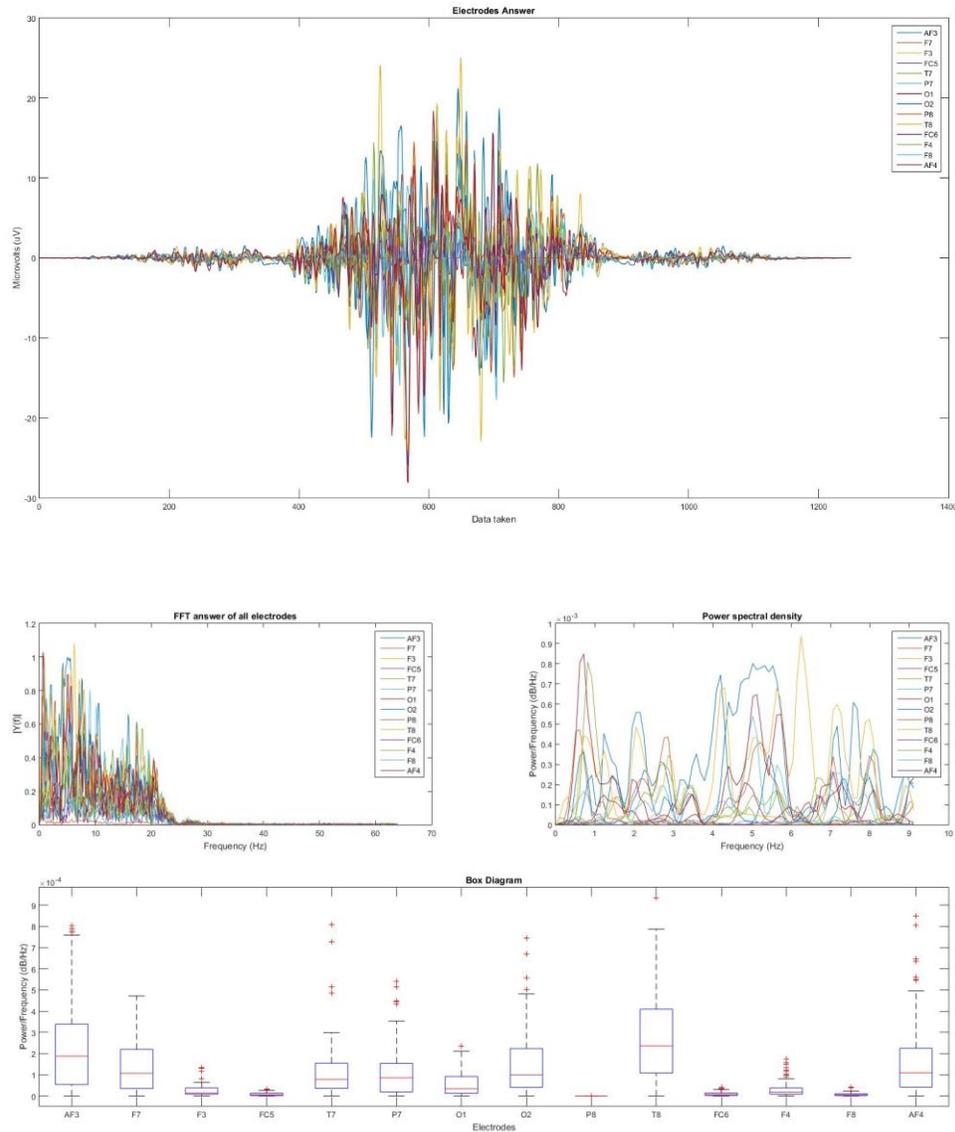


Figura 45. Señal entrante con su resultante en FFT y PSD (S12)

En las pruebas realizadas hacia los sujetos de sexo femenino, se verificó manualmente las salidas de las pruebas, aunque se observó visualmente que las pruebas de cada gesto fueron exitosas, se notó que el cambio de amplitud fue bajo, esto es debido a que el cuero cabelludo de todas las participantes era lo suficientemente largo para tener algún tipo de interferencia física con los electrodos, dando una respuesta errónea y difícil de usar para este proyecto; por lo tanto, esta base de datos no se usará para

la caracterización de gestos faciales, disminuyendo drásticamente la base de datos a nueve personas, con un total de 54 datos (Figura 39).

7.3 Caracterización de gestos faciales

7.3.1 Convolución y Correlación

Tomando los datos resultantes de la Tabla 1, se desea hallar la similitud de las señales manifestadas en cada electrodo, para poder saber con la mayor exactitud qué relación tienen las señales se hacen dos métodos estadísticos, convolución y correlación.

Se empieza con la convolución, una operación que se encarga de combinar dos señales creando una nueva, antes de poder hacer este procedimiento se deben de tener algunas cosas en cuenta. Las señales de entrada de cada individuo, aunque se hiciera el mismo procedimiento con cada uno de ellos, las reacciones que ellos tienen para hacer el gesto seleccionado siempre será en tiempos diferentes, para solucionar esto, se realiza un algoritmo que tome las señales y las cuadre en un mismo intervalo, se denota igualmente en este código que las amplitudes máximas y mínimas (dependiendo de la forma de la respuesta del electrodo) son diferentes para cada persona, para hacer la convolución correctamente, se normalizo las señales entrantes para que tenga un valor máximo y mínimo de 1 y -1.

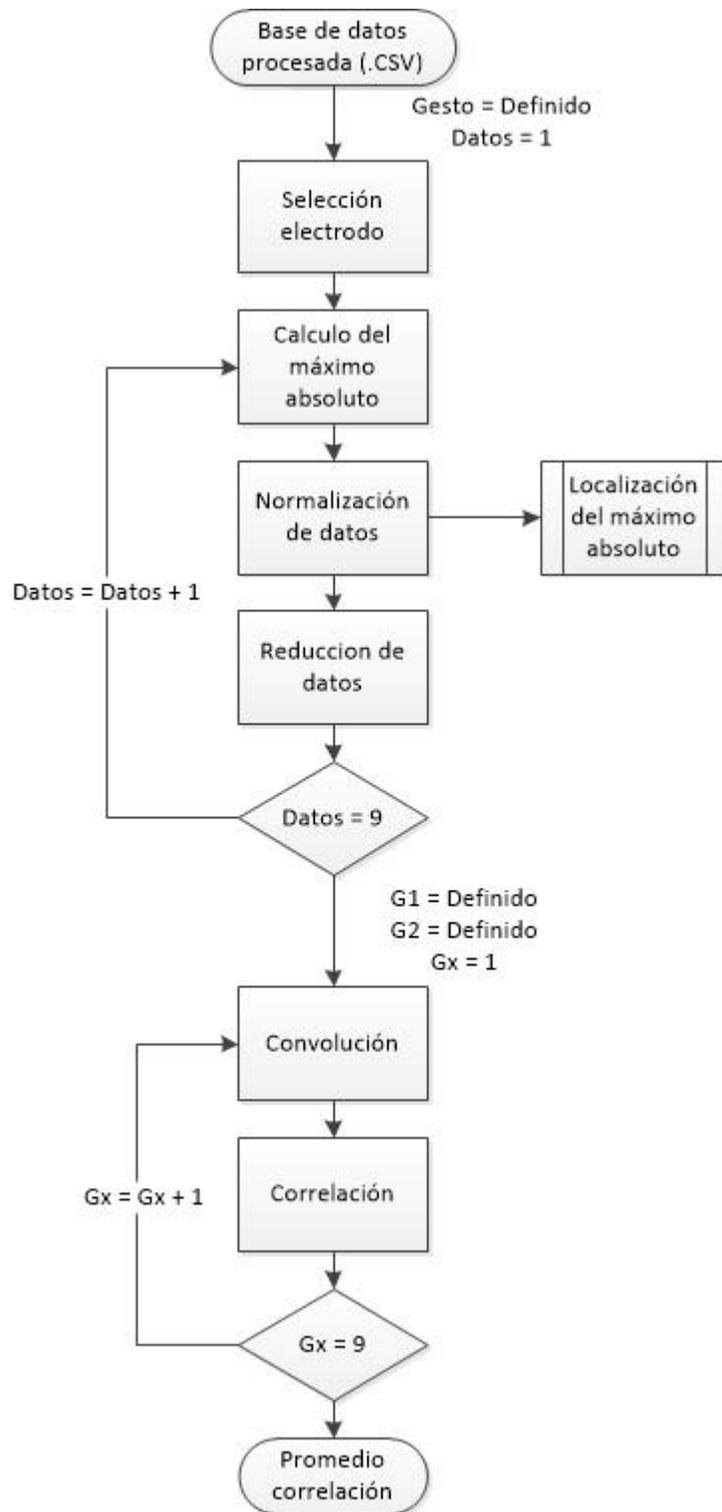


Figura 46. Diagrama de flujo del proceso de correlación y convolución

Observado en la Figura 46, se observa el proceso del código realizado, después de que los datos fueran normalizados y puestos en el mismo tiempo de respuesta, se realiza los procesos de convolución y correlación, las variables descritas en este diagrama se explicaran más adelante; en este proceso se realizó la normalización con un máximo absoluto, esto es debido a que algunas respuestas en algunos gestos faciales y oculares se obtuvo una amplitud negativa superior a la positiva, por lo cual se debió hallar este máximo para que su correlación fuera correcta, finalmente se deseó hallar la localización de este valor para que fuera el punto base del tiempo de respuesta en cada dato evaluado.

Haciendo el algoritmo planteado se puede observar su resultado sin convolución y correlación, utilizando en esta sección el mismo gesto facial con el que se ha visualizado todos los resultados de este documento, el levantamiento de las cejas, junto con el electrodo que más porcentaje obtuvo visto en la Tabla 1, F8.

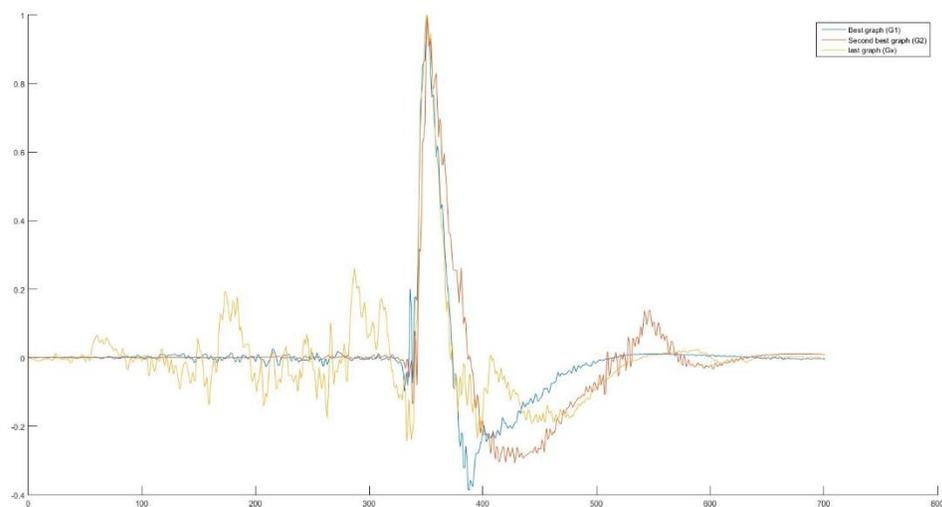


Figura 47. Señales organizadas y normalizadas para la convolución. (S4, S3 y S9)

Después de realizar el proceso exitosamente como se observa en la Figura 47, se realiza la convolución, para esto se toman tres señales del electrodo F8 de tres sujetos diferentes, y su clasificación es G1, G2 y Gx. En donde G1 es la mejor señal del electrodo en la base de datos del gesto facial correspondiente, G2 es la segunda mejor señal del electrodo y Gx es cualquier otra señal de la base de datos, se puede observar en la Figura 48, cada respuesta del electrodo F8 con cada individuo de la base de datos.

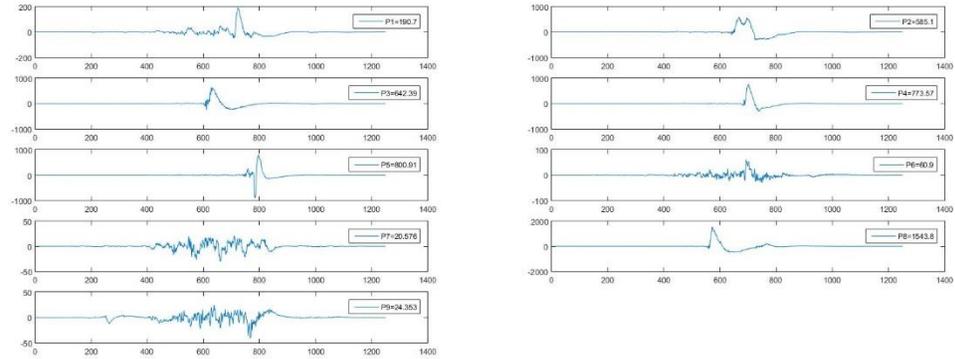


Figura 48. Respuesta de cada electrodo F8 de cada individuo en el gesto de levantamiento de las dos cejas

La convolución se desarrollaría de la siguiente manera: Se realiza la convolución entre G1 y G2, dando como resultado C1, luego se realizaría la convolución entre G1 y Gx, dando como resultante Cx. C1 es la señal piloto con la cual se realizará la correlación con Cx, la señal Cx siempre será variable, en otras palabras, G1 y G2 siempre estarán constantes ya que son las mejores señales de la base de datos, mientras que Cx cambiará ya que una de sus entradas será la señal que se quiere hallar su correlación correspondiente (Gx), luego de obtener las dos señales resultantes de la convolución se realiza el cálculo de la correlación. El resultado de la correlación muestra con mayor exactitud en un rango de -1 a 1, cuanto las dos señales evaluadas se relacionan, para demostrar la efectividad de la correlación, se realiza este procedimiento usando las señales de la Figura 34, obteniendo el siguiente resultado a continuación ilustrado en la Figura 49.

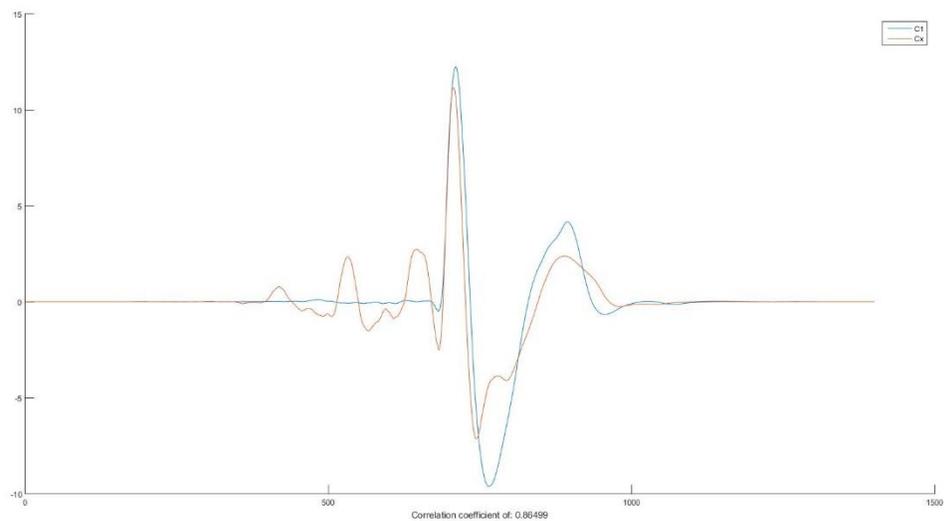


Figura 49. Resultado de la convolución y correlación.

Con estas señales seleccionadas, se observa gráficamente que tiene similitudes en la forma como se manifiesta cada una, verificando con el resultado de la correlación, dio un resultado de 0.86, significando que existe una muy buena relación entre las dos señales salientes de la convolución. Seguido a este procedimiento se hace el mismo proceso con cada señal de la base de datos, este resultado de la correlación se le saca un promedio y su resultado es observado a continuación en la Tabla 3.

Gesto Facial	Electrodos	Resultado de correlación
Levante de la dos cejas	F7, F8	F7: 0.7802 F8: 0.7411
Masticar	F7, T7, F8, FC5, FC6	F7: 0.6912 T7: 0.2591 F8: 0.3751 FC5: 0.6214 FC6: 0.6539
Mirar hacia la derecha	F7, T8, FC6, F8	F7: 0.6036 T8: 0.7821 F8: 0.9325 FC6: 0.8017
Mirar hacia la izquierda	F7, F8, FC6	F7: 0.5050 F8: 0.7268 FC6: 0.5516
Cerrar los ojos	AF3, F7, F8, AF4	AF3: 0.8397 F7: 0.8506 F8: 0.7701 AF4: 0.9353
Parpadeo	AF3, F7, F8, AF4	AF3: 0.7340 F7: 0.7172 F8: 0.5618 AF4: 0.7497

Tabla 3. Correlación de cada electrodo en su respectivo gesto facial

Con estos datos obtenido en la tabla 3 se hace un promedio total de las correlaciones obtenidas en todos los electrodos, con el fin de saber que electrodos tienen la peor y mejor correlación y cuantas veces es manifestado en cada acción grabada.

Electrodo	Número de veces manifestado	Resultado de correlación
AF3	2	0.78685
F7	6	0.69228
FC5	1	0.6214
T7	1	0.2591
T8	1	0.7821
FC6	3	0.6690
F8	6	0.68456
AF4	2	0.8425

Tabla 4. Correlación total de cada electrodo y el número de veces manifestado con respecto a cada gesto fácil y ocular

Reflejado en la Tabla 4, se puede observar que el electrodo T7 tiene la más baja correlación con respecto a los demás, y por lo tanto no será considerado para futuros análisis; en el caso de T8 y FC5 aunque tengan una buena correlación, estos electrodos solamente son manifestados en un gesto facial u ocular, y ya que no se realizó su análisis de convolución y correlaciones para los demás gestos faciales, su respuesta en otros gestos puede ser aleatoria y dañina para el siguiente análisis, y por esto estarán eliminados para la siguiente sección. Removiendo estos tres electrodos hace que el sistema sea más rápido y preciso para la caracterización, ya que serán menos datos de entrada; con los electrodos restantes (AF3, F7, FC6, F8, AF4) se hará la caracterización de los gestos faciales mediante máquinas de soporte vectorial.

7.3.2 Máquinas de soporte vectorial (SVM)

Para comprobar las características halladas en todos los gestos fáciles, se decidió hacer una clasificación de estos mediante máquinas de soporte vectorial, este método es uno de los más confiables en investigaciones relacionada con electroencefalograma o con cantidades grandes de datos.

Se comenzó en la realización de un algoritmo que tomara solamente los electrodos seleccionados en la sección anterior para cada gesto facial, estos electrodos son normalizados en un rango de -1 a 1 y son disminuidos en una cantidad menor de datos (1250 a 701), los resultados de cada electrodo son unidos en una misma fila para así crear un total de seis filas; estas filas se les colocó seis etiquetas de valores entre 1 hasta 6, las cuales simbolizan su gesto correspondiente. En la librería usada los autores especificaron que los datos de entrada deben estar en sparse, y por eso se transformó todas las filas en este formato. Se guardó el resultado del algoritmo en un nuevo archivo con el número de cada persona (S1, S2... S9) para realizar la clasificación correspondiente, el resultado de este algoritmo es mostrado a continuación en la Figura 50, en donde cada gráfica simboliza un gesto facial con sus cinco electrodos correspondientes.

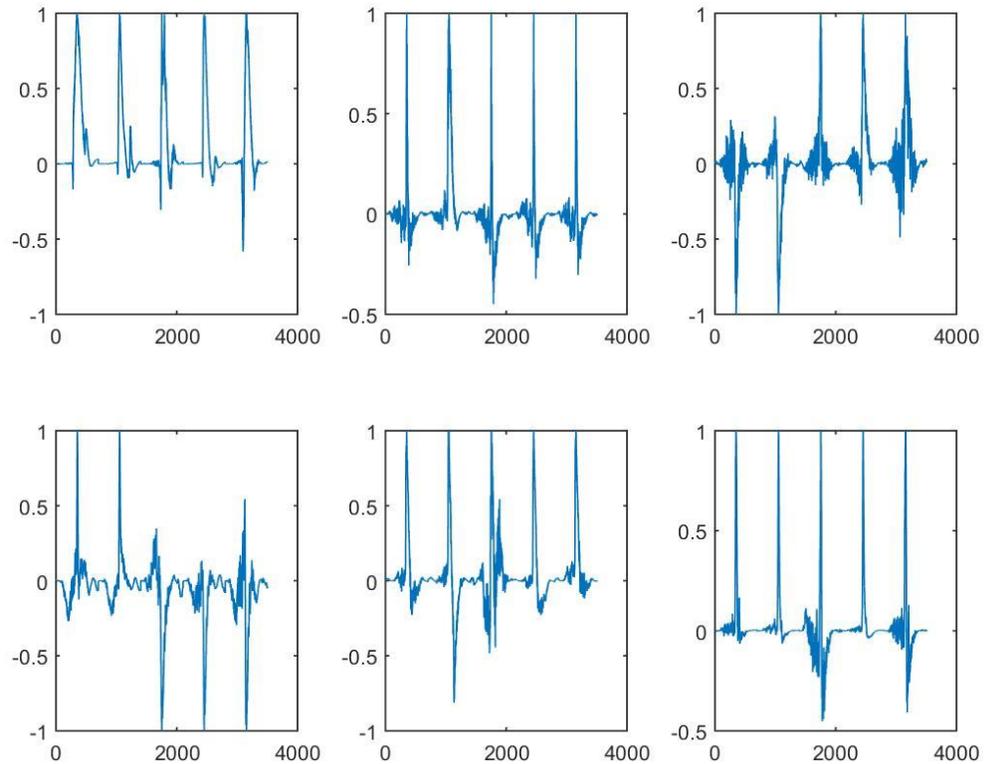


Figura 50. Electrodo normalizados y divididos en sus diferentes gestos faciales (S8)

Obteniendo los archivos de cada individuo, se realizó el proceso de validación cruzada mediante SVM, con un valor total de iteraciones de 9, ya que son nueve personas las cuales son evaluadas para esta investigación; explicado en el marco conceptual, hay diferentes núcleos que se pueden tomar para hacer la clasificación, en este caso ya que no se sabe con exactitud que núcleo es el mejor para estos tipos de datos, se tomó cada núcleo y se realizó su validación cruzada, para así usar el núcleo que mejor porcentaje obtenga. Algunos de estos núcleos dependen de valores independientes como C y γ , por lo tanto a cada núcleo se le realizó un barrido exponencial de estas dos variables ($C = 2^{-5}, 2^{-3}, \dots, 2^{15}$. $\gamma = 2^{-15}, 2^{-13}, \dots, 2^3$). El resultado de este proceso es mostrado a continuación en la Figura 48.

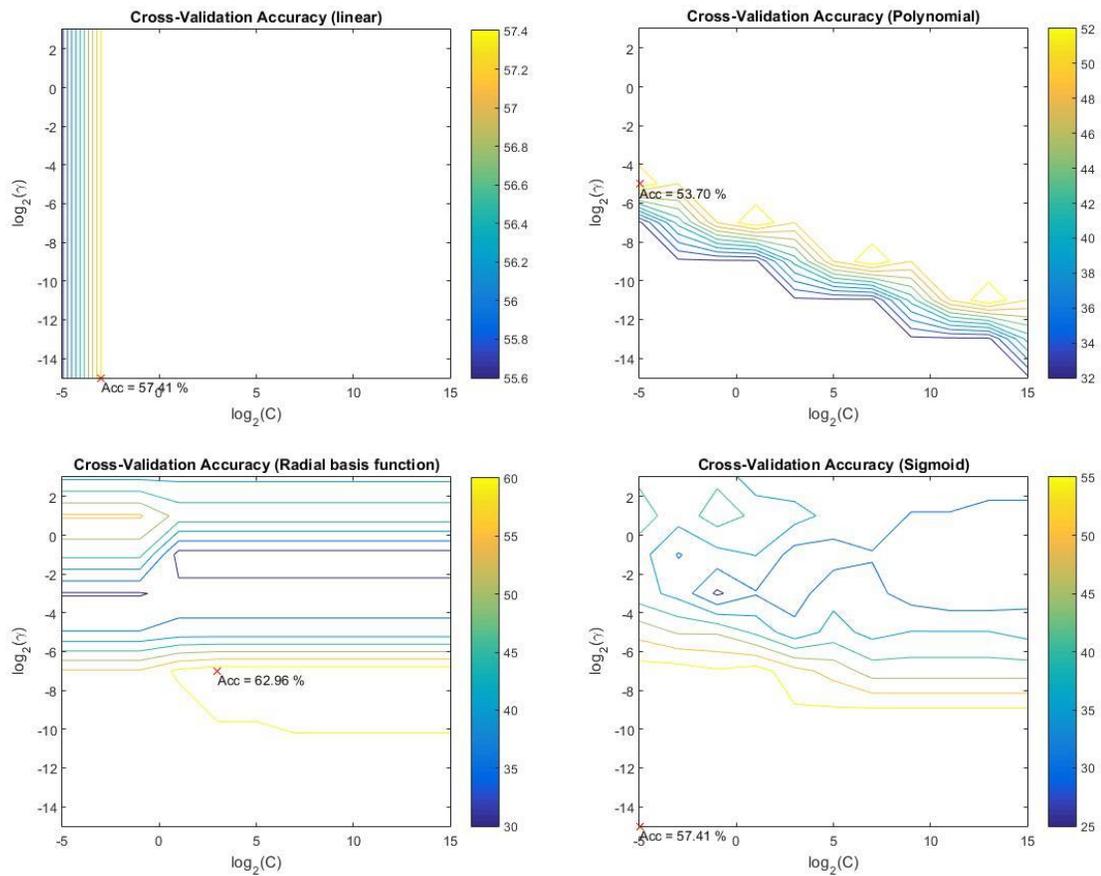


Figura 51. Validación cruzada con cada núcleo

Visto en la Figura 51, el núcleo que mejor porcentaje de clasificación obtuvo fue el de RBF, dado esto, se tomara este núcleo para los siguientes análisis. Se realizara nuevamente la validación cruzada con una red de búsqueda más fina, tomando los valores de la Figura 51, los mejores valores fueron $C = 3$ y $\gamma = -7$, por lo tanto se realizó el siguiente barrido exponencial de la siguiente manera: $C = 2^1, 2^{1.5}, \dots, 2^5$. $\gamma = 2^{-9}, 2^{-9.5}, \dots, 2^{-5}$, usando esta nueva red de búsqueda se obtuvo lo siguiente, mostrado en la Figura 52.

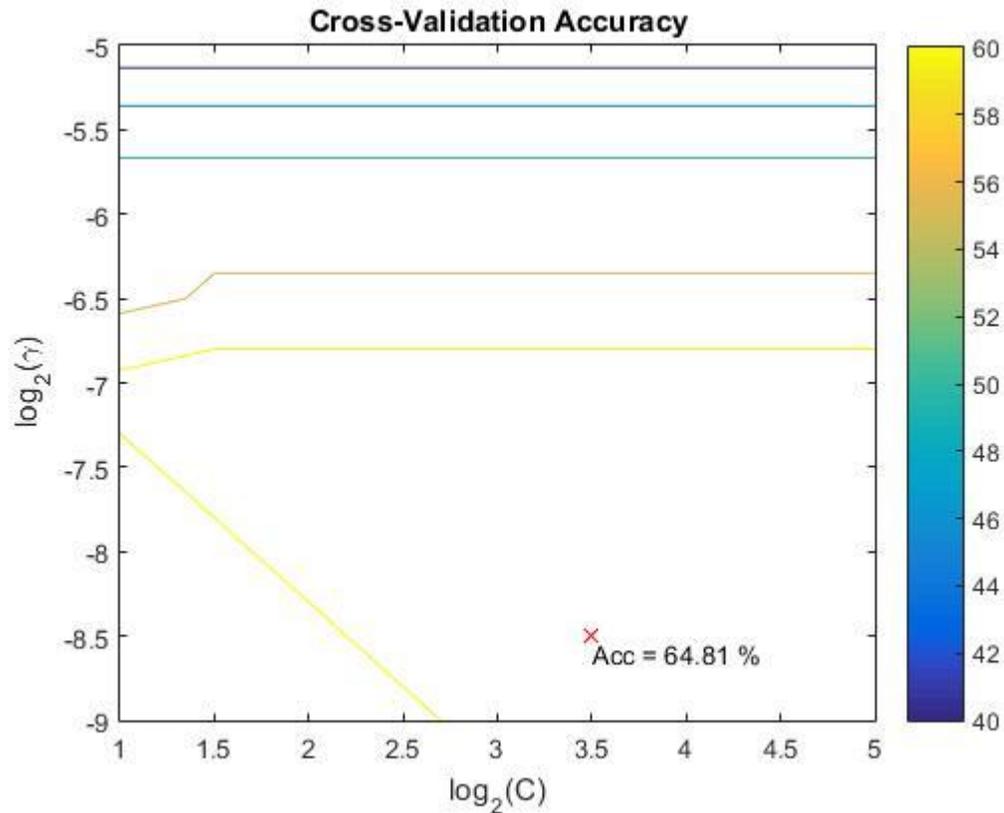


Figura 52. Validación cruzada con menor red de búsqueda

Usando una red de búsqueda más pequeña se observa que se incrementó el porcentaje de clasificación de 62.96% a 64.81%, este resultado dado indica que cuando hay una entrada diferente a la de la base de datos, este método clasificara de forma correcta estas características halladas en un 64.81%. Para saber las razones de porque la validación cruzada da este valor, se creó un algoritmo que hace lo mismo que esta función, pero en vez de mostrar el porcentaje promedio, se visualizó el porcentaje individual de cada sujeto. Se desea saber estos porcentajes individuales por diferentes razones, ya que en la base de datos usadas puede haber un gesto facial que no tiene coherencia, ya sea por la cantidad de electrodos usados o porque los resultados de un individuo puedan ser diferentes con el resto de la base de datos, también puede darse la posibilidad que algún sujeto en la base de datos tenga un porcentaje menor el cual puede corromper todo el sistema de clasificación, a continuación se mostrara en la Tabla 5 los resultados individuales de cada sujeto usado para la clasificación mediante validación cruzada.

Sujeto	Porcentaje de clasificación	Cantidad de gestos clasificados
--------	-----------------------------	---------------------------------

S1	50%	3
S2	50%	3
S3	100%	6
S4	16.6667%	1
S5	16.6667%	1
S6	100%	6
S7	83.3334%	5
S8	100%	6
S9	50%	3
Promedio	62.96%	3.77

Tabla 5. Porcentaje de clasificación de cada sujeto

Con los datos obtenidos en la Tabla 5, se demostró que los sujetos 4 y 5 tienen la menor cantidad de gestos clasificados, haciendo que estos resultados bajen notoriamente el porcentaje de clasificación de los gestos faciales. Para mejorar esta clasificación, se procede en eliminar a estos dos sujetos y se realiza la validación cruzada nuevamente, haciendo esto se muestra en la Figura 53 lo siguiente:

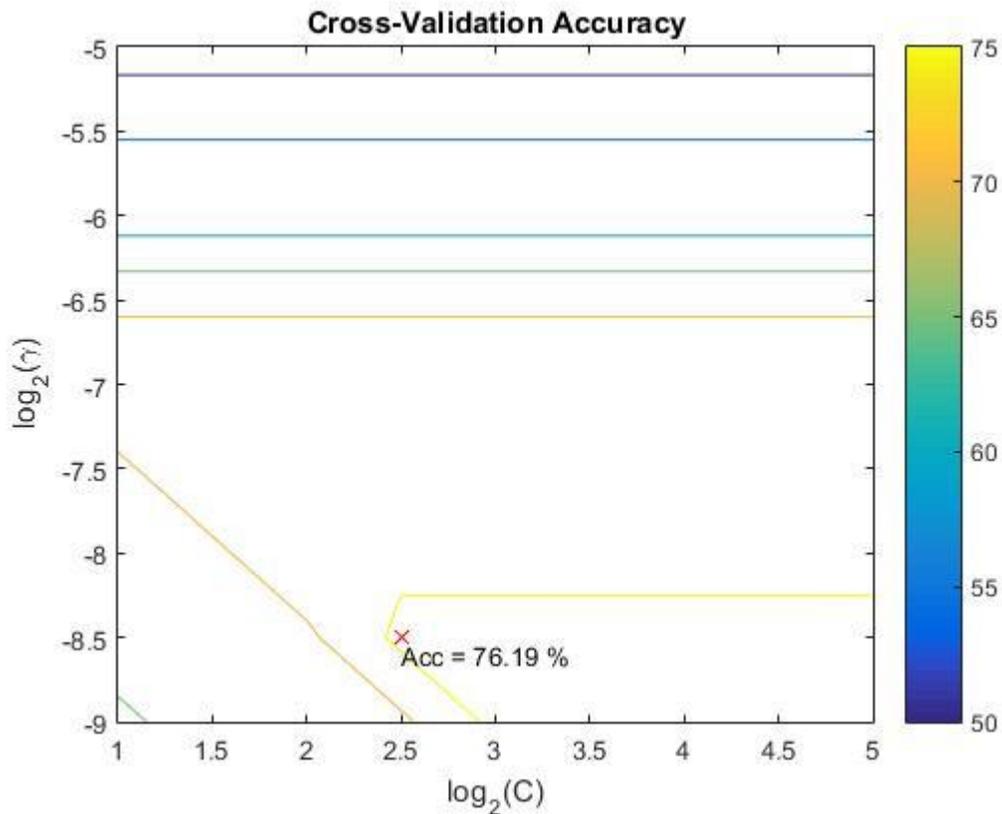


Figura 53. Validación cruzada resultante de la eliminación de S4 y S5

Eliminando a los sujetos S4 y S5 se obtuvo un incremento en la validación cruzada de 64.81% a 76.19%, obteniendo un incremento del 10.38%, un incremento sumamente importante ya que la validación cruzada nos certifica la clasificación de estas características con otros datos fuera de la base de datos. Se realiza el mismo procedimiento anterior y se saca el porcentaje individual de cada sujeto, para observar cuantos gestos son clasificados por cada persona.

Sujeto	Porcentaje de clasificación	Cantidad de gestos clasificados
S1	66.6667%	4
S2	50%	3
S3	100%	6
S6	83.3334%	5
S7	83.3334%	5
S8	83.3334%	5
S9	50%	3
Promedio	73.80%	4.42
S4	16.6667%	1
S5	16.6667%	1

Tabla 6. Porcentaje de clasificación de cada sujeto

Tomando los valores obtenidos en la tabla 5, se puede observar que solamente una persona pudo clasificar todos los gestos de manera correcta, los demás individuos obtuvieron una cantidad aceptable a comparación con la tabla anterior. Con estos resultados se desea mirar que acción es la más invariables de todas, para esto, se creó un algoritmo que verifica cuales gestos pudo clasificar todas las personas y cuáles no, los resultados serán observados en la siguiente tabla.

Gesto Facial	Cantidad de veces clasificado	Porcentaje de clasificación
Levante de la dos cejas	3	42.85%
Masticar	5	71.42%
Mirar hacia la derecha	7	100%
Mirar hacia la izquierda	5	71.42%
Cerrar los ojos	6	85.71%
Parpadeo	5	71.42%

Tabla 7. Porcentaje de clasificación de cada gesto facial

Mostrado en Tabla 7 se muestra la cantidad de veces que cada gesto fue clasificado con su porcentaje correspondiente, todos los gestos tienen un porcentaje de clasificación decente menos uno, el levantamiento de las dos cejas. Para observar que pasa con el sistema de validación cruzada se eliminara este gesto facial temporalmente de la base de datos y se entrenara el sistema solamente con estos cinco gestos, el resultado de validación cruzada seria el siguiente mostrado a continuación en la Figura 54.

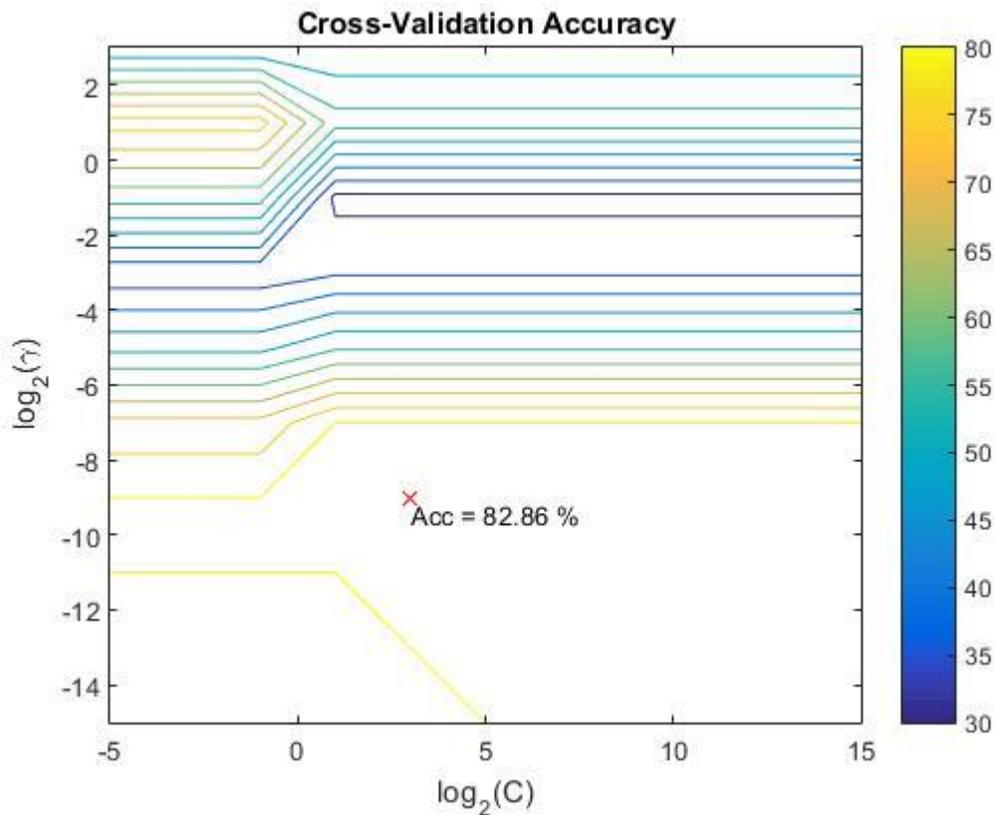


Figura 54. Validación cruzada sin un gesto facial

Se demostró que eliminando un gesto facial de la base de datos el porcentaje de clasificación se eleva un 6.67%, este porcentaje no es lo suficientemente decente para tenerlo en consideración, ya que el enfoque principal es la caracterización de todos los seis gestos faciales.

Seguido a esto, tomando los datos resultantes de la validación cruzada de las Figura 49 y Figura 50, se hace la prueba final con un entrenamiento SVM normal (sin validación cruzada); para hacer este proceso se tomaron los mejores parámetros obtenidos de C y gamma, se entrenó el sistema y luego

se hace la prueba correspondiente, este proceso es válido hacerlo ya que los resultados de estas dos constantes son los valores más adecuados para todo el conjunto de entrenamiento.

Sujeto	Porcentaje de clasificación (1)	Porcentaje de clasificación (2)
S1	100%	100%
S2	100%	100%
S3	100%	100%
S4	100%	16.6667%
S5	100%	33.3333%
S6	100%	100%
S7	100%	100%
S8	100%	100%
S9	100%	100%
Promedio	100%	83.333%

Tabla 8. Porcentaje de clasificación tomando con los C y gamma de la Figura49 (1) y Figura 50 (2)

Mostrado en la Tabla 8 se puede observar que tomando los valores obtenidos en la validación cruzada en un entrenamiento normal de SVM se obtiene un resultado del 100% con todas las nueve personas, en el segundo caso se observa que las personas S4 y S5 tiene porcentajes bajos, esto es debido a que las constantes C y gamma fueron entrenadas sin estos individuos; en el caso de S5 su porcentaje subió un 16.6667% a comparación de su resultado en la Tabla 5, esto significa que las dos constantes pudieron mejorar la clasificación correspondiente de la persona aunque no estuviera en el proceso de entrenamiento.

Finalmente, en la siguiente figura, se mostrará un gráfico con los resultados obtenidos en las Tablas 5,6 y 8, divididos en los resultados de la validación cruzada con la base de datos de nueve personas (VC1), los resultados de la validación cruzada con la base de datos disminuida (VC2) y el resultado del método de clasificación SVM con las constantes C y gamma de VC1.

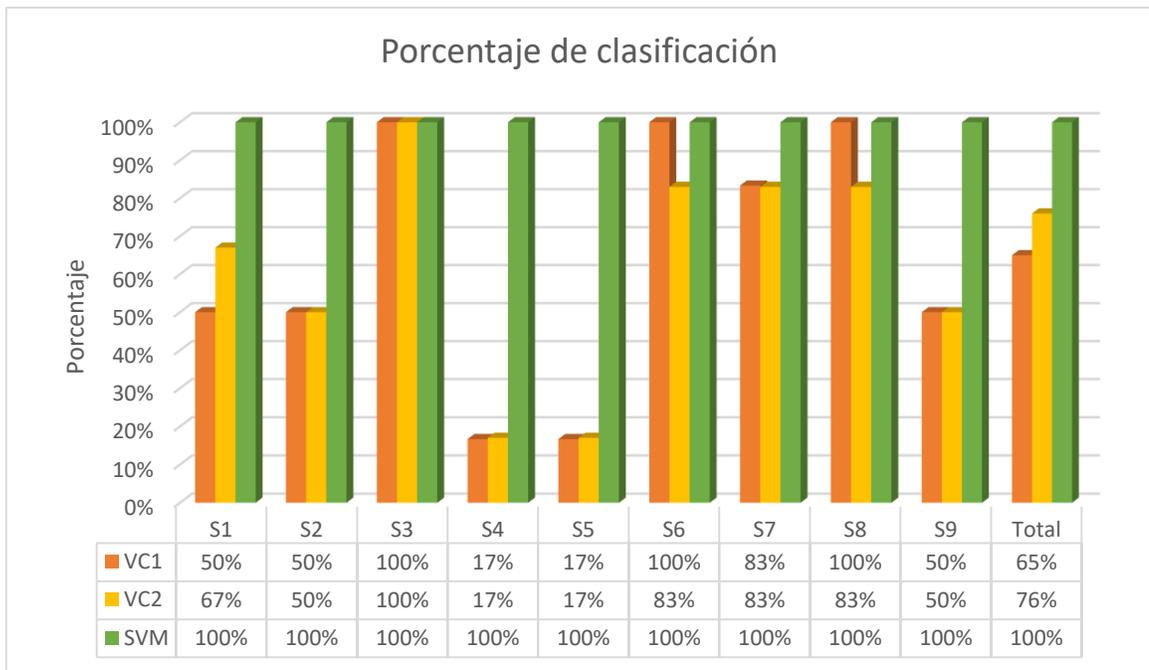


Figura 55. Gráfico de porcentajes de clasificación

Se puede observar en la Figura 55 que el entrenamiento mediante SVM da 100% en todos los casos (tono verde), debido a que los datos de prueba estuvieron en el entrenamiento de nuestro sistema, haciendo que el porcentaje de clasificación fuera perfecto. Por esta razón se quiso realizar el mismo procedimiento con validación cruzada, si en alguna otra ocasión se realiza la prueba de verificación con datos que no fueron suministrados en la fase de entrenamiento su clasificación puede ser una incógnita sin la utilización de este método; en este grafico se puede observar de mejor manera como afecto los datos de los individuos S4 y S5 en VC1 (tono naranja), ya que su porcentaje fue tan bajo a comparación de los demás sujetos de la base de datos fue razón suficiente para no tenerlos en cuenta en el entrenamiento de clasificación, así se pudo concluir que la clasificación de las características halladas en esta investigación fue mayor al 75% (tono amarillo) con una base de datos final de siete personas.

Conclusiones

En este trabajo de grado se pudo confirmar que mediante EEG se obtiene una opción viable para la medición de gestos fáciles y oculares, con la característica que los instrumentos utilizados en la toma de datos no fueron invasivos, son portátiles y fáciles de usar, a comparación de otros métodos descritos en el marco conceptual.

Se realizó el análisis de señales de la base de datos obtenida mediante diferentes tipos de procesamientos para poder observar las diferentes características de cada gesto facial y ocular, tales como amplitud, forma, potencia y frecuencia, para así obteniendo la mejor clasificación posible dependiendo de qué características fueron tomadas; se destacó que las señales en bruto tenían similitudes en el proceso de correlación y convolución observado en la Tabla 3 y 4 al contrario de los resultados obtenidos por FFT (Figura 64) y PSD (Figura 65), estos datos sirvieron solamente para diferenciar que electrodos tenían más cambio que otros, y así disminuir la cantidad usada para la clasificación.

Para futuros trabajos, es preferible hacer las mediciones con individuos que tengan el cabello corto, confirmado en el análisis de resultados, toda la base de datos de las mujeres tuvo valores de voltaje lo suficientemente bajos para no poder distinguir alguna diferencia de frecuencia y potencia, haciendo que la base de datos bajara considerablemente a lo largo del análisis de las señales medidas.

Se realizaron otras disminuciones en la base de datos a lo largo de la utilización del SVM para mirar cómo cambia los resultados de la validación cruzada, este método pudo clasificar correctamente las características halladas en este proyecto con un porcentaje máximo de 76%. Usando estos métodos se pudo saber que eran los problemas principales de esta investigación y como se pueden profundizar en trabajos a futuro. Estos problemas fueron los escasos de datos de entrada y falta de sesiones de grabación, para futuras clasificaciones se debe de tener una base de datos más amplias y si es posible diferentes sesiones de mediciones, ya que, algunas veces visto a lo largo de este documento, los valores pueden verse decentes visualmente en la grabación, pero al momento de usarlos pueden ser inservibles para su uso correspondiente.

Bibliografía

- [1] C. D. de I. Fundación Universidad Central (Bogotá, *Nómadas.*, núm. 26. Fundación Universidad Central, Departamento de Investigaciones, 2007.
- [2] E. Gervilla Herder, “VALORES DEL CUERPO EDUCANDO. ANTROPOLOGÍA DEL CUERPO Y EDUCACIÓN”, vol. 38, pp. 183–189, 2000.
- [3] A. Lecuyer, F. Lotte, R. B. Reilly, R. Leeb, M. Hirose, y M. Slater, “Brain-Computer Interfaces, Virtual Reality, and Videogames”, *Computer (Long. Beach. Calif.)*, vol. 41, núm. 10, pp. 66–72, oct. 2008.

- [4] J. Teijeiro Amador *et al.*, “Sistema automatizado de registro de la actividad eléctrica de estructuras profundas del sistema nervioso central”, *Neurocirugia*, vol. 7, núm. 3, pp. 171–180, ene. 1996.
- [5] M. E. Universidad de Buenos Aires. Facultad de Psicología. y D. G. Politis, *Anuario de investigaciones.*, vol. 18. Facultad de Psicología, UBA, Subsecretaría de Investigaciones, 2011.
- [6] S. M. Lay y D. A. Pizarro, “Robotic motion control with cognitive and facial detection via Emotiv EEG”, *INGENIARE - Rev. Chil. Ing.*, vol. 23, núm. 4, pp. 496–504, 2015.
- [7] B. Horwitz, “Relating fMRI and PET Signals to Neural Activity by Means of Large-Scale Neural Models”, *Neuroinformatics*, vol. 2, núm. 2, pp. 251–266, 2004.
- [8] E. A. Larsen y A. I. Wang, “Classification of EEG Signals in a Brain- Computer Interface System”, *Nor. Univ. Sci. Technol.*, núm. June, pp. 1–72, 2011.
- [9] P. Díaz, “Implicancias de las técnicas de medición de la actividad cerebral en la cognición: ¿El tiempo o el espacio?”, *Rev. Psicol.*, vol. 17, núm. 1, p. ág. 87-100, ene. 2008.
- [10] M. A. Vega y Marco A., *Polis revista de la Universidad Bolivariana.*, núm. 33. Univ, 2012.
- [11] Á. Universidad de La Sabana. y Universidad de La Sabana. Facultad de Enfermería y Rehabilitación., *Aquichan.*, vol. 4, núm. 1. Universidad de La Sabana, 2004.
- [12] C. Perris, “EEG techniques in the measurement of the severity of depressive syndromes.”, *Neuropsychobiology*, vol. 1, núm. 1, pp. 16–25, 1975.
- [13] F. Sherwani *et al.*, “Eye Blinking Activity”, 2015.
- [14] A. Reyes, “Interfaz Cerebro Computador Mediante la Clasificación de Señales Electroencefalográficas”, *PhD Propos.*, vol. 1, 2013.
- [15] J. S. Patrón, J. S. Patrón, y C. R. B. Monje, “Emotiv EPOC BCI with Python on a Raspberry pi”, *Sist. Telemática*, vol. 14, núm. 36, pp. 27–38, 2016.
- [16] “Controlling a Robot Using Brain Waves”, *2014 IEEE Int. Conf. Comput. Intell. Comput. Res.*, pp. 2–5, 2014.
- [17] “EPOC+ Headset Details · EPOC+”. [En línea]. Disponible en:

- https://emotiv.gitbooks.io/epoc-user-manual/content/epoc+_headset_details/. [Consultado: 04-jun-2018].
- [18] “NeuroHappiness: Hablemos del Cerebro”. [En línea]. Disponible en: <http://neurohappiness.blogspot.com/2014/12/hablemos-del-cerebro.html>. [Consultado: 04-jun-2018].
- [19] “Comprender FFTs y Funciones Ventana - National Instruments”. [En línea]. Disponible en: <http://www.ni.com/white-paper/4844/es/>. [Consultado: 04-jun-2018].
- [20] “Convolución, procesamiento de señales. | Rama Estudiantil del IEEE de la UCSA”. [En línea]. Disponible en: <https://ramaucsa.wordpress.com/2013/12/17/convolucion-procesamiento-de-senales/>. [Consultado: 04-jun-2018].
- [21] C.-W. Hsu, C.-C. Chang, y C.-J. Lin, “A Practical Guide to Support Vector Classification”, 2003.
- [22] B. Efron y R. Tibshirani, “Padres de cross-validation y el bootstrapping Bradley Efron y Rob Tibshirani”.
- [23] “Enfoque Cuantitativo – Fases del Proceso Cuantitativo”. [En línea]. Disponible en: <https://humanidades2osneideracevedo.wordpress.com/2015/05/28/enfoque-cuantitativo/>. [Consultado: 17-jun-2018].
- [24] “User Manual Table of Contents”, 2017.
- [25] E. EPOC, “Headset and software setup for your Emotiv EPOC neuroheadset”, *SpringerReference*, pp. 1–19, 2003.
- [26] “DC Offset · EmotivPRO”. [En línea]. Disponible en: https://emotiv.gitbooks.io/emotivpro/notes_on_the_data/dc_offset.html. [Consultado: 04-jun-2018].

Anexos

Código ejecutado para el análisis de señales EEG:

CSV_Filter.m

```

function [] = CSV_Filter()
datadir = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas Brutas\'; %Path to
get .CSV files
datafinal = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas Filtradas\';
%Path to save the edited .CSV files
delete(strcat(datafinal,'*')) %delete all old information
datafile = dir(fullfile(datadir,'*.csv')); %Data file name, location and information for
each .CSV files
data1 = 1250;
window = flattopwin(data1);
%wvtool(window)
for i=1:length(datafile)
    filename = fullfile(datadir,datafile(i).name); %Getting every single .CSV depending on
'i'
    M{i} = csvread(filename,1,0); %Reading the current .CSV file, except its first line
(useless data)
    data{i} = M{i}(1:data1,(3:16)); %taking only the electrodes information off the .CSV file
    %%%%% Offset Removal with Median Method
    for k = 1:14
        med(1,k) = median(data{i}(:,k)); % calculate median of each sample
        offset{i}(:,k) = data{i}(:,k) - med(:,k); % remove the offset of each sample
        offset{i}(:,k) = window.*offset{i}(:,k); %Flat window
    end
    csvwrite(strcat(datafinal,datafile(i).name),offset{i}) %writing the resulting file on
other folder
end
end
end

```

Entradas.m

```

root = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas Filtradas';
imgroot = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\Imagenes Electrodo';
imgrootsvm = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\Imagenes SVM';
datadirsvm = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas SVM\'; %Path to
save the edited .CSV files
LG = {'AF3', 'F7', 'F3', 'FC5', 'T7', 'P7', 'O1', 'O2', 'P8', 'T8', 'FC6', 'F4', 'F8',
'AF4'};
P = {'P1', 'P2', 'P3', 'P4', 'P5', 'P6', 'P7', 'P8', 'P9'};
fs = 128;

```

Individual_Graph.m

```

run Entradas.m
[fname, pname] = uigetfile('*.csv','select the file',root);
filename = fullfile(pname, fname);
MH = csvread(filename);

```

```

[f c] = size(MH);
%Plotting
F1 = figure('name', ['Electrodes' fname]);
for i = 1:c
    hold on
    maxi = max(MH(:,i));
    mini = min(MH(:,i));
    sp(i)= subplot(7,2,i);
    plot(MH(:,i));
    xlabel(['Min : ',num2str(mini),' Max : ',num2str(maxi)],'FontSize',8)
    ylabel('uV');
    legend(strcat(LG(i)));
end
M1 = max(max(MH)); M2 = min(min(MH));
set(sp, 'ylim', [M2 M1])
hold off
F2 = figure('name', fname);
subplot(2,1,1);
plot(MH, 'Linewidth', 1)
title('Electrodes Answer'); xlabel('Data taken'); ylabel('Microvolts (uV)'); legend(LG);
subplot(2,1,2);
boxplot(MH, 'Labels', LG)
title('Box Diagram'); xlabel('Electrodes'); ylabel('Microvolts range (uV)');
F3 = figure('name', fname);
plot(MH, 'Linewidth', 1)
title('Electrodes Answer'); xlabel('Data taken'); ylabel('Microvolts (uV)'); legend(LG);

```

FFT.m

```
function [ PSDfc, PSDT ] = FFT(MH)
```

```
run Entradas.m
```

```

[f c] = size(MH);
for i = 1:c
    spectrum = fft(MH(:,i))/f;
    spectrum = spectrum(1:f/2);
    spectrum = 2 * (sqrt(spectrum .* conj(spectrum))); % get magnitude
    fc(:,i) = (0:f/2-1)*fs/f;
    FFTE(:,i) = spectrum;
    PSD(:,i) = spectrum.*conj(spectrum)/f;
    PSDfc(:,i) = fc(1:80,i);
    PSDT(:,i) = PSD(1:80,i);
end

```

```

F1 = figure('name', 'FFT');
plot(fc, FFTE)
legend(strcat(LG));
title('FFT answer of all electrodes');
xlabel('Frequency (Hz)');
ylabel('|Y(f)|');

```

```

F2 = figure('name','PSD');
plot(PSDfc,PSDT)
Legend(strcat(LG));
title('Power spectral density');
xlabel('Frequency (Hz)');
ylabel('Power/Frequency (dB/Hz)');
Legend(strcat(LG));
F3 = figure('name','Boxplot');
boxplot(PSDT,'Labels',LG)
title('Box Diagram'); xlabel('Electrodes'); ylabel('Power/Frequency (dB/Hz)');

```

end

Comparing_Signals.m

```

clc; clear all; close all;
run Entradas.m
datadir = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas Filtradas\'; %Path
to save the edited .CSV files
datafile = dir(fullfile(datadir,'*Masticar.csv')); %Data file name, location and
information for each .CSV files
Electrode = input('Specify the Electrode... AF3:1 F7:2 F3:3 FC5:4 T7:5 P7:6 O1:7 O2:8 P8:9
T8:10 FC6:11 F4:12 F8:13 AF4:14 = ');
for i=1:length(datafile)
    filename = fullfile(datadir,datafile(i).name);
    M{i} = csvread(filename); %Reading the current .CSV file
    MH(:,i) = M{i}(1:1250,Electrode);
    maxi = max(MH(:,i));
    %MH(:,i) = MH(:,i)/maxi;
end
% %Plotting
figure(1)
for i=1:length(datafile)
    hold on
    subplot(7,2,i);
    plot(MH(:,i));
    maxi = max(MH(:,i));
    legend(strcat(P(i),'=',num2str(maxi)));
end
hold off
figure(2);
subplot(2,1,1);
plot(MH,'Linewidth',1)
title('Electrodes Answer'); xlabel('Number of data taken'); ylabel('Millivolts range
(mV)'); legend(P);
subplot(2,1,2);
boxplot(MH,'Labels',P)
title('Box Diagram'); xlabel('People'); ylabel('Microvolts (uV)');

```

Convolution.m

```
clc; clear all;
run Entradas.m
%[fname, pname] = uigetfile('*.csv','Select the file',root,'MultiSelect','on');
datadir = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas Filtradas\'; %Path
to save the edited .CSV files
datafile = dir(fullfile(datadir,'*Masticar.csv')); %Data file name, location and
information for each .CSV files
Electrode = input('Specify the Electrode... AF3:1 F7:2 F3:3 FC5:4 T7:5 P7:6 O1:7 O2:8 P8:9
T8:10 FC6:11 F4:12 F8:13 AF4:14 = ');
%%LevanteCeja: F7(2) =4,3, F8(13) = 8,2
%%Masticar: F7(2)=2,4, T7(5)=5,1, F8(13)=4,3, FC5(4)= 2,7 FC6(11) = 2,7
%%OjoDerecho: F7(2)=9,3, T8(10)=7,9, FC6(11)=3,9, F8=3,9
%%OjoIzquierdo: F7(2)=2,8, F8(13)=8,9, FC6(11)=8,7
%%OjosCerrados: AF3(1)=3,8, F7(2)=8,2, F8(13)=8,6, AF4(14)=8,3
%%Parpadear: AF3(1)=8,3, F7(2)=8,9, F8(13)=8,6, AF4(14)=8,6
T1 = input('From the list specify the best graph: ');
T2 = input('From the list specify the second best graph: ');
for i=1:length(datafile)
    filename = fullfile(datadir,datafile(i).name);
    M{i} = csvread(filename); %Reading the current .CSV file
    MH(:,i) = M{i}(1:1250,Electrode);
    result = max(abs(MH(:,i)));
    MH(:,i) = MH(:,i)/result;
    MHTemp = abs(MH(:,i));
    KM = find(MHTemp==max(MHTemp));
    G(:,i) = MH(KM-350:KM+350,i);
end
disp(length(datafile))
for i=1:length(datafile)
    G1 = G(:,T1);
    G2 = G(:,T2);
    %T3 = input('From the list specify the last graph (1, 2 , 3):');
    Gx = G(:,i);
    C1 = conv2(G1,G2);
    Cx = conv2(G1,Gx);
    % Correlation coefficient
    R = corrcoef(C1,Cx);
    RF(i) = R(1,2);
end
R = mean(RF)
```

SVM_Creator.m

```
function [ Answer ] = SVM_Creator()
datadir = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas Filtradas\'; %Path
```

```

to get .CSV files
datafinal = 'C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas SVM\'; %Path to
save the edited .CSV files
delete(strcat(datafinal, '*')) %delete all old information
datafile = dir(fullfile(datadir, '*.csv')); %Data file name, location and information for
each .CSV file
labelM = 1;
Person = 1;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
for i=1:length(datafile)
    filename = fullfile(datadir,datafile(i).name); %Getting every single .CSV depending on
    'i'
    M{i} = csvread(filename); %Reading the current .CSV file, except its first line
    (useless data)
    %AF3:1 F7:2 FC6:11 F8:13 AF4:14
    data{i} = M{i}(:, [1 2 11 13 14]); %taking only the electrodes information off the .CSV
    file
    datasize = size(data{i});
    % Normalization
    for j=1:datasize(2)
        result = max(abs(data{i}(:,j)));
        data{i}(:,j) = (data{i}(:,j)/result);
        dataTemp = abs(data{i}(:,j));

        Location_Max = find(dataTemp==max(dataTemp)); %Getting location of max value
        TData{i}(:,j) = data{i}(Location_Max-350:Location_Max+350,j); %Creating a new
        vector for F7

        FData = TData{i}(:,j);
        FDataT(j,:) =FData.';
    end

    %%%% SVM DATA
    [LD,CD] = size(FDataT); %Size for the reshape (depending entries)
    FDataF = reshape(FDataT.',1,LD*CD); %Reshaping the matrix to be on 1 row x columns
    labels = labelM(ones(1,1)); %Label matrix
    FTData{i} = [labels, FDataF]; %Rearranging the final matrix
    labelM = labelM + 1;
    if labelM == 7
        DSVM = cat(1,FTData{i-5:i}); %Getting the vectors of the accoding person
        libsvmwrite(strcat(datafinal, 'S', num2str(Person)), DSVM(:,1),
        sparse(DSVM(:,2:end))); %Creating the file of each person
        labelM = 1;
        Person = Person+1;
    end
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
DataM = zeros(6,LD*CD);
PersonT = Person-1;
for i=1:PersonT
    [label{i},data{i}] = libsvmread(strcat('C:\Users\Fenrir\Dropbox\Proyecto de
Grado\PruebasEPOC\Pruebas SVM\S',num2str(i)));
    dataT{i} =full(data{i});
    DataM = [DataM ; dataT{i}];
end
DataM = DataM(7:end,:);
labelF = cell2mat(label);
labelF = labelF(:);
DSVMF = [labelF, DataM];
libsvmwrite('C:\Users\Fenrir\Dropbox\Proyecto de Grado\PruebasEPOC\Pruebas SVM\SF',
DSVMF(:,1), sparse(DSVMF(:,2:end))));
end

```

SVM_CV.m

```

close all; clear all; clc; format short;
run Entradas.m
CSV_Filter;
SVM_Creator;
Num_People = 9;
Num_Actions = 6;
folds = Num_People;
%# grid of parameters
[labels,data] = libsvmread(fullfile(datadirsvm,'SF'));
%meshgrid(-5:2:15, -15:2:3); meshgrid(1:0.5:5, -9:0.5:-5);
[C,gamma] = meshgrid(1:0.5:5, -9:0.5:-5);
cv = zeros(numel(C),1);

for i=1:numel(C)
    cv(i) = svmtrain(labels, data, sprintf('-q -c %f -g %f -v %d', 2^C(i), 2^gamma(i),
folds));
end
%%%pair (C,gamma) with best accuracy
[~,idx] = max(cv);
best_C = 2^C(idx);
best_gamma = 2^gamma(idx);
%%%%%
for j=1:Num_People
    disp(strcat('Person_',num2str(j)))
    [labelst,datat] = libsvmread(fullfile(datadirsvm,strcat('S',num2str(j))));

model = svmtrain(labels,data,sprintf('-q -c %f -g %f', best_C, best_gamma));
svmpredict(labelst,datat,model);
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%
%%%%%%%%

```

```

## contour plot of paramter selection
contour(C, gamma, reshape(cv,size(C))), colorbar
hold on
plot(C(idx), gamma(idx), 'rx')
text(C(idx), gamma(idx), sprintf('Acc = %.2f %%',cv(idx)), 'HorizontalAlign','left',
'VerticalAlign','top')
hold off
xlabel('log_2(C)'), ylabel('log_2(\gamma)'), title('Cross-validation Accuracy')
disp('%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% ManualSVM %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%');
SVM_Manual(Num_People,Num_Actions,best_C ,best_gamma);

```

SVM_Manual.m

```

function [ Answer ] = SVM_Manual(Num_People,Num_Actions,best_C,best_gamma)
    run Entradas.m
    [labels,data] = libsvmread(fullfile(datadirsvm,'SF'));
    LS = size(labels); LC = LS-Num_Actions;
    DS = size(data); DC = DS/Num_People;
    labels=labels(1:LC);
    for k=1:Num_People
        if k == 1
            data_t= data((DC+1):end,:);
        elseif k == Num_People
            data_t= data(1:(DC*(k-1)),:);
        else
            data_t= data([1:(DC*(k-1)) (DC*k)+1]:end,:);
        end
        disp(strcat('Person_',num2str(k)))
        [labels_p,data_p] = libsvmread(fullfile(datadirsvm,strcat('S',num2str(k))));

        model_3{k} = svmtrain(labels,data_t,sprintf('-q -c %f -g %f', best_C, best_gamma));
        svmpredict(labels_p,data_p,model_3{k});
    end
    %%%% Actions test
    Person_Action = input('what data do you want to test?:');
    disp('%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%Action test%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%')
    disp(strcat('Person_',num2str(Person_Action)))
    [labels_pA,data_pA] =
    libsvmread(fullfile(datadirsvm,strcat('S',num2str(Person_Action))));
    for i=1:Num_Actions
        svmpredict(labels_pA(i),data_pA(i,:),model_3{Person_Action});
    end
end

```

Imágenes de varios resultados no mostrados en el analisis de resultado:

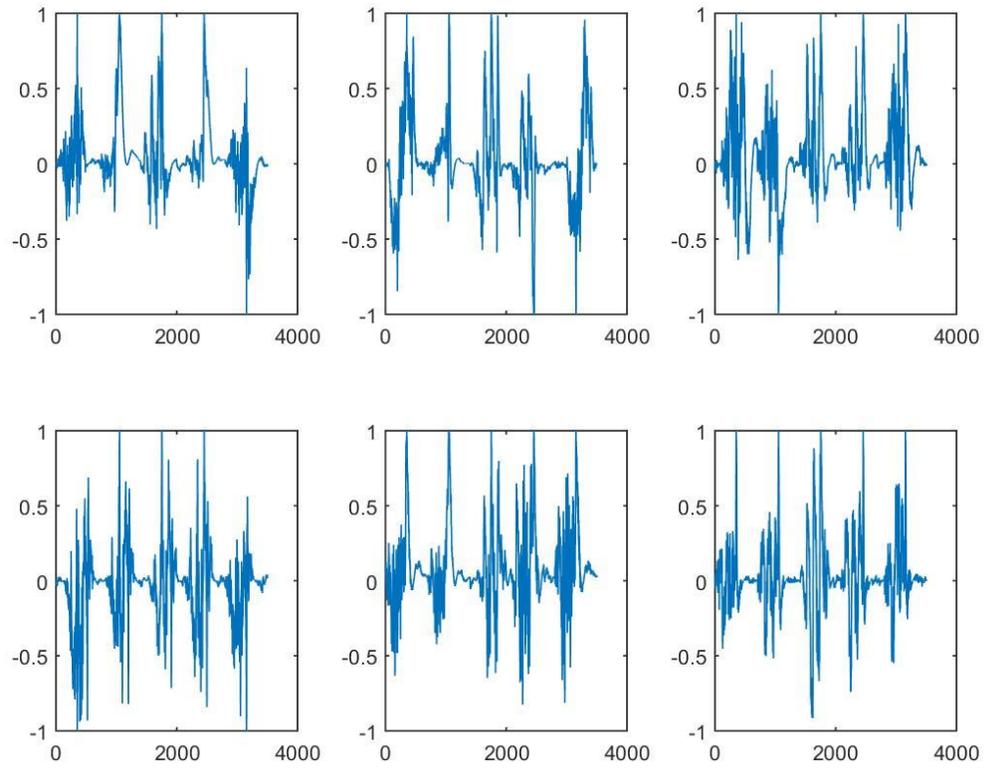


Figura 56. Electrodo normalizados y divididos en sus diferentes gestos faciales (S1)

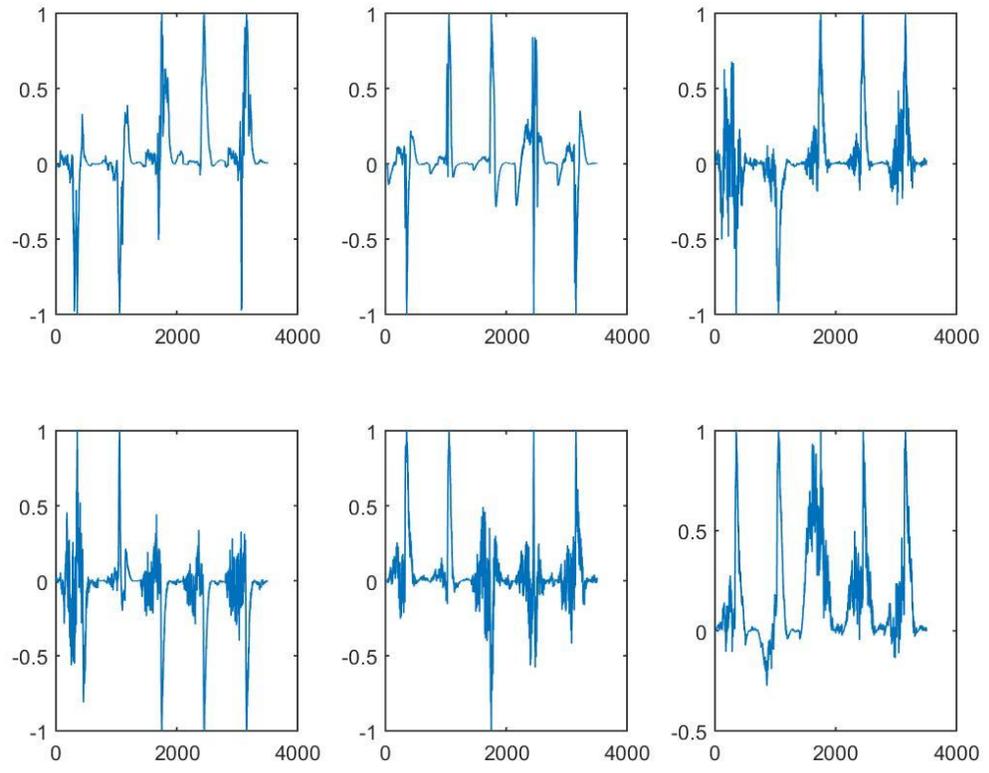


Figura 57. Electrodo normalizados y divididos en sus diferentes gestos faciales (S2)

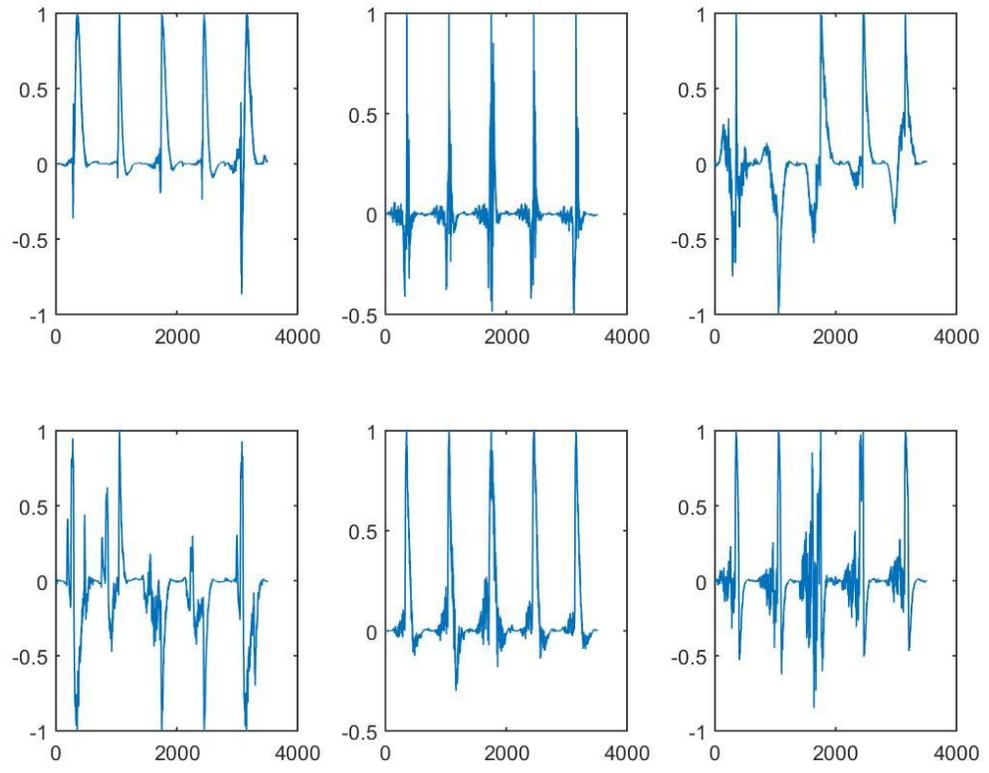


Figura 58. Electrodo normalizados y divididos en sus diferentes gestos faciales (S3)

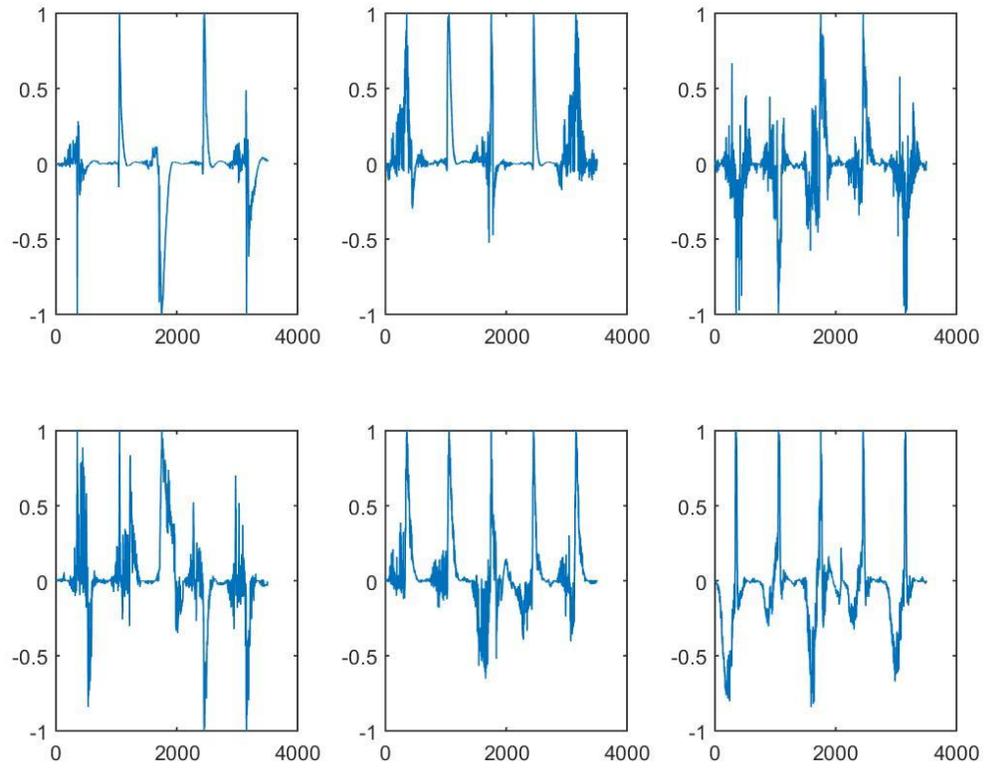


Figura 59. Electrodo normalizados y divididos en sus diferentes gestos faciales (S4)

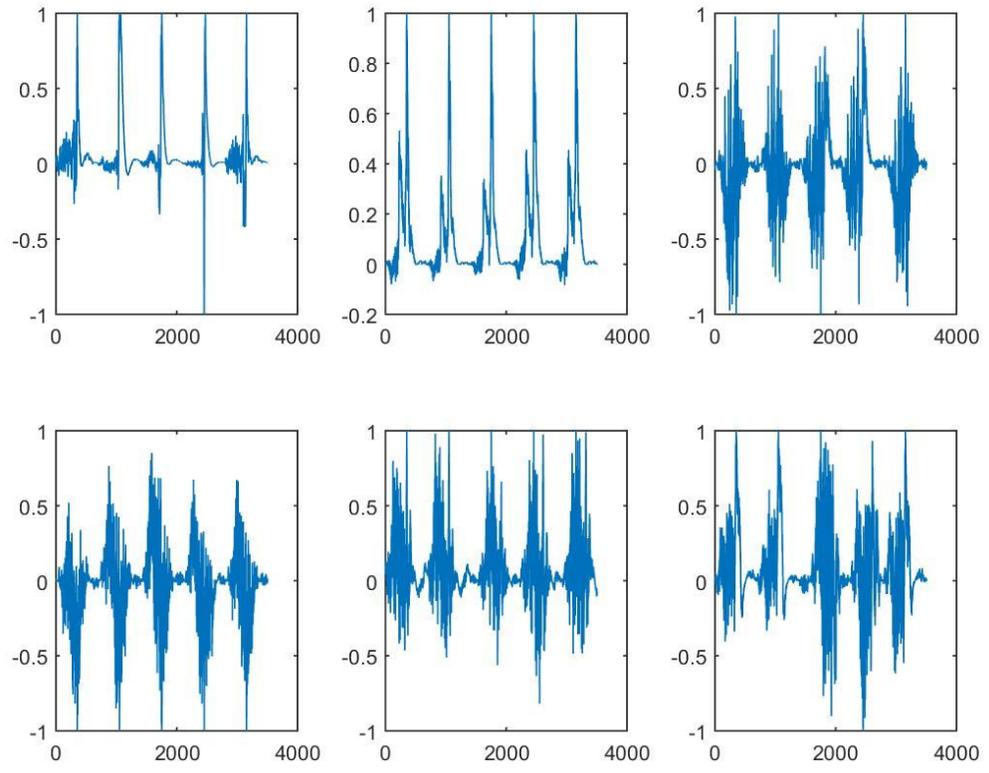


Figura 60. Electrodo normalizados y divididos en sus diferentes gestos faciales (S5)

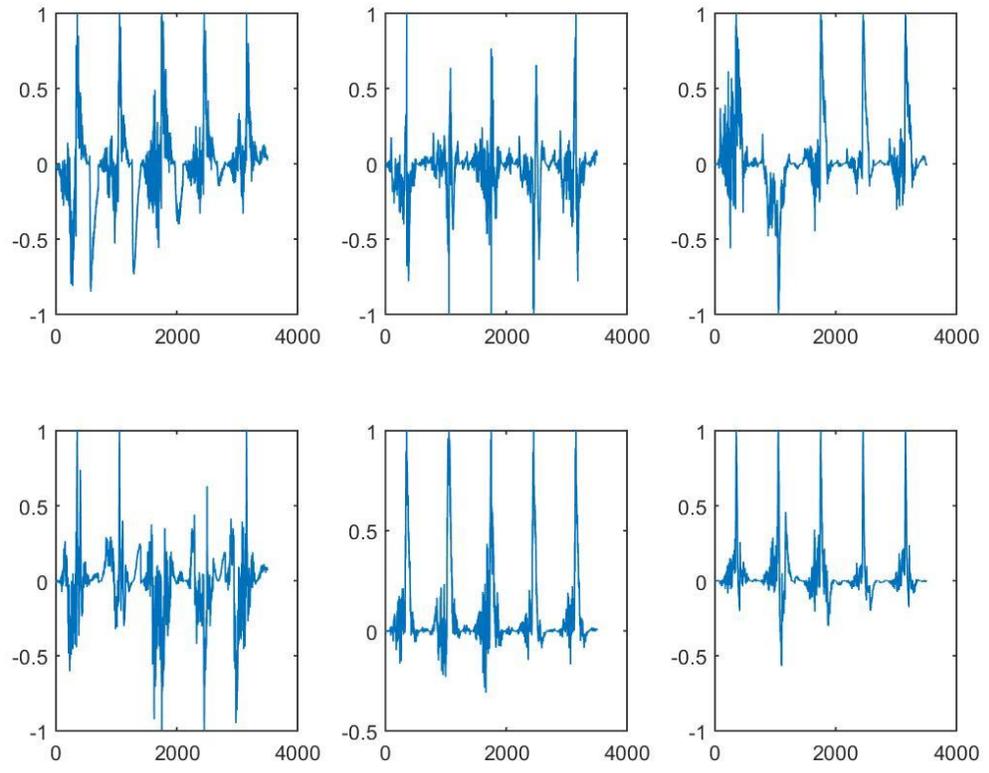


Figura 61. Electrodo normalizados y divididos en sus diferentes gestos faciales (S6)

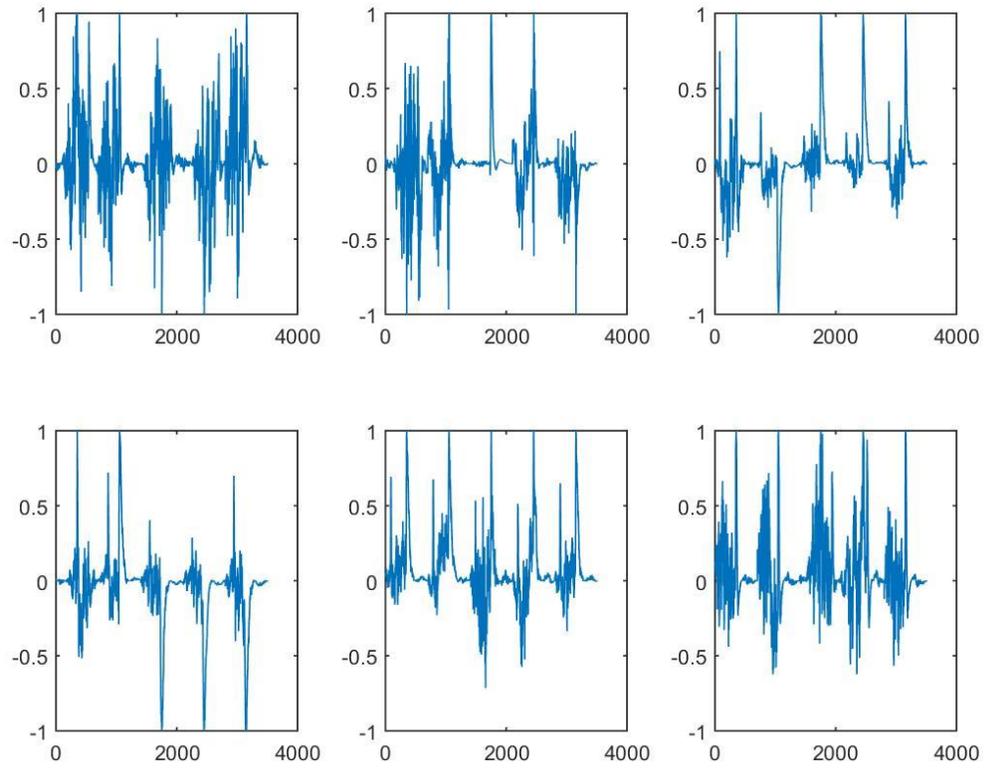


Figura 62. Electrodo normalizados y divididos en sus diferentes gestos faciales (S7)

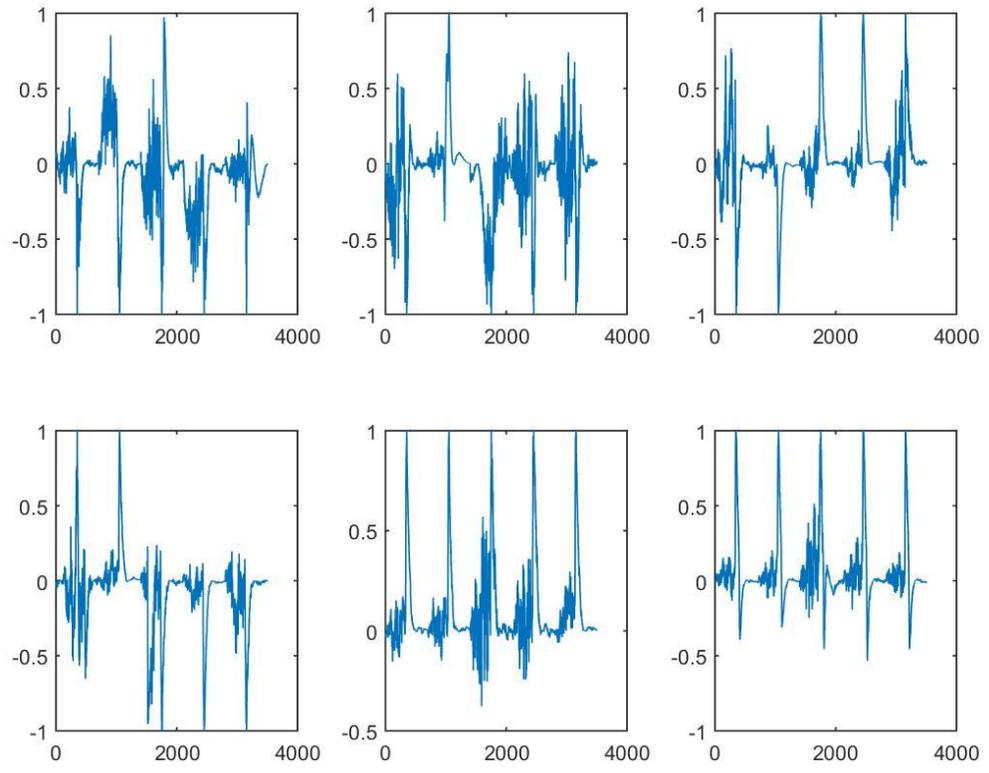


Figura 63. Electrodo normalizados y divididos en sus diferentes gestos faciales (S9)

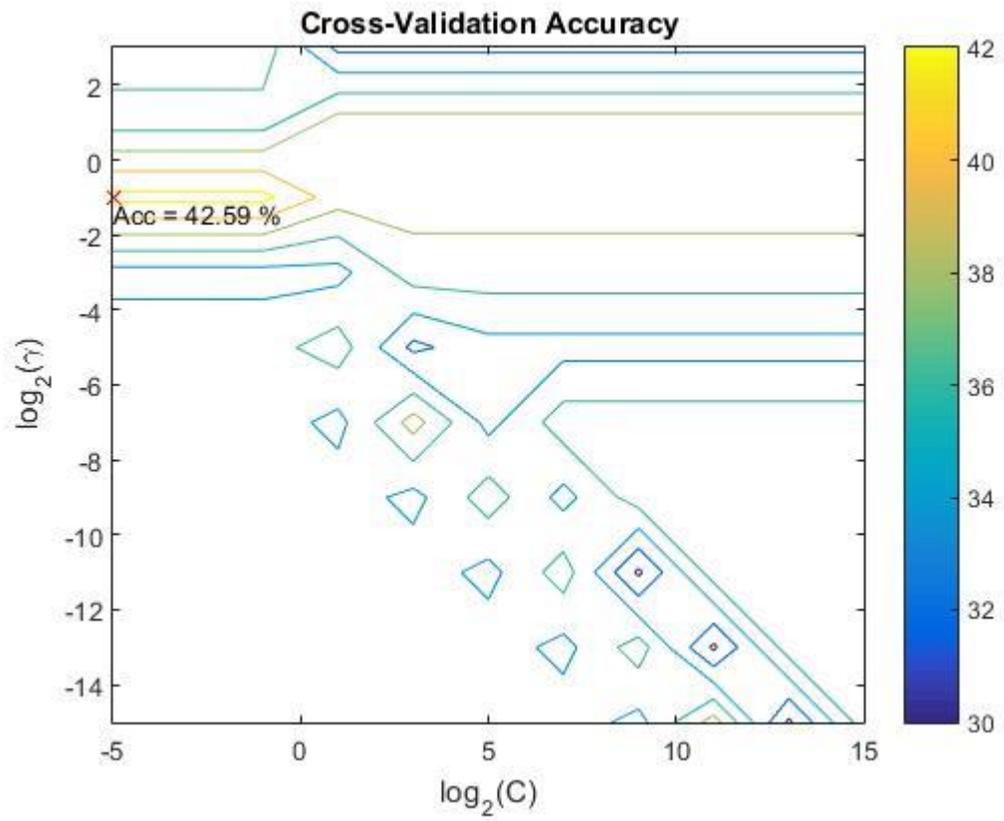


Figura 64. Validación cruzada con datos resultados de FFT

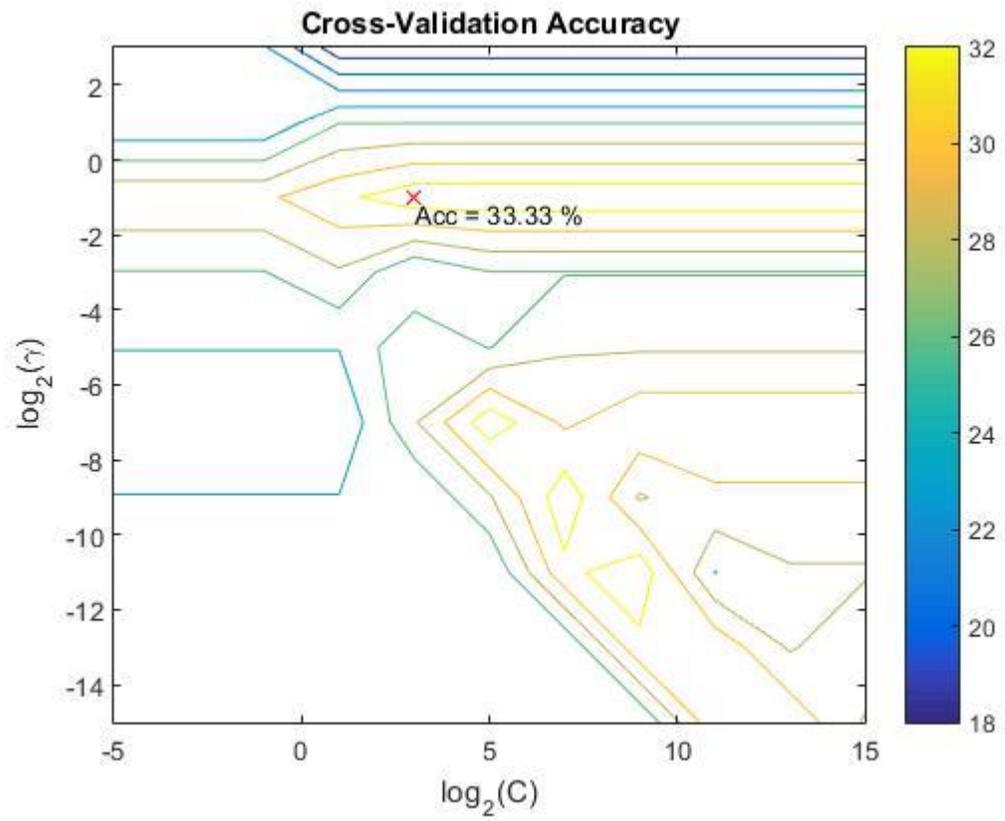


Figura 65. Validación cruzada con datos resultantes de PSD