



ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL
Facultad de Ingeniería en Electricidad y Computación

Procesamiento de señales EEG para la detección de la Intención motora de miembros inferiores en sujetos con parálisis cerebral

Tesis Doctoral

Previo a la obtención del título:

DOCTOR EN CIENCIAS COMPUTACIONALES APLICADAS

Presentado por:

Víctor Manuel Asanza Armijos

GUAYAQUIL – ECUADOR

Año: 2022

Director: Dr. Enrique Peláez

Co-Director: Dr. Francis Loayza

Dedicatoria

*A mi madre Zoila,
gracias a su ejemplo de sacrificio me ha permitido llegar lejos. Ella vive en mi memoria
y su amor en mi corazón.*

*A mi tío Abdón,
con su ejemplo de trabajo y esfuerzo me ha enseñado a ser mejor persona.
Gracias a su apoyo incondicional.*

*A mis hijos Jean, Misael y Angel,
por su amor y paciencia durante mis estudios.
Siempre me recuerdan las recompensas de ser padre.*

*A mi abuela y a mi esposa: Zoila y Verónica,
por su amor, sacrificio y paciencia en este viaje.*

Agradecimiento

*Quiero expresar mi agradecimiento a mis tutores,
el Dr. Enrique Peláez y el Dr. Francis Loayza,
por su sabia orientación durante mi trabajo de investigación.*

Tabla de Contenido

1	Capítulo 1: Introducción.....	16
1.1	Justificación.....	17
1.2	Contribución.....	19
1.3	Preguntas de investigación y objetivos.....	25
1.4	Objetivos	26
1.5	Organización del Documento.....	26
1.6	Bibliografía	32
2	Capítulo 2: Análisis del Estado del Arte	40
2.1	Electroencefalografía (EEG)	41
2.2	Bandas de frecuencia	42
2.3	Áreas del cerebro	43
2.4	Metodología Experimental	45
2.4.1	Movimientos activos.....	46
2.4.2	Imagenético Motor	48
2.4.3	Imagenético Motor – Movimientos Activos	49
2.4.4	Imagenético motor - Movimientos activos - Intentos de movimientos	50
2.4.5	Intenciones de Movimiento – Movimientos Activos	51
2.4.6	Movimientos Asistidos.....	52
2.4.7	Estimulación eléctrica de los miembros inferiores.....	52
2.5	Preprocesamiento de Datos	53
2.6	Extracción de Características	56
2.7	Algoritmos de Clasificación	59
2.8	Discusión	61
2.9	Conclusiones	64
2.10	Publicaciones	66
2.11	Bibliografía	66
3	Capítulo 3 RQ1: ¿Cómo se puede detectar el patrón de actividad motora cortical de los sujetos con PCI al realizar tareas de intención motora de las extremidades inferiores?	70
3.1	Detección de intenciones motoras en sujetos con PCI.....	70
3.1.1	Introducción.....	71

3.1.2	Objetivos	72
3.1.3	Estado del Arte.....	72
3.1.4	Metodología.....	74
3.1.4.1	Diseño Experimental	74
3.1.4.2	Recolección de Datos.....	75
3.1.4.3	Pre-procesamiento de Datos	75
3.1.4.4	Caracterización de Señales	76
3.1.4.5	Selección de Características.....	76
3.1.4.6	Clasificación.....	76
3.2	Metodología experimental para el registro de señales EEG.....	77
3.2.1	Antecedentes	78
3.2.2	Metodología.....	79
3.2.3	Equipamento.....	79
3.2.4	Consentimiento Informado.....	81
3.2.5	Metodología Experimental	82
3.2.5.1	Configuración del entorno y equipos.....	83
3.2.6	Descripción de los Datos.....	85
3.2.7	Información demográfica de los participantes	87
3.2.8	Notas de Usuario.....	88
3.2.8.1	Preparación del conjunto de datos en bruto	88
3.2.8.2	Pre-procesamiento del conjunto de datos en bruto	89
3.2.8.3	Extracción de características.....	89
3.2.8.4	Información estadística rms en el conjunto de datos de EEG	90
3.2.8.5	Selección de características	91
3.2.8.6	Clasificación de las tareas motrices e imaginarias.....	91
3.2.9	Resultados.....	92
3.2.10	Declaración de disponibilidad de datos	94
3.3	Conclusiones	94
3.4	Publicaciones	96
3.5	Bibliografía	96
4	Capítulo 4 RQ2: ¿Cómo podrían adaptarse los actuales algoritmos de caracterización utilizados en el EEG-BCI para extraer características adecuadas de las intenciones motoras de las extremidades inferiores?	103

4.1	Extracción de características basadas en densidad espectral en la detección de tareas motoras e imagenético motoras de señales EEG.....	104
4.1.1	Introducción.....	104
4.1.2	Trabajos relacionados.....	106
4.1.3	Dataset.....	106
4.1.4	Metodología.....	108
4.1.5	Análisis de los Resultados.....	113
4.2	Clasificación de señales SSVEP-EEG de la región occipital del cerebro.....	115
4.2.1	Introducción.....	115
4.2.2	Trabajos relacionados.....	117
4.2.2.1	Adquisición de señales SSVEP-EEG.....	117
4.2.2.2	Pre-procesamiento.....	117
4.2.2.3	Análisis de las señales SSVEP-EEG.....	118
4.2.2.4	Selección de características.....	118
4.2.2.5	Métodos de clasificación.....	118
4.2.3	Dataset.....	119
4.2.3.1	Organización del experimento.....	119
4.2.3.2	Dispositivo de adquisición de datos.....	120
4.2.3.3	Metodología experimental.....	121
4.2.3.4	Datos registrados.....	122
4.2.4	Metodología.....	123
4.2.4.1	Preprocesamiento de datos.....	124
4.2.4.2	Extracción de características.....	124
4.2.4.3	Configuración de la clasificación.....	125
4.2.5	Análisis de resultados.....	125
4.3	Etapas del procesamiento de señales EEG.....	128
4.3.1	Introducción.....	128
4.3.2	Metodología.....	129
4.3.3	Resultados.....	133
4.4	Control de una mano robótica empleando características temporales.....	138
4.4.1	Introducción.....	138
4.4.2	Metodología.....	140

4.4.2.1	Paciente:	140
4.4.2.2	Diseño mecánico y fabricación	140
4.4.2.3	Auricular EEG y señales neuronales.....	141
4.4.2.4	Interfaz Arduino y algoritmo de control	142
4.4.2.5	Implementación y conexión del cableado	143
4.4.3	Resultados.....	144
4.4.3.1	Análisis de los valores de atención	144
4.4.3.2	Par, fuerza de agarre y pérdidas en las articulaciones de los dedos	146
4.5	Detección de intenciones motoras en extremidades superiores basados en señales EMG	147
4.5.1	Introducción.....	147
4.5.2	Metodología.....	148
4.5.3	Resultados.....	154
4.6	Conclusiones	158
4.6.2	Clasificación de señales SSVEP-EEG de la región occipital del cerebro	159
4.6.3	Etapas del procesamiento de señales EEG	159
4.6.4	Control de una mano robótica empleando características temporales	160
4.6.5	Detección de intenciones motoras en extremidades superiores basados en señales EMG	161
4.7	Publicaciones	162
4.8	Bibliografía	163
5	Capítulo 5 RQ3: ¿Qué algoritmo de aprendizaje automático será eficaz para el análisis EEG-BCI en la detección de las intenciones motoras de las extremidades inferiores?.....	170
5.1	Clasificación de una tarea motora imaginaria y una tarea motora en extremidades inferiores..	171
5.1.1	Introducción.....	171
5.1.2	Trabajos relacionados	173
5.1.3	Base de datos	175
5.1.4	Metodología.....	177
5.1.5	Resultados y Discusiones	182
5.2	Detección de intenciones motoras de extremidades superiores e inferiores basado en combinación de algoritmos supervisados y no supervisados.....	184
5.2.1	Introducción.....	184
5.2.1.1	Trabajos relacionados	185
5.2.2	Materiales y métodos	186
5.2.2.1	EEG Dataset.....	186

5.2.2.2	Implementación del hardware.....	186
5.2.2.3	Estructura del sistema.....	188
5.2.2.4	Preprocesamiento de datos.....	189
5.2.3	Extracción de características.....	192
5.2.4	Clasificación.....	192
5.2.5	Control	193
5.2.6	Resultados y Discusiones	194
5.3	Algoritmos de clustering en la detección de tareas motoras e imagenético motoras de señales EEG	197
5.3.1	Introducción.....	197
5.3.2	Trabajos relacionados	198
5.3.3	Diseño del sistema implementado	199
5.3.3.1	Visión general del sistema	199
5.3.3.2	Adquisición de datos.....	200
5.3.3.3	Selección de características	201
5.3.3.4	Implementación de FPGA	203
5.3.3.5	Configuración del sistema.....	204
5.3.3.6	Clasificación.....	204
5.3.4	Evaluación del rendimiento	205
5.4	Clasificación de sujetos con enfermedad de Parkinson.....	210
5.4.1	Introducción.....	210
5.4.2	Trabajos relacionados	212
5.4.3	Conjunto de Datos	213
5.4.4	Metodología.....	215
5.4.4.1	Preprocesamiento de datos.....	215
5.4.4.2	Extracción de características.....	215
5.4.4.3	Algoritmo de clasificación	216
5.4.5	Resultados y Discusiones	219
5.5	Conclusiones	222
5.5.1	Clasificación de una tarea motora imaginaria y una tarea motora en extremidades inferiores	222
5.5.2	Detección de intensiones motoras de extremidades superiores e inferiores basado en combinación de algoritmos supervisados y no supervisados.....	223

5.5.3	Algoritmos de clustering en la detección de tareas motoras e imagenético motoras de señales EEG	223
5.5.4	Clasificación de sujetos con enfermedad de Parkinson.....	224
5.6	Publicaciones	225
5.7	Bibliografía	226
6	Capítulo 6: Conclusiones generales	232
6.1	Bibliografía	235

Figuras

Figura 1.5.1 Conexiones entre las preguntas de investigación y las publicaciones realizadas. [autoría propia].....	32
Figura 2.4.1 Dispositivos de adquisición de EEG utilizados en los trabajos revisados. Referencias bibliográficas asociadas: ETG-4000 [30], Neuroscan [31-34,43,44], BrainNet BNT 36 [47,48], Biotop 6 R-12 [35], BrainVision actiCHamp [36], ActiCap y dos amplificadores BrainAmp [37], amplificador NVX 52 [38], NuAmps [39], BrainBoard [40], NeXus-32 [41], BCI2000 [42] y amplificador Active Two [45,46]. Las imágenes que se muestran aquí están disponibles de forma gratuita en el sitio web oficial del fabricante/proveedor y se utilizan exclusivamente con fines académicos y sin ánimo de lucro. ETG-400: https://www.usa.philips.com/healthcare/resources/landing/fnirs ; Neuroscan, NuAmps: https://compumedicsneuroscan.com ; BrainNet BNT 36: https://www.emsamed.com.br ; BrainVision actiCHamp, ActiCap y dos amplificadores BrainAmp: https://brainvision.com ; amplificador NVX 52: https://mks.ru ; BrainBoard: https://github.com/gskelly/eeg ; Nexus-32: https://www.biofeedback-tech.com ; BCI2000: https://www.bci2000.org . Último acceso (a todos ellos): 10 de febrero de 2022). [autoría propia].....	46
Figura 2.4.7.1 Taxonomía de alto nivel y trabajos relacionados para las metodologías experimentales de adquisición de datos. Referencias bibliográficas asociadas: movimientos activos [35,36,39,45,49], imagenético motor [32,33,37,41,50,51], imagenético motor-movimientos activos [34,38,40,42], imagenético motor -movimientos activos-intentos de movimientos [44], intención de movimiento-movimientos activos [30,46-48], movimientos asistidos [31], y estimulación eléctrica de miembros inferiores [43]. [autoría propia].....	53
Figura 2.5.1 Taxonomía de alto nivel y trabajos relacionados con el preprocesamiento de datos. Referencias bibliográficas asociadas: filtro butterworth [42,45-47], filtro paso-bajo [30,43], filtro notch [31,37,47], filtro paso-banda [32-35,38-40], y filtro espacial [36,44]. [autoría propia].....	56
Figura 2.6.1 Taxonomía de alto nivel y trabajos relacionados para la extracción de características. Referencias bibliográficas asociadas: dominio del tiempo [44], basado en ERD/ERS [31,40], basado en banco de filtros [32,38], basado en análisis de potencia [30,34,37,39,41-43,46], y basado en análisis de correlación [33,35,36,45,47,48]. [autoría propia].....	59
Figura 2.7.1 Taxonomía de alto nivel y trabajos relacionados con los algoritmos de clasificación. Referencias bibliográficas asociadas: clasificador bayesiano [41,45], SVM [32,33,36,44], bosque aleatorio [46], LDA [30,38,40,47,48,] y NN [34,42]. [autoría propia].....	61
Figura 2.8.1 Diagrama de flujo conjunto que resume los tipos de tareas y algoritmos que se han utilizado en cada etapa. Referencias bibliográficas asociadas por tarea: Metodología experimental: movimientos activos [35,36,39,45,49], imaginería motora [32,33,37,41,49,50], imaginería motora-movimientos activos [34,38,40,42], imaginería motora-movimientos activos-intentos de movimiento [44], intención de movimiento-movimientos activos [30,45-47], movimientos asistidos [31], y estimulación eléctrica de miembros inferiores [43]; Preprocesamiento de datos: filtro pasa-banda [32-35,38-40], filtro butterworth [42,45,46,48], filtro espacial [36,44], filtro notch [31,37,45], y filtro pasa-bajos [30,43]; Extracción de características: basada en banco de filtros [32,38], basada en ERD/ERS [31,40], basada en análisis de correlación [33,35,36,45,47,48], basada en análisis de potencia [30,34,37,39,41-43,46], y en el dominio	

del tiempo [44]; Clasificación: LDA [30,38,40,47,48], SVM [32,33,36,44], clasificador bayesiano [41,45], bosque aleatorio [46] y NN [34,42]. [autoría propia]	62
Figura 3.2.3.1 A la izquierda el casco y a la derecha la tarjeta electrónica Cyton y Dasy de OpenBCI. [autoría propia].....	80
Figura 3.2.3.2 Sistema completo de adquisición de señales EEG en tiempo real para miembros superiores e inferiores. [autoría propia].....	81
Figura 3.2.5.1.1 Configuración del Experimento. [autoría propia]	84
Figura 3.2.5.1.2 Estímulos visuales utilizados durante el experimento. [autoría propia]	84
Figura 3.2.8.2.1 Gráfico de los datos de EEG sin procesar (a) y de los datos de EEG normalizados (b), del sujeto 3 y de la tarea 8 (Descanso). [autoría propia].....	89
Figura 3.2.8.3.1 Gráfico de extracción de características de 2976 archivos, consolidados en un solo archivo llamado "allData" de 2976 ejemplos por 16 características y una etiqueta. [autoría propia]	90
Figura 3.2.8.4.1 Gráfico de estadísticas determinadas de las características RMS desde el electrodo 1 analizados en el archivo allData. [autoría propia]	90
Figura 3.2.8.5.1 Matriz de correlación para determinar los electrodos características redundantes. [autoría propia].....	91
Figura 4.1.3.1 Artefacto de DC presente en los 64 electrodos del EEG de la tarea motora imaginaria. [autoría propia]	108
Figura 4.1.4.1 Distribución de 64 electrodos de superficie. [autoría propia].....	109
Figura 4.1.4.2 84 características en la tarea motora imaginaria ambas manos. [autoría propia].....	110
Figura 4.1.4.3 Algoritmo K-means, con nueve centroides. [autoría propia]	110
Figura 4.1.4.4 Algoritmo K-medoids, con nueve centroides. [autoría propia]	111
Figura 4.1.4.5 Cálculo de la distancia EPS óptima para DBSCAN con distancia mínima = 9. [autoría propia]	111
Figura 4.1.4.6 Resultados del clustering con DBSCAN. [autoría propia].....	112
Figura 4.1.4.7 Resultados del algoritmo Clustering espectral. [autoría propia]	112
Figura 4.1.4.8 Resultados de Clustering Jerárquico. [autoría propia].....	113
Figura 4.1.5.1 Frequency analysis with the FFT of the filtered EEG signals. [autoría propia]	113
Figura 4.1.5.2 Explorar el número óptimo de cluster para todo el algoritmo de cluster. [autoría propia]	114
Figura 4.1.5.3 Porcentaje de éxito de todos los algoritmos de agrupación. [autoría propia]	115
Figura 4.2.3.1.1 Puesta en marcha durante la adquisición de datos. [autoría propia]	120
Figura 4.2.3.2.1 Disposición de los electrodos Emotiv Epoc. [autoría propia]	120
Figura 4.2.3.4.1 Estímulos visuales utilizados durante el experimento. [autoría propia]	122
Figura 4.2.3.4.2 Estructura de los códigos utilizados en el proceso de adquisición. [autoría propia]	123
Figura 4.3.2.1 Estímulos visuales generados por una pantalla con LEDs utilizados para adquirir las señales de EEG occipital. [autoría propia]	130
Figura 4.3.2.2 Distribución de los 2 electrodos occipitales Equipo Emotiv. [autoría propia].....	131
Figura 4.3.2.3 Artefactos de corriente continua presentes en las señales del EEG occipital estímulo visual de 5 Hz. [autoría propia]	131
Figura 4.3.2.4 a) Histograma de la señal de EEG sin preprocesamiento para el área occipital con un estímulo visual de 5 Hz. b) Comparación entre la distribución de los datos adquiridos del EEG frente a los datos de una distribución normal. [autoría propia]	132

Figura 4.3.2.5 Un análisis de la frecuencia FFT de la señal de EEG. [autoría propia]	133
Figura 4.3.3.1 Señal de EEG sin artefactos de DC en los 2 electrodos del área occipital occipital. [autoría propia].....	134
Figura 4.3.3.2 Análisis de la frecuencia filtrada con la FFT de las señales de EEG. [autoría propia]	134
Figura 4.3.3.3 a) Histograma de la señal de EEG con preprocesamiento al área occipital con estímulo visual de 5Hz. b) Comparación entre la distribución de los datos adquiridos del EEG frente a los datos de una distribución normal. [autoría propia]	135
Figura 4.3.3.4 SS vs k clusters. [autoría propia]	136
Figura 4.3.3.5 Señales de EEG en el rango de frecuencia de 5 a 9 Hz (cluster 1) y en el rango de 24 a 29 Hz (cluster 2). [autoría propia].....	137
Figura 4.4.2.2.1 La parte izquierda muestra el diseño de la prótesis realizado con Blender. La derecha muestra el dispositivo impreso en 3D, incluidos los servomotores. [autoría propia].....	141
Figura 4.4.2.3.1 Ubicación del sensor Neurosky en la región Frontopolar uno y virtual en el oído izquierdo en el Sistema 10-20 EEG. [autoría propia]	142
Figura 4.4.2.4.1 Diagrama de flujo general del algoritmo de programación. [autoría propia]	143
Figura 4.4.2.5.1 Esquema general de conexión. A. Dispositivo Neurosky sobre la cabeza. B. Módulo Bluetooth HC-05. C. Baterías de 5 [V]. D. Arduino Micro. E. Servomotores. F. Borrador de mano. [autoría propia].....	144
Figura 4.4.3.1.1 Paciente con la prótesis y el dispositivo Neurosky. [autoría propia].....	146
Figura 4.4.3.2.1 Fuerza de transmisión a los dedos a través del hilo de nylon, el servomotor emite un par específico de 8,5 Kgf por cm. [autoría propia].....	146
Figura 4.5.2.1 Reproducción del gesto de la mano a los estímulos visuales utilizados para adquirir las señales EMG. Procedimiento también descrito en [84].	149
Figura 4.5.2.2 Distribución de treinta y dos electrodos de superficie alrededor del músculo digitorum communis. Los electrodos denominados A6 y D6 se utilizaron como referencia a tierra [84]......	150
Figura 4.5.2.3 Artefactos de DC presentes en los treinta electrodos de la señal EMG para la letra A. [autoría propia].....	151
Figura 4.5.2.4 Histograma de las señales EMG sin preprocesamiento. [autoría propia]	152
Figura 4.5.2.5 Análisis de frecuencias utilizando la FFT de señales EMG con ruido componentes de ruido. [autoría propia]	152
Figura 4.5.2.6 Ganancia del filtro Butterworth para la frecuencia de la raba de 7Hz a 20Hz. [autoría propia]	153
Figura 4.5.3.1 Señal EMG sin artefactos de DC presentes en los treinta electrodos de una letra A. [autoría propia].....	155
Figura 4.5.3.2 Frequency analysis of the filtered EMG signals using FFT. [autoría propia]	155
Figura 4.5.3.3 Histograma de las señales EMG filtradas con distribución normal. [autoría propia]	156
Figura 4.5.3.4 Evaluación del algoritmo K-means con nueve centroides. [autoría propia].....	157
Figura 4.5.3.5 Evaluación del algoritmo DBSCAN. [autoría propia]	157
Figura 4.5.3.6 Evaluación del algoritmo de clustering jerárquico. [autoría propia]	158
Figura 5.1.1.1 Gráfico de los componentes que integran las tarjetas de desarrollo genéricas basadas en FPGA SoC. [autoría propia]	172
Figura 5.1.3.1 Distribución y análisis espectral de 64 electrodos de superficie vistos en el sistema internacional 10/10. [autoría propia]	176

Figura 5.1.3.2 El archivo de actividad motora de ambos pies (ME2) contiene 4.599 filas o muestras x 64 columnas o electrodos EEG de superficie. [autoría propia]	177
Figura 5.1.4.1 Representación en el dominio del tiempo de 4.599 muestras de la señal EEG de la actividad motora de ambos pies (ME2). [autoría propia]	177
Figura 5.1.4.2 Estimación de la densidad espectral de potencia del periodograma de la señal EEG de la actividad motora de ambos pies (ME2). [autoría propia].....	178
Figura 5.1.4.3 Estimación del periodograma de la densidad espectral de potencia, tras el filtro de paso de banda de la señal EEG correspondiente a la actividad motora de ambos pies (ME2). [autoría propia] ..	179
Figura 5.1.4.4 Diagrama de la función de reconocimiento de patrones de las NN en Simulink. [autoría propia].....	180
Figura 5.1.4.5 Diagrama de bloques del procesamiento de datos en la FPGA. [autoría propia].....	181
Figura 5.1.5.1 Matriz de confusión de la clasificación de todos los eventos. [autoría propia]	182
Figura 5.1.5.2 Características operativas del receptor de la clasificación de todos los eventos. [autoría propia].....	183
Figura 5.2.2.2.1 Mano robótica en 3D y movimientos programados en la mano robótica relacionados con las intenciones de los motores M1 y M2 descritas en la sección 2.3. [autoría propia].....	187
Figura 5.2.2.2.2 Descripción del SoC utilizado para la interconexión de los elementos de hardware. [autoría propia].....	188
Figura 5.2.2.3.1 Estructura del sistema BCI de enfoque en línea. [autoría propia].....	189
Figura 5.2.2.4.1 Arquitectura de aprendizaje no supervisado para la selección de los electrodos y señales significativas con PCA. [autoría propia]	190
Figura 5.2.2.4.2 Espectrograma 3D de cada una de las tareas ejecutadas durante 4,1s (656 muestras). [autoría propia]	191
Figura 5.2.6.1 Asignación de clusters y centros para PS y Rs signos. [autoría propia]	194
Figura 5.2.6.2 Matriz de confusión de prueba. Matriz de confusión de prueba. [autoría propia]	195
Figura 5.2.6.3 Electrodo utilizados en la intención motora M1 y M2. [autoría propia].....	196
Figura 5.3.3.2.1 Sistema digital propuesto, utilizando MYO y un dispositivo portátil. [autoría propia] ..	200
Figura 5.3.3.2.2 Datos de EMG de la señal de mano de la letra "L". [autoría propia].....	201
Figura 5.3.3.3.1 Valores del sensor de señal de mano de la letra "B". [autoría propia].....	202
Figura 5.3.3.3.2 Forma de onda de múltiples puntos de la letra "B". [autoría propia]	203
Figura 5.3.4.1 Gestos entrenados basados en Lenguaje de Señas Americano (ASL). [autoría propia]	205
Figura 5.3.4.2 Representación de los datos: Los gestos G se entrenan utilizando $N \in$ muestras de RS. [autoría propia]	206
Figura 5.3.4.3 Precisión utilizando 5 características. [autoría propia].....	207
Figura 5.3.4.4 Precisión utilizando el esquema propuesto basado en características RMS. [autoría propia]	208
Figura 5.3.4.5 Número de puntos no clasificables utilizando $K = 2$. [autoría propia].....	209
Figura 5.3.4.6 Número de puntos no clasificables utilizando $K = 3$. [autoría propia].....	209
Figura 5.4.4.1 Pasos de la metodología. [autoría propia]	215
Figura 5.4.4.2.1 a) Búsqueda de registros basada en la lista de UserKey de la carpeta de Usuarios Archivados. b) Normalización Min-Max de los registros de la carpeta Tappy Data. c) Extracción de características para cada uno de los 217 participantes. [autoría propia]	216

Figura 5.4.4.3.1 División del conjunto de datos en conjuntos de entrenamiento y de prueba. [autoría propia].....	217
Figura 5.4.5.1 Precisión y tiempo de ejecución de los mejores algoritmos de ML de los mejores algoritmos. [autoría propia].....	221
Figura 5.4.5.2 Matriz de confusión. [autoría propia].....	221
Figura 5.4.5.3 Curva de características operativas del receptor de NB. [autoría propia]	222

Tablas

Tabla 2.2.1 Actividades mentales con las bandas de frecuencia de las señales EEG. [autoría propia]	43
Tabla 2.9.1 Precisión de clasificación de los algoritmos para cada tipo de tarea. [autoría propia]	66
Tabla 3.1.1.1 Sistema de Clasificación de la Función Motora Gruesa (GMFCS). [autoría propia]	71
Tabla 3.1.3.1 Comparación de algoritmos de clasificación BCI-EEG [33,41,42].	74
Tabla 3.2.6.1 Explicación de la codificación de cada archivo “.CSV”. [autoría propia].....	85
Tabla 3.2.9.1 Resultados de la clasificación con tareas motoras e imagenético motor. [autoría propia]..	93
Tabla 4.2.5.1 Resultados medios de clasificación obtenidos con el conjunto de pruebas. [autoría propia]	127
Tabla 4.2.5.2 Tiempo medio de entrenamiento y clasificación con la Raspberry Pi4 B. [autoría propia]	127
Tabla 4.3.3.1 Resultados de aciertos utilizando k-means a diferentes grupos de características. [autoría propia].....	137
Tabla 4.4.3.1.1 Comparación del conjunto de datos de atención entre sujetos con y sin amputación. [autoría propia].....	144
Tabla 5.1.5.1 Recursos utilizados por el FPGA. [autoría propia].....	183
Tabla 5.1.5.2 Tiempos de ejecución. [autoría propia]	184
Tabla 5.2.6.1 Recursos utilizados por la FPGA. [autoría propia].....	196
Tabla 5.4.5.1 Resultados de los algoritmos de clasificación. [autoría propia].....	220

1 Capítulo 1: Introducción

El registro de señales de Electroencefalografía (EEG) ha sido empleado ampliamente en aplicaciones médicas, incluido el monitoreo de actividad cerebral para pacientes con trastornos neurológicos tales como: Alzheimer, Esclerosis Múltiple, Parkinson, accidentes cerebrovasculares, entre otros [1-5]. Por otro lado, el procesamiento de estas señales EEG, la detección de intenciones motoras y potenciales relacionados a eventos, han logrado establecer la base para el desarrollo de la Interfaz Cerebro-Ordenador (BCI). Esta última, beneficia a las personas con discapacidades motrices al permitirles controlar prótesis activas [6], ortesis de asistencia biomecánica [7], exoesqueletos robóticos de extremidades inferiores [8] y dispositivos de automatización del hogar [9,10].

El registro de las señales EEG se lo puede realizar de forma invasiva y no invasiva. El primer método de registro requiere intervención quirúrgica con equipamiento más sensible, especializado y presenta un riesgo para el paciente [11]. En contraparte, el segundo método de registro no requiere equipos excesivamente costosos ni una intervención quirúrgica [12], convirtiéndolo en una atractiva alternativa gracias a la cada vez más accesible tecnología de adquisición de datos EEG no invasivos. Por ejemplo, empresas tales como EMOTIV (www.emotiv.com) [13] y OPENBCI (www.openbci.com) [14] nos ofrecen tecnologías viables en cuanto a costo y facilidad de uso para el registro de señales EEG de forma no invasiva [15]. Los equipos no invasivos registran las señales con electrodos que hacen contacto con el cuero cabelludo, estas señales bioeléctricas se utilizan para registrar la actividad de la corteza cerebral en el orden de los microvoltios (μV) [16]. Gracias al bajo costo y al bajo riesgo que implica el uso de estos dispositivos no invasivos, cada vez es más frecuente encontrar trabajos que utilizan estas señales para el control de dispositivos buscando mejorar la calidad de vida de las personas con discapacidades motrices [17]. Sin embargo, dada la naturaleza no invasiva de las señales EEG y a su registro en el dominio del tiempo, son muy sensibles al ruido producido principalmente por el movimiento relativo entre los electrodos de superficie y el cuero cabelludo, la sudoración de la piel, tejido adiposo, los latidos del corazón, el parpadeo y los armónicos de la red eléctrica [18,19].

En general, aplicaciones basadas en la detección de intenciones motoras empleando señales EEG, se han vuelto cada vez más populares, en particular con el uso de algoritmos de Aprendizaje Autónomo (Machine Learning - ML) [20,21]. Debido a la elevada relación

señal-ruido de estas señales, las aplicaciones basadas en aprendizaje autónomo emplean etapas de pre-procesamiento y extracción de características [19]. Por otro lado, gracias al creciente desempeño computacional muchos trabajos han logrado emplear técnicas basadas en algoritmos de aprendizaje profundo logrando obtener porcentajes de acierto bastante altos. Trabajos como los realizados por Movahedi et al. [22] demuestran que es posible detectar actividades mentales como imaginación de movimiento con un acierto del 86.91% usando el algoritmo Deep Belief Network (DBN) y un acierto de 91.31% con el algoritmo Sparse version of DBN [22]. En cuanto a la detección de movimiento de las manos izquierda, derecha y los pies, la investigación realizada por Schirrmeister et al. [23] ha demostrado que es posible superar el 90% de acierto empleando el algoritmo Deep ConvNet. Trabajos como el de Ordóñez et al. [24] empleando el algoritmo Deep Convolutional Long Short-Term Memory (DeepConvLSTM) con datos registrados de sensores tales como acelerómetros 3D, giroscopios 3D, sensores magnéticos 3D, 2 sensores inerciales en cada pie y 12 acelerómetros en extremidades; han logrado obtener porcentajes de acierto de 89,5% en la detección de modos de movimiento y 91,5% en el reconocimiento de gestos. Con el mismo dataset que el trabajo anterior [24], Abdulmajid et al. [25] han logrado realizar el reconocimiento de actividad humana con un porcentaje de acierto de 97.8% con el algoritmo Deep Recurrent Neural Networks (DR NN). Trabajos como el de Bashivan et al. [26] demuestran que el uso combinado de algoritmos como el LSTM y el Deep Recurrent-Convolutional Network puede mejorar el porcentaje de acierto en la clasificación entre un 11,32% a 12,86%. Finalmente, el trabajo realizado por He et al. [27] ha logrado demostrar que el uso de los algoritmos de aprendizaje profundo puede ser aplicado en la caracterización automática de señales EEG registradas durante la realización de tareas de intenciones de movimiento.

1.1 Justificación

Las personas con Parálisis Cerebral Infantil (PCI) representan una de las principales causas de discapacidad afectando la calidad de vida de las personas y la de sus familiares quienes tienen que dedicar tiempo a su cuidado con impacto directo en la economía de la familia y su relación con la sociedad [28].

Recientes investigaciones demuestran que la plasticidad cerebral juega un papel importante en la rehabilitación de sujetos con PCI [29,30]. Actividades de rehabilitación

motora para este tipo de pacientes ayudan a recuperar el desempeño de coordinación motora y sensorial, mejorando así las condiciones de vida de los pacientes y el entorno familiar [31]; pero, algunas de estas terapias de rehabilitación motora requieren de asistencia de un especialista que brinda un acompañamiento durante toda la sesión [32]. Existen equipos robóticos de rehabilitación motora que ayudan a mejorar la atención brindada al paciente, tratando de entregar cierta autonomía en la ejecución de las tareas motoras, algunos de estos equipos suelen ser ortesis robóticas o exoesqueletos robóticos [33]. Estos equipos utilizan señales de Electromiografía (EMG) para realizar la detección de la intensidad motora de los pacientes, las cuales dependen de la actividad muscular en pequeñas proporciones, siendo esto un problema para personas que han perdido la capacidad de controlar su actividad muscular, espasticidad muscular o incluso con aquellos que han perdido la tonalidad muscular [34,35].

Las recientes aplicaciones de la ingeniería y la neurociencia han conducido al desarrollo de sistemas de Interfaz Cerebro-Ordenador (BCI) que favorecen las vidas de las personas con discapacidades motoras [36]. Por esto, el uso de técnicas no invasivas usando electrodos superficiales de EEG para obtener la actividad eléctrica del cerebro, es una de las técnicas más utilizadas para BCI ya que es una alternativa económica aplicable en terapias de rehabilitación [26,27]. Para el registro de esta actividad cerebral, los electrodos EEG son utilizados con distribución estandarizada llamada "Sistema Internacional 10-20" [28].

Existe un crecimiento sin precedentes de dispositivos para detectar la actividad cerebral mientras se realizan tareas motoras [29]. Además, estudios médicos como los realizados por He et al. [30], Liu et al. [31] revelan que las señales EEG pueden utilizarse para detectar intenciones de movimiento en personas que sufren trastornos neurológicos como la Epilepsia, la enfermedad de Alzheimer y el trastorno de Parkinson [1-5]. En consecuencia, las personas con discapacidades motoras pueden controlar dispositivos de asistencia o prótesis utilizando sensores EEG no invasivos [31].

Se ha realizado un número importante de estudios para identificar o clasificar las intenciones de movimiento de las extremidades superiores empleando señales EEG [6-8,15,20,33-36]. Pero, son pocos los trabajos que se refieren a la identificación de la intención de movimiento de las extremidades inferiores [37-40]. No obstante, la neurorrehabilitación de los miembros inferiores es un tema importante en el ámbito médico,

ya que algunas personas sufren problemas de movilidad en sus miembros inferiores, como los diagnosticados con trastornos neurodegenerativos como: Esclerosis múltiple y las personas con hemiplejia o tetraplejia [41-46]. En particular, los sistemas convencionales de Reconocimiento de Patrones (RP) son una de las herramientas computacionales más adecuadas para el análisis de señales EEG, ya que el conocimiento explícito de las características implicadas en el proceso de RP es crucial, tanto para mejorar el rendimiento de la clasificación de la señal como para proporcionar una mayor interpretabilidad [47,48].

En este sentido, existe una necesidad real de investigar qué técnicas de RP de referencia y de última generación, permiten una comprensión más profunda de los patrones asociados a las intenciones motoras y una adecuada selección de la técnica específica. En esta tesis doctoral se ha realizado una revisión de artículos especializados en la identificación de tareas motoras de extremidades inferiores mediante sistemas de análisis de señales BCI/EEG basados en la RP. A continuación, se discute sus metodologías experimentales para el registro de señales de EEG durante la ejecución de tareas de extremidades inferiores. Además, revisamos los algoritmos utilizados en las etapas de preprocesamiento, extracción de características y clasificación. Por último, se propone el desarrollo de algoritmos que nos permitan extraer características adecuadas de las intenciones motoras de extremidades inferiores; y, desarrollar algoritmos de inteligencia artificial que permitan detectar estas intenciones motoras.

1.2 Contribución

Entre las principales contribuciones realizadas por esta tesis doctoral se destacan: a) el análisis del estado del arte en la detección de intenciones motoras para extremidades inferiores, basados en el análisis de señales EEG; b) el desarrollo de modelos para detección de intenciones motoras empleando algoritmos de aprendizaje no supervisado y aprendizaje supervisado; c) el desarrollo de hardware embebido para aplicaciones portátiles como test-bed de los algoritmos implementados; y d) la realización de una base de datos con el registro de intenciones motoras empleando señales EEG. Estas contribuciones se detallan a continuación:

- Previo al desarrollo de esta investigación se realizó una revisión literaria de los trabajos más destacados en relación con la detección de intenciones motoras en extremidades inferiores. La revisión realizada en este trabajo es una visión general según la

clasificación dada en [66]. Su objetivo es presentar un estudio de los artículos científicos especializados sobre la detección de las intenciones de movimiento de los miembros inferiores utilizando enfoques basados en BCI/EEG. Se centra en los estudios que siguieron el paradigma de imágenes motoras, tal y como se define en [67]. A nivel de análisis de señales, para una posterior interpretabilidad, los enfoques basados en la RP son de interés para este trabajo, con especial énfasis en las etapas de RP como el preprocesamiento, la extracción de características y la clasificación. Además, se estudian las metodologías experimentales para la adquisición de datos.

Como resultado de este análisis se generó una publicación titulada: "Identification of Lower-Limb Motor Tasks via Brain-Computer Interfaces: A Topical Overview", que fue publicada en la revista científica MDPI / Biomedical Sensor [68] en febrero 2022.

Aprendizaje no supervisado:

- Como resultado de esta investigación, se demuestra que es posible detectar estímulos visuales de 4-9Hz y de 24-29Hz con un 80% de precisión, basado en señales EEG de la región occipital del cerebro empleando el algoritmo k-means de clustering. Además, se realizó la implementación de la primera metodología experimental que permitió el registro de datos de la región cortical del cerebro, basado en Steady State Visual Evoked Potentials (SSVEP). Los estímulos visuales fueron generados por una luz led sin ruido lumínico externo. Se utilizó el dispositivo EMOTIV EPOC y se contó con 5 voluntario sanos. En este trabajo, los datos registrados fueron filtrados en el rango de 2 a 40Hz, luego se determinaron características temporales y de Densidad Espectral de Potencia (PSD).

Los resultados de esta metodología se publicaron en el paper titulado: "Clustering of EEG occipital signals using k-means", en el 2016 [58].

- Como resultado de esta investigación, también se realizó la detección de tareas motoras e imagenético motoras con una precisión de 88%, basado en señales EEG de la corteza motora del cerebro, empleando algoritmos de clustering como K-means, K-medoids, Clustering Jerárquico, Clustering Espectral y DbSCAN. Se emplearon datos de 25 sujetos de prueba. El dataset utilizado en los experimentos fue facilitado a través de

la iniciativa de datos libre llamada Physionet. Los datos fueron filtrados en el rango de 7 a 30 Hz. Se calcularon características basadas en PSD.

Los resultados de estos experimentos se publicaron en el paper titulado: "EEG signal clustering for motor and imaginary motor tasks on hands and feet", en el 2017 [59].

- Como resultado de esta investigación, también se demostró que los algoritmos de aprendizaje no supervisado pueden ser utilizados en la detección de 9 tareas motoras, basado en señales EMG del antebrazo, empleando algoritmos clustering como K-means, K-medoids, Clustering Jerárquico, Clustering Espectral y DbSCAN. En la experimentación se emplearon los datos de 6 sujetos de prueba. Los datos fueron facilitados por la Universidad de Navarra. Además, los datos fueron filtrados en el rango de 7 a 20 Hz. También se calcularon características temporales y características basadas en PSD.

Los resultados de estos experimentos se publicaron en el paper titulado: "EMG Signal Processing with Clustering Algorithms for motor gesture Tasks", en el 2018 [60].

Aprendizaje supervisado:

- En cuanto al aprendizaje supervisado, se realizó una revisión de trabajos enfocados en la detección de intenciones motoras en sujetos que padecen PCI. Como resultado de esta investigación se encontró que algunas de las características más usadas en la detección de intenciones motoras fueron aquellas basadas en PSD. Los experimentos demostraron que los mejores resultados se obtuvieron con algoritmos Máquinas de Vectores de Soporte (SVM), tales como Least-squares SVM (LS-SVM). Este estudio permitió demostrar que las características usadas tanto en algoritmos supervisados y no supervisado, pueden ser los mismos; así como la etapa previa de preprocesamiento de señales basadas en filtros de 7 a 30Hz.

En este estudio se plantea un estándar para el preprocesamiento de señales, extracción de características, selección de características y clasificación, que será utilizado en las siguientes etapas de esta investigación, en particular en la clasificación basada en algoritmos de aprendizaje supervisado.

Los resultados de estos experimentos se publicaron en el paper titulado: "Supervised pattern recognition techniques for detecting motor intention of lower limbs in subjects with cerebral palsy", en el 2017 [57].

- Como resultado de esta investigación y en base al trabajo de detección de tareas motoras empleando señales EMG y algoritmos de clustering publicado en [60], también se realizó la clasificación de 9 tareas motoras utilizando el dispositivo MYO de 8 electrodos EMG de contacto seco. En este trabajo se utilizó la estructura propuesta en [57] basada en preprocesamiento de señales, extracción de características, selección de características y clasificación. La clasificación fue realizada con el algoritmo K-Nearest Neighbors (KNN) obteniendo un accuracy promedio de 93.2%.

Los resultados de estos experimentos se publicaron en el paper titulado: "k-NN-Based EMG Recognition for Gestures Communication with Limited Hardware Resources", en el 2019 [62].

- En relación al clustering de señales EEG occipitales usando k-means [58], también se planteó la clasificación de 4 estímulos visuales (7Hz, 9Hz, 11Hz y 13Hz) empleando el dispositivo EMOTIV EPOC. Para este procedimiento se planteó una metodología experimental de registro de señales EEG (SSVEP) en la región occipital del cerebro, con 20 sujetos de prueba. Los estímulos visuales fueron generados por un monitor de 17 pulgadas y se contó con ruido lumínico externo.

Para la realización de este procedimiento se utilizó la estructura propuesta en [57] basada en preprocesamiento de señales, extracción de características, selección de características y clasificación. Para la clasificación se ejecutó más de un algoritmo, entre los cuales tenemos: SVM, Red Neuronal Perceptrón Multicapa (MLP), RandomForest (RF), k-Nearest Neighbors (KNN) y eXtreme Gradient Boosting (XGBoost). Los resultados obtenidos demostraron que la detección de estímulos visuales es mejor cuando se utiliza luces led y sin ruido lumínico externo.

Los resultados de estos experimentos se publicaron en el paper titulado: "SSVEP-EEG Signal Classification based on Emotiv EPOC BCI and Raspberry Pi", en el 2021 [61].

Aplicaciones en tiempo real:

- Basado en el clustering de patrones relacionados al desarrollo de tareas motoras e imaginarias de manos y pies, a partir del análisis de señales EEG [59], se desarrolló un clasificador en tiempo real basado en NN e implementado en un arreglo tipo Arreglos de Compuertas Programables en Campo (FPGA). Para el desarrollo de los experimentos se emplearon los datos de 8 sujetos de prueba. El dataset fue facilitado por la iniciativa de datos libre llamada Physionet, y se evaluaron las tareas motoras e imagenético motoras de ambos pies. Las señales de los 64 electodos EEG fueron preprocesadas utilizando un filtro paso banda entre 7 a 30 Hz. Para la etapa de extracción de características, se utilizó las características basadas en PSD. Los resultados demostraron que es posible detectar y diferenciar las actividades motoras e imagenético motoras en extremidades inferiores con un acierto de 92.1% y 93.8%, respectivamente.

Los resultados de estos experimentos se publicaron en el paper titulado: "Implementation of a Classification System of EEG Signals Based on FPGA", en el 2020 [20].

- Como resultado de esta investigación, también se logró implementar el control de una prótesis robótica de extremidad superior, empleando las características temporales. El dispositivo utilizado fue un Neurosky, que permite registrar señales EEG con un solo electrodo en la corteza frontal. Los datos fueron registrados a partir de 10 sujetos de prueba, de los cuales 5 padecían de algún tipo de amputación en extremidad superior.

Los resultados de estos experimentos utilizando el control de una prótesis robótica de extremidad superior, se publicaron en el paper titulado: "A 3D-Printed EEG based Prosthetic Arm", en el 2021 [63].

- Basados en los resultados de la implementación de un sistema de clasificación de señales EEG en FPGA y en el clustering de patrones relacionados al desarrollo de

tareas motoras e imaginarias de manos y pies, a partir del análisis de señales EEG [20, 59], se desarrolló una técnica de selección automática de electrodos superficiales EEG, empleando algoritmos de aprendizaje no supervisado, a partir de los cuales se extraen características de los electrodos seleccionados para usarlos en el clasificador de tareas motoras e imagenético motoras. En estos experimentos se utilizaron los datos de 109 sujetos de prueba. El dataset fue facilitado por la iniciativa de datos libre llamada Physionet. Además, se evaluaron las tareas imagenético motoras de ambas manos y ambos pies. En la etapa de preprocesamiento se utilizó un filtro paso banda para las frecuencias de 8 a 31Hz. Para la etapa de extracción de características, se usó características temporales para el algoritmo de clustering y características basadas en PSD para el clasificador. Los resultados demostraron que es posible detectar intenciones motoras en extremidades superiores e inversiones con un 97.3% de acierto con Red Neuronal (NN).

Los resultados de estos experimentos se publicaron en el paper titulado: “BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control”, en el 2021 [64].

Desarrollo de una base de datos

- Para el desarrollo de los experimentos realizados en [58,61-63], se diseñaron metodologías experimentales para el registro de señales EEG en regiones occipitales o de la corteza frontal. Para ello se utilizaron dispositivos como el EMOTIV ESPOC y el Neurosky, que cuentan con 16 y 1 electrodo superficial, respectivamente. Por otro lado, también se desarrolló una metodología experimental que permite registrar señales EEG de 32 electrodos superficiales con el dispositivo OpenBCI. Esta metodología experimental cuenta con las normas de bioseguridad por el COVID-19. Para el desarrollo de este experimento se contó con la participación de 24 sujetos de prueba, de los cuales uno padece de PCI.

Como resultado de estos experimentos se desarrolló un dataset, el cual se encuentra disponible en el siguiente enlace: <https://data.mendeley.com/datasets/w9xfz56txv/2> [69].

1.3 Preguntas de investigación y objetivos

El trastorno de Parálisis Cerebral Infantil (PCI) es una de las principales causas de afectación psicomotriz de la población [49]. Una forma de conocer la intención motora de estos pacientes es tomar las señales de actividad cerebral presentes en la corteza motora; existen técnicas invasivas y no invasivas para capturar estas señales. Una técnica no invasiva es medir las señales EEG en la corteza cerebral [27]. Sin embargo, esta técnica es susceptible al ruido eléctrico o artefactos provenientes de movimientos relativos entre electrodos, parpadeos, actividad muscular, frecuencia cardiaca, etc. [50].

Por otro lado, las técnicas para capturar la actividad cortical motora correspondiente a las extremidades inferiores no son efectivas porque es difícil detectarlas, ya que se registran en el giro motor central ubicado en el lado interior de la fisura longitudinal del cerebro [51]. Luego del análisis del estado del arte, se ha detectado que las técnicas de visualización topográfica de actividad cortical motora se centran en el análisis únicamente de las extremidades superiores en sujetos con algún tipo de trastorno en la corteza motora [52, 53,54]; tampoco existen base de datos de actividad cortical motora de extremidades inferiores de sujetos con daño en médula espinal basadas en EEG-BCI [26].

Otra dificultad radica en las afecciones que producen los daños de actividad cortical motora que se manifiestan en trastornos, tales como: Hemiplejía, Diplejía, Cuadriplejia e invalidez; y con ello la actividad cortical motora se ve afectada en proporción al grado de la función motora gruesa GMFCS (I, II, III, IV o V) que el sujeto padezca [52,55,56]. Lee et al, en [54] demostraron que la actividad cortical motora en extremidades superiores de sujetos con un nivel de GMFCS mayores a IV presenta actividad neuronal en áreas corticales irregulares, por lo tanto, nos centramos en los sujetos con PCI que posean habilidades motoras residuales [50].

Dados estos antecedentes, en esta tesis doctoral se pretende responder a las siguientes preguntas de investigación:

- RQ1: ¿Cómo podría detectarse el patrón de actividad motora cortical de los sujetos con Parálisis Cerebral Infantil (PCI) al realizar tareas de intención motora de las extremidades inferiores?

- RQ2: ¿Cómo podrían adaptarse los actuales algoritmos de caracterización utilizados en EEG-BCI para extraer las características adecuadas de las intenciones motoras de las extremidades inferiores?
- RQ3: ¿Qué algoritmo de aprendizaje autónomo será eficaz para el análisis del EEG-BCI en la detección de las intenciones motoras de las extremidades inferiores?

1.4 Objetivos

Esta tesis de investigación tiene los siguientes objetivos

- OBJETIVO GENERAL:
 - Detectar las intenciones motoras de las extremidades inferiores mediante técnicas de aprendizaje autónomo para el reconocimiento de patrones y la caracterización de señales no estacionarias para la asistencia computarizada de sujetos que sufren Parálisis Cerebral Infantil (PCI).
- OBJETIVOS ESPECÍFICOS:
 - Implementar una metodología experimental basada en EEG-BCI que permita detectar la actividad cortical motora de sujetos con lesión medular leve al realizar tareas de intención motora de extremidades inferiores.
 - Adaptar los actuales algoritmos de aprendizaje autónomo utilizados en EEG-BCI para extraer las características adecuadas de las intenciones motoras de las extremidades inferiores.
 - Desarrollar una metodología, basada en técnicas de aprendizaje autónomo utilizadas en EEG-BCI, para realizar una detección eficiente de las intenciones motoras de las extremidades inferiores en sujetos con Parálisis Cerebral Infantil (PCI).

1.5 Organización del Documento

- Capítulo 1
 - En este capítulo se presenta una introducción al ámbito del problema a investigar; las motivaciones que justifican una solución a este problema; un resumen de las principales contribuciones a partir de los resultados obtenidos

en la búsqueda de las respuestas a las preguntas de investigación; los objetivos; y, la organización de esta tesis doctoral.

- Capítulo 2

- En este capítulo se presentan los resultados del análisis del estado del arte, que resume artículos especializados que cubren la identificación de tareas motoras de extremidades inferiores mediante sistemas de análisis de señales BCI/EEG basados en la RP. Para ello, primero se establecieron términos de búsqueda y criterios de inclusión y exclusión para encontrar los artículos más relevantes sobre el tema. Como resultado, se identificaron 22 artículos más relevantes y actuales. A continuación, se muestra la revisión de las metodologías experimentales para el registro de señales de EEG, durante la ejecución de tareas de extremidades inferiores. Además, se revisan los algoritmos utilizados en las etapas de preprocesamiento, extracción de características y clasificación. Por último, se comparan todos los algoritmos y se determinan cuáles son los más adecuados en términos de precisión. Como resultado de este análisis se publicó un artículo titulado: "Identification of Lower-Limb Motor Tasks via Brain-Computer Interfaces: A Topical Overview", el que fue publicado en la revista científica Multidisciplinary Digital Publishing Institute (MDPI) el 2022 [68].

- Capítulo 3

- En este capítulo se responde la primera pregunta de investigación donde se presentan los algoritmos de extracción de características y clasificación que permiten detectar satisfactoriamente las intensidades motoras en miembros inferiores en sujetos con parálisis cerebral (PC). Este estudio dio como resultado un artículo científico titulado: "Supervised pattern recognition techniques for detecting motor intention of lower limbs in subjects with cerebral palsy", el que fue presentado en el Congreso IEEE, denominado "Ecuador Technical Chapters Meeting (ETCM)", en el 2017 [57].
- También, dentro de este capítulo se discute la metodología experimental desarrollada para el registro de las señales EEG de las tareas de extremidades inferiores y superiores. Además, se crea el conjunto de datos a partir de 24 sujetos, uno de los cuales presenta Parálisis Cerebral Infantil (PCI). Además, se presenta un conjunto de datos que contiene 2.976 archivos ".CSV" de 24 sujetos de prueba durante el desarrollo de tareas motoras e imágenes motoras.

Los voluntarios fueron reclutados entre colegas investigadores de la ESPOL y pacientes del Hospital Luis Vernaza de Guayaquil, Ecuador. Cada archivo “.CSV” tiene 501 filas, de las cuales la primera enumera los electrodos de 0 a 15, y las 500 filas restantes corresponden a 500 muestras. Además, cada archivo contiene 17 columnas, de las cuales la primera indica el número de muestreo y las 16 columnas restantes representan 16 electrodos de EEG de superficie. Este capítulo incluye medidas estadísticas sobre la información demográfica de todos los sujetos de prueba reclutados. Por último, se detalla la metodología experimental utilizada para registrar las señales de EEG durante la ejecución de la tarea de las extremidades superiores e inferiores. Este conjunto de datos se denomina “MILimbEEG” y contiene las señales EEG adquiridas durante tareas motoras e imágenes motoras. Los datos recogidos facilitaron la evaluación de modelos de detección y clasificación de señales EEG, dedicados al reconocimiento de tareas.

El dataset presentado en este capítulo dio como resultado el artículo titulado “MILimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motor Imagery Tasks” el mismo que se encuentra disponible en el siguiente enlace: <https://data.mendeley.com/datasets/w9xfz56txv/2> [69]. Este trabajo fue enviado a la revista MDPI DATA (www.mdpi.com/journal/data) y este trabajo actualmente está en proceso de revisión.

- Capítulo 4
 - En este capítulo se responde la segunda pregunta de investigación y también, se introduce el uso de algoritmos de clustering en la detección de tareas motoras e imagenético motoras, basado en señales EEG obtenidas de forma superficial de la corteza motora. Los datos pertenecen a 25 sujetos sanos que realizaron movimientos motores e imaginarios de manos y pies. Se presenta el preprocesamiento de los datos, extracción de características basada en la densidad espectral y el análisis de cinco algoritmos de clustering para detectar tareas motoras e imaginarias. Los resultados fueron publicados en el artículo titulado “EEG signal clustering for motor and imaginary motor tasks on hands

and feet”, que fue presentado en el 2017 en el Congreso “IEEE Second Ecuador Technical Chapters Meeting” (ETCM) [59].

- Se presenta el diseño experimental para el registro de señales de Electroencefalografía (EEG) en 20 sujetos de prueba sometidos a potenciales evocados visualmente en estado estable (SSVEP). Los estímulos se realizaron con frecuencias de 7, 9, 11 y 13 Hz. También se implementa un sistema de clasificación basado en señales SSVEP-EEG de la región occipital del cerebro obtenidas con el dispositivo Emotiv EPOC. Estos datos se utilizaron para entrenar algoritmos basados en inteligencia artificial en una Raspberry Pi 4 Modelo B. Los resultados fueron publicados en el artículo científico titulado: “SSVEP-EEG Signal Classification based on Emotiv EPOC BCI and Raspberry Pi”, el mismo que fue presentado el 2021 en el “Symposium on Biological and Medical Systems” (BMS) de “International Federation of Automatic Control” (IFAC) [61].
- Dentro de este capítulo también se presenta un análisis estadístico de la distribución de las señales normales de EEG, para determinar la necesidad de un preprocesamiento que elimine los componentes de ruido de las redes eléctricas u otras posibles fuentes. Este preprocesamiento incluyó el diseño y uso de un filtro que elimina cualquier componente de la señal que no esté en el rango de frecuencias de funcionamiento del área occipital del EEG. Finalmente, se utilizó un algoritmo no supervisado para agrupar las señales según sus características frecuenciales y temporales. Los resultados generaron el artículo científico titulado: “Clustering of EEG occipital signals using k-means” presentado el 2016 en el Congreso “IEEE Ecuador Technical Chapters Meeting” (ETCM) [58].
- Además, se analiza el caso de un hombre de 64 años que recibió una descarga eléctrica de 13,2 kV. en su mano derecha, registrando una baja señal EMG. Los datos adquiridos del dispositivo EEG se filtraron y ajustaron a las capacidades del paciente para encontrar un valor de umbral que se utilizó como parámetro de control. Como resultado, el sujeto de prueba fue capaz de controlar una prótesis impresa en 3D, que se ajustó al muñón del paciente. Los resultados fueron publicados en el artículo científico titulado: “A 3D-Printed EEG based Prosthetic Arm” que fue presentado el 2021, en el “International Conference on

E-health Networking, Application & Services” (HEALTHCOM) de IEEE en Shenzhen, China [63].

- Finalmente, se realiza un análisis similar empleando las mismas etapas y algoritmos de clustering, pero esta vez comprobando la detección de intenciones motoras en extremidades superiores basados en señales EMG. Los resultados fueron publicados en el artículo “EMG Signal Processing with Clustering Algorithms for motor gesture Tasks”, presentado en el 2018 en el Congreso “IEEE Third Ecuador Technical Chapters Meeting” (ETCM) [60].
- Capítulo 5
 - En este capítulo se responde la tercera pregunta de investigación y se presenta la implementación de un sistema de clasificación basado en FPGA, capaz de clasificar en tiempo real datos caracterizados, representando una tarea motora imaginaria y una tarea motora en extremidades inferiores. Además, se diseñó una red NN feed-forward de tres capas en Matlab, que permitió probar diferentes arquitecturas para evaluar el rendimiento del clasificador, utilizando métodos como la matriz de confusión y la curva ROC. Este trabajo de investigación dio como resultado la publicación titulada: “Implementation of a Classification System of EEG Signals Based on FPGA” presentado el 2020 en la Conferencia: “Seventh International Conference on eDemocracy & eGovernment” (ICEDEG) en Buenos Aires Argentina [20].
 - Además, en este capítulo se introduce una arquitectura de modelo tipo “extremo a extremo”, que permite la extracción de características y la clasificación mediante una red neuronal artificial. El proceso de extracción de características parte de un conjunto inicial de señales adquiridas por los electrodos de una interfaz cerebro-ordenador (BCI). Esta arquitectura incluye una nueva técnica de selección y agrupación de electrodos, que está relacionada con las intenciones motoras del sujeto. Con ello, se analiza y predice dos tareas imaginarias de intención motora: abrir y cerrar ambos manos y flexionar y extender ambos pies. Los resultados fueron publicados en el artículo científico titulado: “BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control”, que fue presentado el 2021 en el “Symposium on Biological and Medical Systems” (BMS) de “International Federation of Automatic Control” (IFAC) [64].

- Por otro lado, con énfasis en el uso de un número reducido de características en el proceso de clasificación de gestos, para reducir la necesidad de recursos computacionales. Por tal razón, se propone utilizar sólo una característica, el valor de la señal de la raíz cuadrada media (RMS), y el algoritmo de clasificación supervisada KNN. El sistema fue evaluado en una FPGA DE10-Standard para demostrar su portabilidad a dispositivos portátiles con recursos de hardware limitados, los resultados de investigación permitieron generar el artículo científico titulado: “K-NN-Based EMG Recognition for Gestures Communication with Limited Hardware Resources”, que se presentó el 2019 en el congreso denominado: “SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation” (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI) de IEEE en Leicester, United Kingdom [62].
- Finalmente, se presenta un modelo de clasificación de sujetos con la enfermedad de Parkinson utilizando datos de la pulsación de los dedos en un teclado. Se utilizó una base de datos gratuita de Physionet con más de 9 millones de registros, preprocesada para eliminar datos atípicos. En la etapa de extracción de características, se obtuvo 48 características. Se utilizó Google Colaboratory para entrenar, validar y probar nueve algoritmos de aprendizaje supervisado que detectan la enfermedad. Los resultados fueron publicados en el artículo científico titulado: “Classification of Subjects with Parkinson's Disease using Finger Tapping Dataset”, que fue presentado el 2021 en el “Symposium on Biological and Medical Systems” (BMS) de “International Federation of Automatic Control” (IFAC) [65].
- Capítulo 6
 - Este capítulo incluye las conclusiones generales de este trabajo, así como algunas recomendaciones para la realización de trabajos futuros.
- Anexo I
 - Por último, en este anexo se presenta el aval a los datos registrados por parte del comité de ética.

En la figura 1.5.1 se muestra el resumen de las preguntas de investigación asociadas en cada capítulo, con sus respectivos artículos publicados.

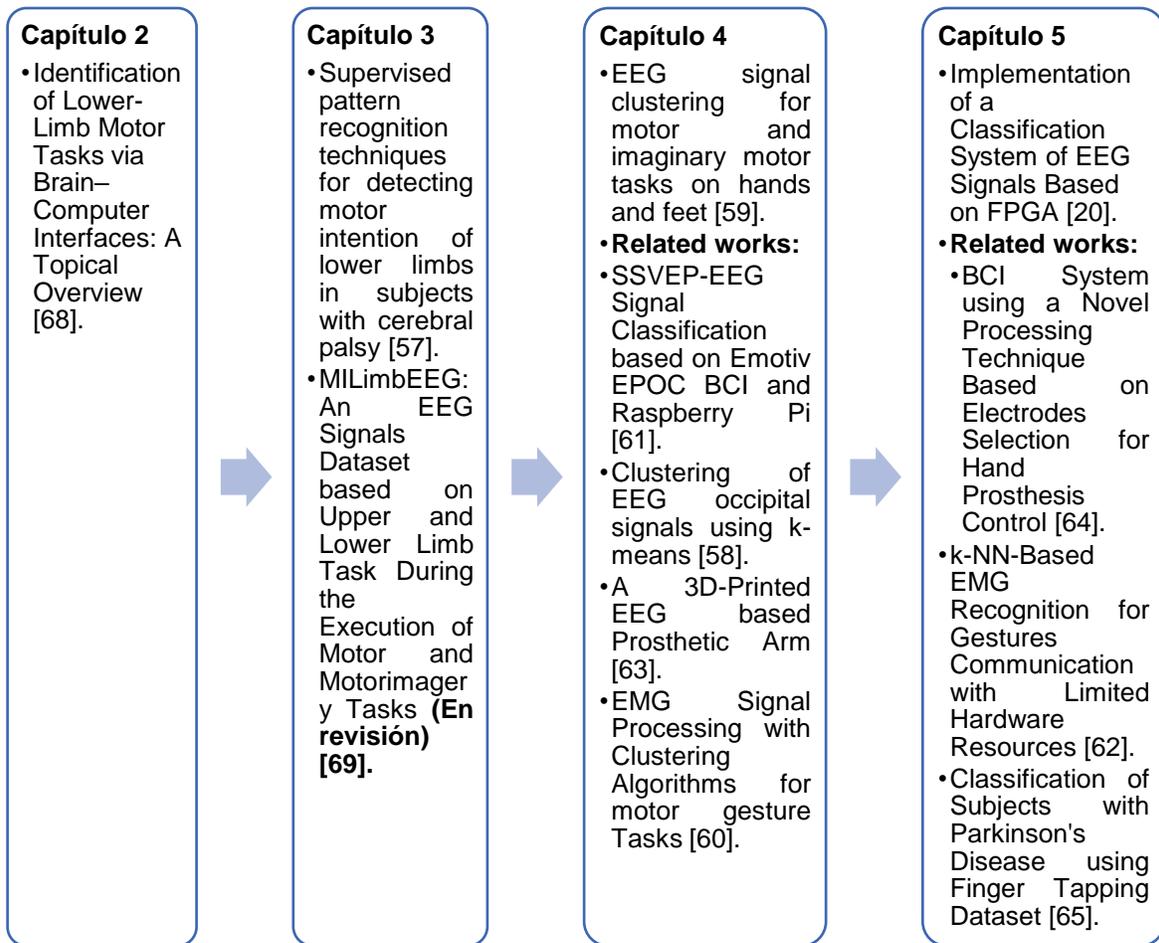


Figura 1.5.1 Conexiones entre las preguntas de investigación y las publicaciones realizadas. [autoría propia]

1.6 Bibliografía

- [1] Alturki, F.A.; AlSharabi, K.; Abdurraqueeb, A.M.; Aljalal, M. EEG signal analysis for diagnosing neurological disorders using discrete wavelet transform and intelligent techniques. *Sensors* 2020, 20, 2505.
- [2] Bi, X.; Wang, H. Early Alzheimer's disease diagnosis based on EEG spectral images using deep learning. *Neural Networks* 2019, 114, 119–135.
- [3] Hussen, D.F.; Hussein, A.A.F.; Monzer, M.A.M.; Hammad, S.A. Combined markers for predicting cognitive deficit in patients with Alzheimer's disease. *Egyptian Journal of Medical Human Genetics* 2021, 22, 1–8.

- [4] Naghsh, E.; Sabahi, M.F.; Beheshti, S. Spatial analysis of EEG signals for Parkinson's disease stage detection. *Signal, Image and Video Processing* 2020, 14, 397–405.
- [5] Pal, A.; Behari, M.; Goyal, V.; Sharma, R. Study of EEG microstates in Parkinson's disease: a potential biomarker? *Cognitive Neurodynamics* 2021, 15, 463–471.
- [6] Al-Quraishi, M. S., Elamvazuthi, I., Daud, S. A., Parasuraman, S., & Borboni, A. (2018). EEG-based control for upper and lower limb exoskeletons and prostheses: A systematic review. *Sensors*, 18(10), 3342.
- [7] Khan, S. M., Khan, A. A., & Farooq, O. (2019). Selection of features and classifiers for EMG-EEG-based upper limb assistive devices—A review. *IEEE reviews in biomedical engineering*, 13, 248-260.
- [8] Crea, S., Nann, M., Trigili, E., Cordella, F., Baldoni, A., Badesa, F. J., ... & Soekadar, S. R. (2018). Feasibility and safety of shared EEG/EOG and vision-guided autonomous whole-arm exoskeleton control to perform activities of daily living. *Scientific reports*, 8(1), 1-9.
- [9] Roy, P. P., Kumar, P., & Chang, V. (2020). A hybrid classifier combination for home automation using EEG signals. *Neural Computing and Applications*, 32(20), 16135-16147.
- [10] Kim, M., Kim, M. K., Hwang, M., Kim, H. Y., Cho, J., & Kim, S. P. (2019). Online home appliance control using EEG-Based brain–computer interfaces. *Electronics*, 8(10), 1101.
- [11] Klaes, C. (2018). Invasive brain-computer interfaces and neural recordings from humans. In *Handbook of behavioral neuroscience* (Vol. 28, pp. 527-539). Elsevier.
- [12] Meng, J., & He, B. (2019). Exploring training effect in 42 human subjects using a non-invasive sensorimotor rhythm based online BCI. *Frontiers in human neuroscience*, 13, 128.
- [13] Kotowski, K., Stapor, K., Leski, J., & Kotas, M. (2018). Validation of Emotiv EPOC+ for extracting ERP correlates of emotional face processing. *Biocybernetics and Biomedical Engineering*, 38(4), 773-781.
- [14] Samson, V. R. R., Praveen Kitti, B., Pradeep Kumar, S., Suresh Babu, D., & Monica, C. (2018). Electroencephalogram-based OpenBCI devices for disabled people. In *Proceedings of 2nd International Conference on Micro-Electronics, Electromagnetics and Telecommunications* (pp. 229-238). Springer, Singapore.
- [15] Cho, J. H., Jeong, J. H., Shim, K. H., Kim, D. J., & Lee, S. W. (2018, October). Classification of hand motions within EEG signals for non-invasive BCI-based robot hand control. In *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 515-518). IEEE.

- [16] Stancin, I., Cifrek, M., & Jovic, A. (2021). A review of EEG signal features and their application in driver drowsiness detection systems. *Sensors*, 21(11), 3786.
- [17] Lupu, R. G., Irimia, D. C., Ungureanu, F., Poboroniuc, M. S., & Moldoveanu, A. (2018). BCI and FES based therapy for stroke rehabilitation using VR facilities. *Wireless Communications and Mobile Computing*, 2018.
- [18] Pander, T. (2019). EEG signal improvement with cascaded filter based on OWA operator. *Signal, Image and Video Processing*, 13(6), 1165-1171.
- [19] Pedroni, A., Bahreini, A., & Langer, N. (2019). Automagic: Standardized preprocessing of big EEG data. *Neuroimage*, 200, 460-473.
- [20] Asanza, V.; Constantine, A.; Valarezo, S.; Peláez, E. Implementation of a Classification System of EEG Signals Based on FPGA. 2020 Seventh International Conference on eDemocracy eGovernment (ICEDEG), 2020, pp. 87–92. doi:10.1109/ICEDEG48599.2020.9096752.
- [21] Amin, H. U., Mumtaz, W., Subhani, A. R., Saad, M. N. M., & Malik, A. S. (2017). Classification of EEG signals based on pattern recognition approach. *Frontiers in computational neuroscience*, 11, 103.
- [22] Movahedi, F., Coyle, J. L., & Sejdić, E. (2017). Deep belief networks for electroencephalography: A review of recent contributions and future outlooks. *IEEE journal of biomedical and health informatics*, 22(3), 642-652.
- [23] Schirrmester, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggenberger, K., Tangermann, M., ... & Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human brain mapping*, 38(11), 5391-5420.
- [24] Ordóñez, Francisco Javier, and Daniel Roggen. "Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition." *Sensors* 16.1 (2016): 115.
- [25] Murad, A., & Pyun, J. Y. (2017). Deep recurrent neural networks for human activity recognition. *Sensors*, 17(11), 2556.
- [26] Fedjaev, J. (2017). Decoding eeg brain signals using recurrent neural networks.
- [27] He, Y.; Luu, T.P.; Nathan, K.; Nakagome, S.; Contreras-Vidal, J.L. A mobile brain-body imaging dataset recorded during treadmill walking with a brain-computer interface. *Scientific data* 2018, 5, 1–10.

- [28] Ihlen, E. A., Støen, R., Boswell, L., de Regnier, R. A., Fjørtoft, T., Gaebler-Spira, D., ... & Adde, L. (2020). Machine learning of infant spontaneous movements for the early prediction of cerebral palsy: A multi-site cohort study. *Journal of Clinical Medicine*, 9(1), 5.
- [29] Mrachacz-Kersting, N., Jiang, N., Stevenson, A. J. T., Niazi, I. K., Kostic, V., Pavlovic, A., ... & Farina, D. (2016). Efficient neuroplasticity induction in chronic stroke patients by an associative brain-computer interface. *Journal of neurophysiology*, 115(3), 1410-1421.
- [30] de Oliveira, J. M., Munoz, R., Ribeiro, S., Wu, W., & de Albuquerque, V. H. C. (2020). REHAB FUN: an assistive technology in neurological motor disorders rehabilitation of children with cerebral palsy. *Neural Computing and Applications*, 32(15), 10957-10970.
- [31] Young, B. M., Nigogosyan, Z., Walton, L. M., Song, J., Nair, V. A., Grogan, S. W., ... & Williams, J. C. (2015). Changes in functional brain organization and behavioral correlations after rehabilitative therapy using a brain-computer interface. *Interaction of BCI with the underlying neurological conditions in patients: pros and cons*.
- [32] Bayona, N. A., Bitensky, J., Salter, K., & Teasell, R. (2005). The role of task-specific training in rehabilitation therapies. *Topics in stroke rehabilitation*, 12(3), 58-65.
- [33] Bertomeu-Motos, A., Blanco, A., Badesa, F. J., Barios, J. A., Zollo, L., & Garcia-Aracil, N. (2018). Human arm joints reconstruction algorithm in rehabilitation therapies assisted by end-effector robotic devices. *Journal of neuroengineering and rehabilitation*, 15(1), 1-11.
- [34] Qian, Q., Hu, X., Lai, Q., Ng, S. C., Zheng, Y., & Poon, W. (2017). Early stroke rehabilitation of the upper limb assisted with an electromyography-driven neuromuscular electrical stimulation-robotic arm. *Frontiers in neurology*, 8, 447.
- [35] Leonardis, D., Barsotti, M., Loconsole, C., Solazzi, M., Troncossi, M., Mazzotti, C., ... & Frisoli, A. (2015). An EMG-controlled robotic hand exoskeleton for bilateral rehabilitation. *IEEE transactions on haptics*, 8(2), 140-151.
- [36] Holz, E. M., Botrel, L., Kaufmann, T., & Kübler, A. (2015). Long-term independent brain-computer interface home use improves quality of life of a patient in the locked-in state: a case study. *Archives of physical medicine and rehabilitation*, 96(3), S16-S26.
- [26] Kinney-Lang, E., Auyeung, B., & Escudero, J. (2016). Expanding the (kaleido) scope: exploring current literature trends for translating electroencephalography (EEG) based brain-computer interfaces for motor rehabilitation in children. *Journal of Neural Engineering*, 13(6), 061002.

- [27] Gomez-Pilar, J., Corralejo, R., Nicolas-Alonso, L. F., Álvarez, D., & Hornero, R. (2016). Neurofeedback training with a motor imagery-based BCI: neurocognitive improvements and EEG changes in the elderly. *Medical & biological engineering & computing*, 1-12.
- [28] Jasper, H. H. (1958). The ten twenty electrode system of the international federation. *Electroencephalography and clinical neurophysiology*, 10, 371-375.
- [29] Casson, A. J. (2019). Wearable EEG and beyond. *Biomedical engineering letters*, 9(1), 53-71.
- [30] He, Y.; Luu, T.P.; Nathan, K.; Nakagome, S.; Contreras-Vidal, J.L. A mobile brain-body imaging dataset recorded during treadmill walking with a brain-computer interface. *Scientific data* 2018, 5, 1–10.
- [31] Liu, D.; Chen, W.; Pei, Z.; Wang, J. A brain-controlled lower-limb exoskeleton for human gait training. *Review of Scientific Instruments* 2017, 88, 104302.
- [32] Alturki, F. A., AlSharabi, K., Abdurraqeeb, A. M., & Aljalal, M. (2020). EEG signal analysis for diagnosing neurological disorders using discrete wavelet transform and intelligent techniques. *Sensors*, 20(9), 2505.
- [33] Bressan, G.; Cisotto, G.; Müller-Putz, G.R.; Wriessnegger, S.C. Deep learning-based classification of fine hand movements from low frequency EEG. *Future Internet* 2021, 13, 103.
- [34] Xu, S.; Zhu, L.; Kong, W.; Peng, Y.; Hu, H.; Cao, J. A novel classification method for EEG-based motor imagery with narrow band spatial filters and deep convolutional neural network. *Cognitive Neurodynamics* 2021, pp. 1–11.
- [35] Zhang, H.; Zhao, M.; Wei, C.; Mantini, D.; Li, Z.; Liu, Q. Eegdenoisenet: A benchmark dataset for deep learning solutions of eeg denoising. *Journal of Neural Engineering* 2021, 18, 056057.
- [36] Al-Quraishi, M.S.; Elamvazuthi, I.; Daud, S.A.; Parasuraman, S.; Borboni, A. EEG-based control for upper and lower limb exoskeletons and prostheses: A systematic review. *Sensors* 2018, 18, 3342.
- [37] Wang, C.; Wu, X.; Wang, Z.; Ma, Y. Implementation of a brain-computer interface on a lower-limb exoskeleton. *IEEE access* 2018, 6, 38524–38534.
- [38] Vinoj, P.G.; Jacob, S.; Menon, V.G.; Rajesh, S.; Khosravi, M.R. Brain-Controlled Adaptive Lower Limb Exoskeleton for Rehabilitation of Post-Stroke Paralyzed. *IEEE Access* 2019, 7, 132628–132648. doi:10.1109/ACCESS.2019.2921375.

- [39] Tariq, M.; Trivailo, P.M.; Simic, M. EEG-based BCI control schemes for lower-limb assistive-robots. *Frontiers in human neuroscience* 2018, 12, 312.
- [40] Liu, D.; Chen, W.; Lee, K.; Chavarriaga, R.; Iwane, F.; Bouri, M.; Pei, Z.; Millán, J.d.R. EEG-based lower-limb movement onset decoding: Continuous classification and asynchronous detection. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2018, 26, 1626–1635.
- [41] Delisle-Rodriguez, D.; Cardoso, V.; Gurve, D.; Loterio, F.; Romero-Laiseca, M.A.; Krishnan, S.; Bastos-Filho, T. System based on subject-specific bands to recognize pedaling motor imagery: towards a BCI for lower-limb rehabilitation. *Journal of neural engineering* 2019, 16, 056005.
- [42] Gurve, D.; Delisle-Rodriguez, D.; Romero-Laiseca, M.; Cardoso, V.; Loterio, F.; Bastos, T.; Krishnan, S. Subject-specific EEG channel selection using non-negative matrix factorization for lower-limb motor imagery recognition. *Journal of neural engineering* 2020, 17, 026029.
- [43] Gu, L.; Yu, Z.; Ma, T.; Wang, H.; Li, Z.; Fan, H. EEG-based classification of lower limb motor imagery with brain network analysis. *Neuroscience* 2020, 436, 93–109.
- [44] Gordleeva, S.Y.; Lobov, S.A.; Grigorev, N.A.; Savosenkov, A.O.; Shamshin, M.O.; Lukoyanov, M.V.; Khoruzhko, M.A.; Kazantsev, V.B. Real-time EEG–EMG human–machine interface-based control system for a lower-limb exoskeleton. *IEEE Access* 2020, 8, 84070–84081.
- [45] Chang, W.C.; Ko, L.W.; Yu, K.H.; Ho, Y.C.; Chen, C.H.; Jong, Y.J.; Huang, Y.P. EEG analysis of mixed-reality music rehabilitation system for post-stroke lower limb therapy. *Journal of the Society for Information Display* 2019, 27, 372–380.
- [46] Hoshino, T.; Oguchi, K.; Inoue, K.; Hoshino, A.; Hoshiyama, M. Relationship between lower limb function and functional connectivity assessed by EEG among motor-related areas after stroke. *Topics in Stroke Rehabilitation* 2020, pp. 1–10.
- [47] Choi, J.; Kim, K.T.; Jeong, J.H.; Kim, L.; Lee, S.J.; Kim, H. Developing a motor imagery-based real-time asynchronous hybrid BCI controller for a lower-limb exoskeleton. *Sensors* 2020, 20, 7309.
- [48] Ortiz, M.; Iáñez, E.; Contreras-Vidal, J.L.; Azorín, J.M. Analysis of the EEG rhythms based on the empirical mode decomposition during motor imagery when using a lower-limb exoskeleton. A case of study. *Frontiers in Neurorobotics* 2020, 14, 48.
- [49] Zapata, L. F. G., & Mesa, S. L. R. (2011). Alimentar y nutrir a un niño con parálisis cerebral. Una mirada desde las percepciones. *Invest Educ Enferm* [Internet], 29(1), 28-39.
- [50] Minguillon, J., Lopez-Gordo, M. A., & Pelayo, F. (2017). Trends in EEG-BCI for daily-life: Requirements for artifact removal. *Biomedical Signal Processing and Control*, 31, 407-418.

- [51] Comani, S.; Velluto, L.; Schinaia, L.; Cerroni, G.; Serio, A.; Buzzelli, S.; Sorbi, S.; Guarnieri, B. Monitoring neuro-motor recovery from stroke with high-resolution EEG, robotics and virtual reality: a proof of concept. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2015, 23, 1106–1116.
- [52] Shin, Y. K., Lee, D. R., Hwang, H. J., You, S. J. H., & Im, C. H. (2012). A novel EEG-based brain mapping to determine cortical activation patterns in normal children and children with cerebral palsy during motor imagery tasks. *NeuroRehabilitation*, 31(4), 349-355.
- [53] Gao, L., Wang, J., & Chen, L. (2013). Event-related desynchronization and synchronization quantification in motor-related EEG by Kolmogorov entropy. *Journal of neural engineering*, 10(3), 036023.
- [54] Lee, J. J., Lee, D. R., Kyum Shin, Y., Lee, N. G., Han, B. S., & You, S. J. H. (2013). Comparative neuroimaging in children with cerebral palsy using fMRI and a novel EEG-based brain mapping during a motor task—a preliminary investigation. *NeuroRehabilitation*, 32(2), 279-285.
- [55] Gómez-Regueira, N., & Vinas-Diz, S. (2016). Mejora del control postural y equilibrio en la parálisis cerebral infantil: revisión sistemática. *Fisioterapia*, 38(4), 196-214.
- [56] Arias Armijos, M. P. (2016). Características epidemiológicas y clínicas de la parálisis cerebral, en el servicio de Hospitalización de Pediatría del Hospital Vicente Corral Moscoso. Enero 2014-Junio 2015
- [57] Asanza, V., Pelaez, E., & Loayza, F. (2017, October). Supervised pattern recognition techniques for detecting motor intention of lower limbs in subjects with cerebral palsy. In *Ecuador Technical Chapters Meeting (ETCM), 2017 IEEE* (pp. 1-5). IEEE
- [58] Asanza, V., Ochoa, K., Sacarelo, C., Salazar, C., Loayza, F., Vaca, C., & Peláez, E. (2016, October). Clustering of EEG occipital signals using k-means. In *Ecuador Technical Chapters Meeting (ETCM), IEEE* (pp. 1-5). IEEE
- [59] Asanza, V., Pelaez, E., & Loayza, F. (2017, October). EEG signal clustering for motor and imaginary motor tasks on hands and feet. In *Ecuador Technical Chapters Meeting (ETCM), 2017 IEEE* (pp. 1-5). IEEE
- [60] Asanza, V., Peláez, E., Loayza, F., Mesa, I., Díaz, J., & Valarezo, E. (2018, October). EMG Signal Processing with Clustering Algorithms for motor gesture Tasks. In *2018 IEEE Third Ecuador Technical Chapters Meeting (ETCM)* (pp. 1-6). IEEE

- [61] Asanza, V., Avilés-Mendoza, K., Trivino-Gonzalez, H., Rosales-Uribe, F., Torres-Brunes, J., Loayza, F. R., ... & Tinoco-Egas, R. (2021). SSVEP-EEG Signal Classification based on Emotiv EPOC BCI and Raspberry Pi. *IFAC-PapersOnLine*, 54(15), 388-393
- [62] C. Cedeño Z., J. Cordova-Garcia, V. Asanza A., R. Ponguillo and L. Muñoz M., "k-NN-Based EMG Recognition for Gestures Communication with Limited Hardware Resources," 2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI), Leicester, United Kingdom, 2019, pp. 812-817
- [63] J. Fuentes-Gonzalez, A. Infante-Alarcón, V. Asanza and F. R. Loayza, "A 3D-Printed EEG based Prosthetic Arm," 2020 IEEE International Conference on E-health Networking, Application & Services (HEALTHCOM), Shenzhen, China, 2021, pp. 1-5, doi: 10.1109/HEALTHCOM49281.2021.9399035
- [64] Constantine, A., Asanza, V., Loayza, F. R., Peláez, E., & Peluffo-Ordóñez, D. (2021). BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control. *IFAC-PapersOnLine*, 54(15), 364-369
- [65] Asanza, V., Sánchez-Pozo, N. N., Lorente-Leyva, L. L., Peluffo-Ordóñez, D. H., Loayza, F. R., & Peláez, E. (2021). Classification of Subjects with Parkinson's Disease using Finger Tapping Dataset. *IFAC-PapersOnLine*, 54(15), 376-381
- [66] Grant, M.J.; Booth, A. A typology of reviews: An analysis of 14 review types and associated methodologies. *Health Inf. Libr. J.* 2009, 26, 91–108.
- [67] Abiri, R.; Borhani, S.; Sellers, E.W.; Jiang, Y.; Zhao, X. A comprehensive review of EEG-based brain–computer interface paradigms. *J. Neural Eng.* 2019, 16, 011001.
- [68] Asanza, V.; Peláez, E.; Loayza, F.; Lorente-Leyva, L.L.; Peluffo-Ordóñez, D.H. Identification of Lower-Limb Motor Tasks via Brain–Computer Interfaces: A Topical Overview. *Sensors* 2022, 22, 2028. <https://doi.org/10.3390/s22052028>
- [69] Asanza, Víctor; Montoya, Daniel; Peláez, Enrique; Loayza, Francis; Lorente-Leyva, Leandro L.; Peluffo-Ordóñez, Diego H.; González, Kléber (2021), "MILimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motorimagery Tasks", Mendeley Data, V2, doi: 10.17632/w9xfz56txv.2

2 Capítulo 2: Análisis del Estado del Arte

En este segundo capítulo se presentan los conceptos básicos relativos a las señales de Electroencefalografía (EEG), las bandas de frecuencia por tareas realizadas y las áreas del cerebro donde se pueden registrar. Además, se realiza un análisis del estado del arte de las técnicas utilizadas para la detección de intenciones motoras en las extremidades inferiores. Este análisis incluye aspectos tales como: Metodología Experimental, Pre-procesamiento de Datos, Extracción de Características y los Algoritmos de Clasificación basados en Deep Learning (DL).

Las recientes aplicaciones de ingeniería y neurociencia han conducido al desarrollo de sistemas de Interfaz Cerebro-Ordenador (BCI) que mejoran la calidad de vida de las personas con discapacidades motoras. Un gran número de estudios relacionados con la detección de las intenciones de movimiento de las extremidades superiores y basados en las señales de EEG han conducido al desarrollo de sistemas BCI [1-4]. Algunos trabajos [5,6] incluso utilizan estímulos visuales basados en SSVEP EEG para detectar la intención motora de los sujetos. Sin embargo, estas metodologías se limitan a la detección de las frecuencias de los estímulos visuales y no hacen uso de la actividad cortical generada durante la ejecución de tareas motoras o imagenético motora; por lo tanto, no se consideran en este estudio. Otro estudio similar [7] presenta un exoesqueleto de extremidades inferiores controlado por el cerebro para macacos rhesus, lo cual fue descartado inequívocamente ya que únicamente es de interés la actividad motora en la corteza cerebral de los humanos. Esta aplicación mejora la calidad de vida de las personas con discapacidades motoras al darles la posibilidad de controlar dispositivos de asistencia y prótesis activas. Sin embargo, la detección de las intenciones de movimiento de las extremidades inferiores ha ganado recientemente más atención por parte de la comunidad científica. El número de publicaciones sobre este tema de investigación ha crecido en los últimos tres años.

Como trabajo relacionado destacable, la literatura científica recoge el estudio de Lennon et al. [8] presentado en diciembre de 2019 y publicado en junio de 2020. Dicho trabajo revisa los estudios sobre las interfaces de los dispositivos de marcha robótica para la rehabilitación de accidentes cerebrovasculares y explora las señales relacionadas con las extremidades superiores e inferiores. Abarca los enfoques basados en las señales de EEG y Electromiográficas (EMG) (tanto de forma individual como conjunta) de forma más amplia

y exhaustiva. Así, debido a los recientes e importantes avances tanto en el diseño de dispositivos electrónicos como en las técnicas de inteligencia computacional y artificial, es necesaria una visión general actualizada y especializada.

2.1 Electroencefalografía (EEG)

El cerebro es responsable de dirigir actividades neuronales avanzadas como el aprendizaje, el lenguaje, la memoria y la inteligencia en el sistema nervioso central. Mientras el cerebro trabaja, las neuronas crean bioelectricidad, que, a su vez, genera fluctuaciones de voltaje [9]. Estas fluctuaciones pueden amplificarse y registrarse, gracias al desarrollo de la electrónica, mediante un electroencefalógrafo.

Los electrodos biomédicos del EEG miden los potenciales eléctricos en el cuero cabelludo; esas señales representan las actividades neuronales correspondientes a cada zona del cerebro [9]. Una de las aplicaciones más conocidas de las señales EEG son las BCI, que hacen que las personas con discapacidades motoras y actividad cortical residual puedan interactuar con prótesis robóticas [10].

Los procedimientos experimentales para desarrollar algoritmos de análisis e interpretación de la actividad cerebral del EEG se basan en la medición de las tareas motoras o de la actividad de las imágenes motoras. Estas señales eléctricas se adquieren en el dominio del tiempo desde el cuero cabelludo con una magnitud del orden de los microvoltios (μV) [11-13].

Hasta donde sabemos, las técnicas para detectar la actividad motora cortical correspondiente a las extremidades inferiores no han sido ampliamente exploradas. Estos potenciales eléctricos son difíciles de evaluar debido a que se originan en localizaciones profundas del cerebro, como el giro motor central, situado en la cara interna de la fisura longitudinal del cerebro [14]. Por ello, algunas técnicas de visualización topográfica basadas en datos de EEG de la actividad motora cortical se centran principalmente en las extremidades superiores [15,16]. Por ejemplo, Yoon Kyum Shin y otros [15] demuestran la diferencia en la corteza prefrontal cuando se realizan actividades motoras con las manos y cuando sólo se imagina que se mueven. En el presente trabajo, incluimos el análisis del movimiento motor e imaginario de las piernas y los pies.

2.2 Bandas de frecuencia

La actividad cortical está representada en el comportamiento de las señales EEG en un rango de frecuencias que va desde menos de 4 Hz a 140 Hz. Este rango incluye las siguientes bandas de frecuencia:

- Onda delta (δ): frecuencias inferiores a 4 Hz. Se ha detectado en bebés o adultos durante el sueño profundo [17].
- Onda Theta (θ): frecuencias entre 4 y 7 Hz. Se detecta en jóvenes y adultos en etapas de somnolencia [18].
- Onda alfa (α): frecuencias entre 8 y 12 Hz. Se detecta en jóvenes y adultos durante la baja actividad cerebral o el reposo [17].
- Onda Mu (μ): 7,5-12,5 (cuando realiza una acción motora).
 - A diferencia de la onda alfa, que se produce a una frecuencia similar sobre la corteza visual en reposo en la parte posterior del cuero cabelludo, la onda mu se encuentra sobre la corteza motora [18].
 - La onda mu se suprime incluso cuando se observa a otra persona realizando un movimiento motor o abstracto con características biológicas. Investigadores como V. S. Ramachandran [19] y sus colegas han sugerido que esto es una señal de que el sistema de neuronas espejo está involucrado en la supresión de la onda mu, aunque otros no están de acuerdo.
- Onda beta (β): 13-25/ 12,5 - 30Hz (Alerta). Esta banda se divide en tres sub-bandas: Ondas Beta bajas (12,5-16 Hz, "potencia Beta 1"), Ondas Beta (16,5-20 Hz, "potencia Beta 2") y Ondas Beta altas (20,5-28 Hz, "potencia Beta 3") [20].
- Onda gamma (γ): > 25/25 - 140 Hz (Conciencia). Se correlacionan con la actividad de las redes cerebrales a gran escala y los fenómenos cognitivos, como la memoria de trabajo, la atención y la agrupación perceptiva [21].

La tabla 2.2.1: resume las actividades mentales con sus respectivas bandas de frecuencia de la señal EEG.

Tabla 2.2.1 Actividades mentales con las bandas de frecuencia de las señales EEG. [autoría propia]

Band	Frequency (Hz)	Mental State
δ	<4	Bebés o adultos durante el sueño profundo.
θ	4 – 7	Jóvenes y adultos en etapas de somnolencia.
α	8 – 12	Jóvenes y adultos durante la baja actividad cerebral o el descanso.
μ	7.5 – 12.5	Presente en el córtex motor durante la ejecución o el pensamiento de actividades motoras.
β	16 – 31	Presente durante el pensamiento activo u ocupado, el estado de concentración, el alto estado de alerta y la ansiedad.
γ	32	Alta actividad cerebral.

La actividad cortical motora medida con sistemas EEG-BCI es más evidente en las bandas de frecuencia Alfa(α) y Beta(β), correspondientes a 7-13 Hz y 13-30 Hz, respectivamente [13]. La Densidad Espectral de Potencia (PSD) suele medir características que determinan la intención de movimiento en los rangos de frecuencia α y β [22-24]. Yong Zhang et al. [23] utilizaron los coeficientes Wavelet como características para la clasificación de tareas mentales, contribuyendo a la precisión de la resolución temporal en el algoritmo. Además, varios métodos aplican el análisis de series temporales a las señales de EEG, como el análisis de coherencia wavelet, la transformada wavelet continua, la transformada wavelet empírica y la descomposición modal empírica [25,26].

Algunos algoritmos de ML (aprendizaje supervisado y no supervisado) utilizados para detectar las intenciones de movimiento de las extremidades superiores son Máquinas de Vectores de Apoyo (SVMs) [22,27], Redes Neuronales (NN) [22], Análisis Discriminante Lineal (LDA) [22,24], y algoritmos de clustering [9,11]. Las SVM obtienen mejores resultados en la detección de intenciones de movimiento para las extremidades superiores [22,27].

2.3 Áreas del cerebro

El homúnculo de Penfield es un mapa de la corteza cerebral que muestra que hay áreas específicas del cerebro humano dedicadas a procesar las funciones motoras y sensoriales de cada parte del cuerpo [27]. Por ejemplo, las extremidades inferiores y superiores están vinculadas a determinadas áreas de la corteza motora y somatosensorial. Además, cada

miembro está asociado al lado contralateral del cerebro, es decir, el hemisferio cerebral derecho controla la actividad motora del lado izquierdo del cuerpo y viceversa. Así, si el cerebro recibe un estímulo en una parte específica de la corteza cerebral, se activará la parte del cuerpo vinculada a esa zona del cerebro [28].

La corteza somatosensorial procesa y trata la información sensorial procedente de la dermis, los músculos y las articulaciones y realiza los movimientos voluntarios de la mano [29]. Por otro lado, la corteza motora planifica, controla y ejecuta todas las acciones motoras voluntarias.

La corteza cerebral se divide en áreas que reaccionan a los estímulos del organismo y coordinan las funciones corporales [29]. Estas áreas se conocen como áreas de Brodmann, definidas y numeradas por el anatomista alemán Korbinian Brodmann en 1909 [30].

La Sociedad Americana de Electroencefalografía estandarizó el sistema internacional 10-10 con 64 electrodos para asegurar el rendimiento y la replicabilidad en la investigación del EEG [9]. El 10-10 se refiere a las distancias reales entre electrodos adyacentes, el 10% de la curva sagital central o de la curva coronal central, como se muestra en la figura 2.3.1. En el diagrama, cada letra se refiere a regiones individuales del cerebro [9]: Frontal Coronal (F), Fronto-Central/Temporal (FC/FT), Temporo-/Central-Parietal (TP/CP), Parietal Coronal (P), Anterior-Frontal Coronal (AF), Parieto-Occipital Coronal (PO) y Occipital (O). Además, la figura 2.3.1 muestra el sistema 10-10 de colocación de electrodos correspondiente a las áreas de Brodmann. Los colores representan la función de cada área: motora, somatosensorial, de atención, visual, ejecutiva, de memoria, de regulación de la emoción y del sonido.

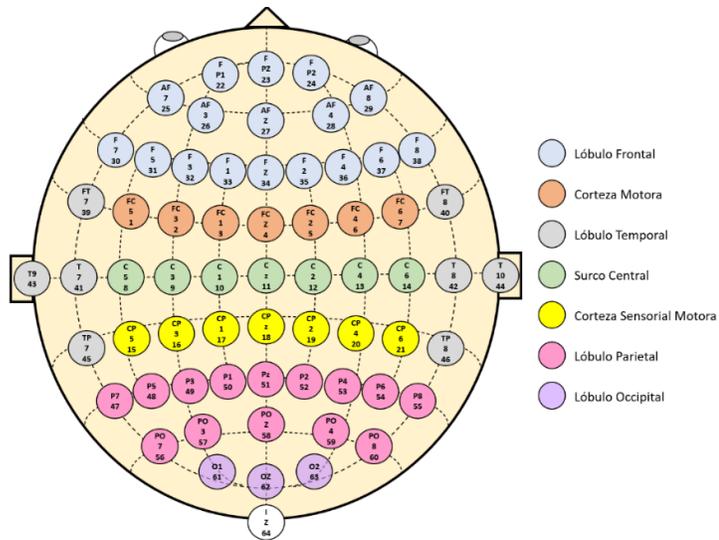


Figura 2.3.1 Áreas de Brodmann en el sistema de posicionamiento de electrodos 10-10. [autoría propia]

2.4 Metodología Experimental

La figura 2.4.1 muestra los dispositivos utilizados por los autores para el registro de las señales de EEG. Existen equipos comerciales como: ETG-4000 [30], Neuroscan [31-34], Biotop 6 R-12 [35], BrainVision ActiChamp [36], ActiCap y dos amplificadores BrainAmp (Brain Products GmbH) [37], amplificador NVX 52 [38], NuAmps [39], BrainBoard utilizando un módulo de chip ADS-1299 (una plataforma de hardware EEG de código abierto) [40], bioamplificadores NeXus-32 [41] y BCI2000 [42]. Otros autores han utilizado equipos combinados como dos amplificadores de EEG de 32 canales (Synamps, Neuroscan) [43]. Además, uno de los investigadores utilizó parte de los electrodos FP1 del Nuamps Express Neuroscan para registrar la Electrooculografía (EOG) [44]. Por último, otros autores han utilizado dos amplificadores Activos [45,46] y BrainNet BNT 36 [47,48].

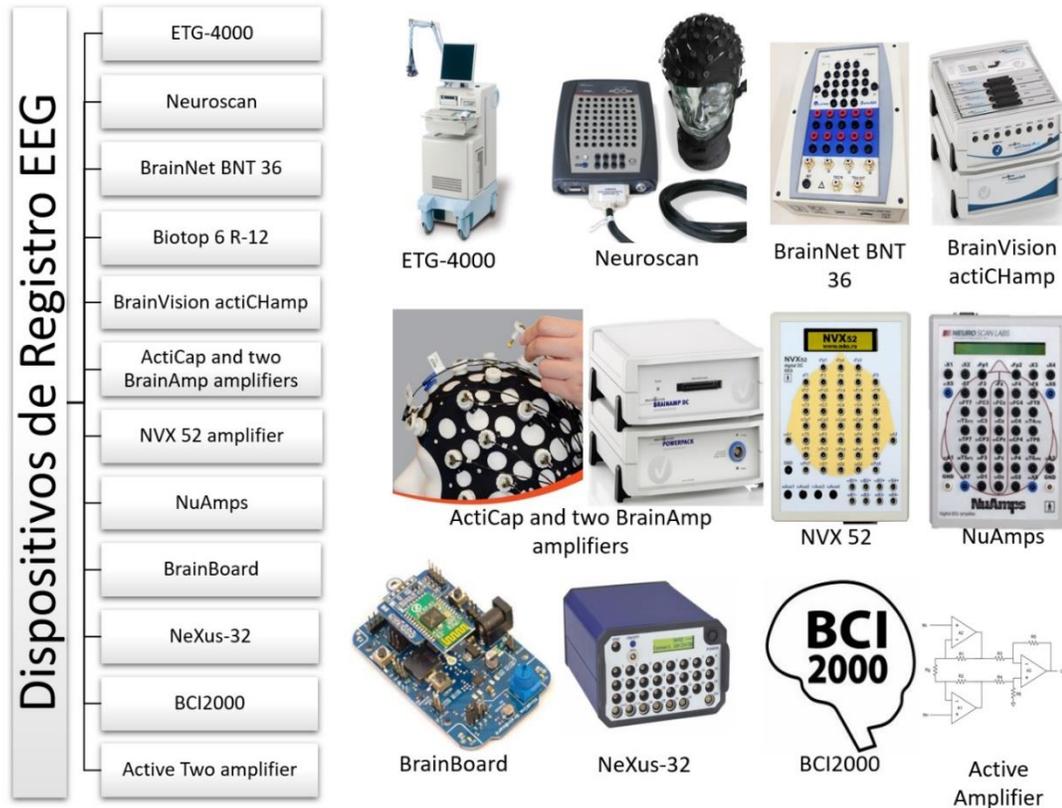


Figura 2.4.1 Dispositivos de adquisición de EEG utilizados en los trabajos revisados. Referencias bibliográficas asociadas: ETG-4000 [30], Neuroscan [31-34,43,44], BrainNet BNT 36 [47,48], Biotop 6 R-12 [35], BrainVision actiCHamp [36], ActiCap y dos amplificadores BrainAmp [37], amplificador NVX 52 [38], NuAmps [39], BrainBoard [40], NeXus-32 [41], BCI2000 [42] y amplificador Active Two [45,46]. Las imágenes que se muestran aquí están disponibles de forma gratuita en el sitio web oficial del fabricante/proveedor y se utilizan exclusivamente con fines académicos y sin ánimo de lucro. ETG-400: <https://www.usa.philips.com/healthcare/resources/landing/fnirs>; Neuroscan, NuAmps: <https://compumedicsneuroscan.com>; BrainNet BNT 36: <https://www.emsamed.com.br>; BrainVision actiCHamp, ActiCap y dos amplificadores BrainAmp: <https://brainvision.com>; amplificador NVX 52: <https://mks.ru>; BrainBoard: <https://github.com/gskelly/eeg>; Nexus-32: <https://www.biofeedback-tech.com>; BCI2000: <https://www.bci2000.org>. Último acceso (a todos ellos): 10 de febrero de 2022). [autoría propia]

2.4.1 Movimientos activos

Se consideran movimientos activos a aquellas tareas en las que los sujetos de prueba deben ejecutar de forma activa con sus extremidades inferiores durante el registro de las señales EEG.

- En su trabajo sobre el seguimiento de la actividad cortical, Gwin, J. T., y Ferris, D.P. [45] registraron señales de EEG en la banda de frecuencia de 8-30 Hz de ocho sujetos sanos diestros (siete hombres y una mujer) de entre 21 y 31 años. Los voluntarios estaban sentados y realizaban movimientos con un dispositivo de rodilla que asistía a los movimientos involuntarios durante el experimento. Las tareas que realizaron

- fueron: movimientos isométricos e isotónicos de tobillo y rodilla. Las tareas físicas se realizaron con la extremidad dominante. Como sensores adicionales, Gwin y Ferris utilizaron una célula de carga para medir la fuerza y un goniómetro para medir el ángulo de flexión. No se utilizó ninguna estimulación visual o auditiva para indicar a los voluntarios cuándo debían ejecutar el movimiento.
- Chou et al. [49] registraron señales de EEG de cinco voluntarios con una Lesión Medular (SCI). Los voluntarios se colocaron frente a un monitor durante el experimento, y un avatar les indicó cuándo debían realizar el movimiento. Con la ayuda de un exoesqueleto, realizaron movimientos de paso a la izquierda y a la derecha. No se utilizaron sensores adicionales.
 - Chang et al. [39] midieron señales de EEG en la banda de frecuencias de 0,5-25 Hz de tres voluntarios sanos en el primer experimento y de dos pacientes tras una apoplejía en el segundo (dos ensayos, uno con y otro sin el sistema de rehabilitación musical). Los voluntarios estuvieron de pie durante el experimento y utilizaron la realidad mixta y aumentada como estímulo visual para indicar cuándo ejecutar el movimiento. La tarea realizada fue caminar. Se utilizaron sensores de captura de movimiento (ángulo de la articulación de la rodilla Notch) como sensores adicionales para obtener el ángulo de flexión de la rodilla de los voluntarios.
 - Hoshino et al. [35] registraron señales de EEG en la banda de frecuencias alfa (8-12 Hz), beta (13-30 Hz), beta baja (13-19 Hz) y beta alta (20-30 Hz) de 24 pacientes que habían sufrido un accidente cerebrovascular. Los criterios de selección de los pacientes fueron: primer accidente cerebrovascular (isquémico o hemorrágico), lesión supratentorial, entre 20 y 85 años de edad, actividad independiente antes del accidente cerebrovascular y mano derecha dominante. Se incluyeron pacientes en las cuatro semanas siguientes al suceso que no perdieron toda su función motora. Como resultado, se eligieron 24 participantes con una edad media de 62 años. Los pacientes estaban acostados en una cama con los ojos cerrados durante el experimento. Las tareas realizadas fueron movimientos de tobillo, dorsiflexión y flexión plantar. No se utilizaron sensores adicionales. No se empleó ninguna estimulación visual o auditiva para indicar a los pacientes cuándo debían realizar el movimiento.
 - Choi et al. [36] adquirieron señales de EEG en la banda de frecuencia de 7-34 Hz de 10 voluntarios sanos. Todos los participantes eran hombres diestros con una edad media de 26,6 años y sin antecedentes de trastornos neurológicos. Los voluntarios

realizaban movimientos activos, y la tarea era caminar y sentarse. Se utilizó la estimulación visual para indicar a los pacientes cuándo debían ejecutar el movimiento. No se utilizaron sensores adicionales.

2.4.2 Imagenético Motor

- Estas tareas son aquellas en las que los sujetos de prueba no ejecutan de forma activa con sus extremidades inferiores. Durante el registro de las señales EEG los sujetos de prueba imaginan en primera persona el movimiento su extremidad.
- Tariq et al. [50] adquirieron señales de EEG de Desincronización Relacionada con Eventos y de Sincronización Relacionada con Eventos (ERD/ERS) de 14 voluntarios sanos. Los participantes estuvieron sentados durante el experimento y realizaron tareas de imaginación motora. No se utilizaron sensores adicionales. Se usó un monitor como estimulación visual.
- Hsu et al. [32] registraron señales de EEG en la banda de frecuencias de 8-30 Hz de ocho voluntarios sanos de entre 20 y 25 años. Las tareas realizadas por los voluntarios fueron pisadas a la izquierda y a la derecha. Se utilizó la Electrooculografía (EOG) como sensor adicional porque se empleó una pantalla como estimulación visual.
- Al-Quraishi et al. [51] midieron señales EEG de Desincronización Relacionada con Eventos (ERD) de tres voluntarios sanos y cuatro pacientes con Lesión Medular (SCI). Los participantes estaban sentados durante el experimento y realizaban imágenes motoras con la ayuda de una rodilla protésica. La tarea ejecutada fue caminar y estar al ralentí. Se utilizó una pantalla para la estimulación visual. No se usaron sensores adicionales durante el experimento.
- En su trabajo sobre la implementación de un sistema BCI, Gu et al. [33] registraron señales de EEG en la banda de frecuencias de 1-30 Hz de 11 voluntarios diestros sanos (4 hombres y 7 mujeres) de entre 22 y 27 años de edad sin antecedentes de trastornos neuromusculares. Los sujetos estuvieron sentados durante el experimento y realizaron imágenes motoras. La tarea realizada fue la dorsiflexión del pie. Se utilizó la Electrooculografía vertical y horizontal (EOG) como sensor adicional. Se empleó una pantalla como medio de estimulación visual para ejecutar las tareas cronometradas.

- Ortiz et al. [37] adquirieron señales de EEG en la banda de frecuencias de 2-60 Hz de tres voluntarios adultos sin impedimentos físicos. Los participantes estaban sentados durante el experimento y realizaban imágenes motoras. La tarea realizada fue caminar. No se utilizaron sensores adicionales. Se aplicó la estimulación auditiva para indicar la ejecución de la tarea mientras el participante pensaba en la acción.
- Do et al. [41] registraron señales de EEG a una frecuencia de muestreo de 256 Hz de dos sujetos (uno sin discapacidad y otro con paraplejia debido a una lesión medular (SCI). La tarea realizada fue la Imaginería Motora Cinestésica (KMI). La tarea consistía en caminar utilizando BCI-edRoGO a lo largo de una trayectoria lineal. Se midieron las señales EMG para descartar el control del BCI mediante movimientos voluntarios de las piernas en el sujeto sano.

2.4.3 Imagenético Motor – Movimientos Activos

Estas tareas son aquellas en las que los sujetos de prueba ejecutan de forma activa e imagenético motor con sus extremidades inferiores, durante el registro de las señales EEG.

- Gordleeva et al. [38] midieron señales de EEG en la banda de frecuencia de 8-15 Hz de ocho voluntarios sanos de 20-27 años. Se obtuvieron señales de EEG y EMG para realizar un movimiento de elevación de piernas utilizando una HMI. Las tareas realizadas fueron la imaginería motora y el movimiento activo. También se utilizaron sensores EMG para la retroalimentación del sistema de control del exoesqueleto de la extremidad inferior.
- Kline et al. [34] registraron señales de EEG en la banda de frecuencia de 8 a 45 Hz de dieciséis voluntarios varones sanos con una edad media de 24,7 años. Se recogieron datos de EEG y fMRI durante movimientos ejecutados e imaginados de las extremidades inferiores. Las tareas realizadas fueron la imaginería motora y el movimiento activo. Los participantes observaron la Imagen Generada por Ordenador (CGI) de un ser humano caminando y ejecutaron un movimiento de las extremidades inferiores o lo imaginaron siguiendo el ritmo de la CGI.
- Murphy et al. [40] adquirieron señales de EEG en la banda de frecuencias de 1-100 Hz de un hombre de 36 años que fue sometido a una amputación transfemoral derecha. Se utilizaron dos sensores adicionales de giroscopio y acelerómetro. El

sujeto realizó diez visitas de dos sesiones de prueba utilizando una prótesis de miembro inferior. Se empleó un gel conductor para rellenar el espacio entre los electrodos y el cuero cabelludo para asegurar una buena conductividad y minimizar los artefactos de ruido. En la primera visita, el sujeto fue entrenado para utilizar el sistema BCI para controlar un interruptor en una prótesis de miembro inferior. Cada visita de entrenamiento tuvo dos sesiones. Durante la primera sesión, se realizó el entrenamiento. Se registraron las señales del EEG mientras el sujeto realizaba tareas de imaginación motora de la extremidad amputada. Estos datos se utilizaron para determinar los parámetros necesarios para predecir la intención de movimiento. En la segunda sesión, estos parámetros se utilizaron para controlar un mecanismo de bloqueo de la rodilla en la prótesis en tiempo real mientras se caminaba en barras paralelas. No se introdujo sensores adicionales. Se utilizó la estimulación auditiva para indicar la ejecución de la tarea mientras el participante pensaba en la acción.

- Asanza et al. [42] emplearon una base de datos de señales EEG de 64 canales grabadas con el llamado sistema BCI2000. Tanto el sistema de adquisición como los datos se describen ampliamente en [52]. Las señales de EEG se registraron a 160 muestras por segundo de ocho sujetos sanos. Las tareas utilizadas para este estudio fueron la actividad motora y las imágenes motoras de flexión dorsal y plantar de ambos pies. No se usaron sensores adicionales.

2.4.4 Imagenético motor - Movimientos activos - Intentos de movimientos

Estas tareas son aquellas en las que los sujetos de prueba imaginan la ejecución en primera persona, ejecutan de forma activa y realizan intenciones de actividad motora con sus extremidades inferiores, durante el registro de las señales EEG.

- Jochumsen et al. [44] registraron señales de EEG en la banda de frecuencias de 0,05-10 Hz de doce sujetos sanos (dos mujeres y diez hombres: 28 ± 4 años) y seis pacientes con apoplejía de las extremidades inferiores. El sujeto estaba sentado en una silla cómoda con el pie derecho (o el pie afectado) sujeto a un pedal en el que se colocó un transductor de fuerza. Las tareas realizadas fueron movimientos ejecutados e intentados y cinética de imágenes motoras. Los sujetos sanos ejecutaron las dos

tareas con Ejecución Motora (EM) e Imaginería Motora (IM), mientras que a los pacientes con ictus se les pidió que intentaran efectuar los movimientos.

2.4.5 Intenciones de Movimiento – Movimientos Activos

Estas tareas son aquellas en las que los sujetos de prueba realizan intenciones de actividad motora y la ejecución de forma activa las tareas motoras con sus extremidades inferiores, durante el registro de las señales EEG.

- Rea et al. [30] registraron las señales del EEG de siete pacientes diestros (cuatro hombres y tres mujeres) con un ictus crónico y una edad media de 54,7 años. Los requisitos para participar en el estudio eran: un intervalo desde el ictus de al menos 12 meses, ninguna afección psiquiátrica o neurológica distinta del ictus, ninguna lesión cerebelosa o déficit motor bilateral, y capacidad para comprender y seguir instrucciones. Los sujetos estaban sentados durante el experimento y realizaban movimientos con un pedal. Las tareas ejecutadas eran movimientos de la cadera con una restricción de la rodilla y el tobillo. Los autores emplearon sensores EMG adicionales durante las tareas.
- Liu et al. [46] registraron señales de EEG en las bandas de frecuencia de 0,1-1 Hz y 0,05-2 Hz de diez voluntarios sanos (siete hombres y tres mujeres) con una edad media de 26,1 años. Los sujetos utilizaron una prensa de piernas personalizada como entrenador de la marcha durante el experimento. Se utilizaron sensores EMG y un pedal de fuerza. Además, se empleó un sensor EOG, ya que los sujetos estaban delante de un monitor con estimulación visual para indicar la ejecución de la flexión plantar.
- Delisle-Rodriguez et al. [47] y Gurve, D. et al. [48] utilizaron los mismos datos. Registraron señales de EEG en las bandas de frecuencia de 8-24 Hz [45] y 0,1-30 Hz [48] de diez voluntarios sanos (tres mujeres y siete hombres) de entre 21 y 36 años. Los voluntarios tuvieron que realizar imágenes motoras y movimientos activos. La tarea efectuada por los voluntarios consistía en pensar en pedalear durante cinco segundos y luego pedalear realmente. Se capturaron señales Superficiales de Electromiografía (sEMG) para verificar la ausencia de contracciones musculares. Se utilizó una pantalla con estimulación visual para realizar las series de movimientos de pedaleo y marcha [47,48].

2.4.6 Movimientos Asistidos

Estas tareas motoras son aquellas en las que los sujetos de prueba realizan de forma pasiva, eso significa que un dispositivo mecánico es quien mueve la extremidad del sujeto de prueba durante el registro de las señales EEG.

- Qiu et al. [31] adquirieron señales de EEG de Desincronización Relacionada con Eventos (ERD) de 12 voluntarios sanos (cinco mujeres y siete hombres) de entre 20 y 26 años y de un paciente de 56 años con hemiplejía. Los requisitos para inscribirse fueron: un mínimo de 2,5 años desde el último ictus, hemiparesia severa y dificultad para extender la rodilla derecha. Las tareas realizadas fueron elevaciones de la pierna derecha. Se utilizó una pantalla con estimulación visual para realizar las series de movimientos. No se usaron sensores adicionales.

2.4.7 Estimulación eléctrica de los miembros inferiores

Estas tareas motoras son aquellas en las que los sujetos reciben un estímulo eléctrico en la extremidad del sujeto de prueba durante el registro de las señales EEG.

- Hauck et al. [43] registraron señales de EEG de seis voluntarios diestros sanos con una edad media de 24,5 años. Además, se obtuvieron imágenes de resonancia magnética de cinco voluntarios para el registro de datos. Los sujetos estaban tumbados y se les aplicó una estimulación eléctrica de bajo amperaje en los nervios peroneo, tibial proximal y tibial distal. También se utilizaron sensores EOG.

La figura 2.4.7.1 resume todas las metodologías experimentales empleadas para registrar las señales de EEG de los miembros inferiores.

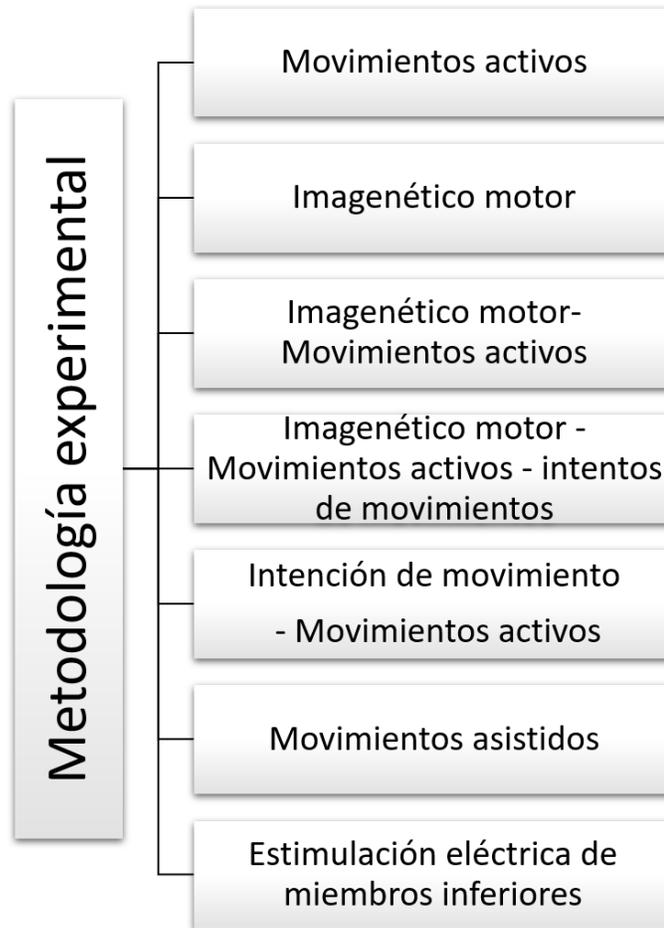


Figura 2.4.7.1 Taxonomía de alto nivel y trabajos relacionados para las metodologías experimentales de adquisición de datos. Referencias bibliográficas asociadas: movimientos activos [35,36,39,45,49], imagenético motor [32,33,37,41,50,51], imagenético motor-movimientos activos [34,38,40,42], imagenético motor - movimientos activos-intentos de movimientos [44], intención de movimiento-movimientos activos [30,46-48], movimientos asistidos [31], y estimulación eléctrica de miembros inferiores [43]. [autoría propia]

2.5 Preprocesamiento de Datos

Las señales EEG adquiridas por métodos superficiales, son muy susceptibles a ruido o artefactos provenientes de diferentes tipos de fuentes: red eléctrica, movimientos relativos entre electrodos, parpadeos, actividad muscular, frecuencia cardiaca, etc. El preprocesamiento tiene como objetivo reducir la Relación Señal Ruido (SNR) de las señales EEG [1,2,53]; para este fin, se usará, los siguientes tipos de filtros:

- Filtro Butterworth
 - Gwin y Ferris [45] utilizaron un filtro Butterworth de 1 Hz de paso alto para eliminar el ruido de las señales de EEG de movimiento activo. Se

- eliminaron los canales con una desviación estándar mayor o igual a 1 mV; se eliminaron los canales cuya curtosis era superior a tres desviaciones estándar de la media; se eliminaron los canales no correlacionados ($r \leq 0,4$) con los canales cercanos durante más del 0,1% de las muestras de tiempo.
- Liu et al. [46] excluyeron el ruido de las señales de EEG de intención de movimiento y movimiento activo utilizando un filtro Butterworth no causal de sexto orden para las bandas de frecuencia de 30-300 Hz. Además, utilizaron el Operador de Energía Teager-Kaiser (TKEO) para condicionar las señales, minimizar el ruido de fondo y reducir los artefactos de movimiento. El acondicionamiento también incluyó un filtro Butterworth de paso bajo de segundo orden no causal de 50 Hz.
 - Gurve et al. [48] suprimieron el ruido de las señales de EEG de imágenes motoras y movimiento activo utilizando un filtro Butterworth de segundo orden de 0,1 a 30 Hz y la geometría de Riemann Factorización de Matriz No Negativa (NMF).
 - Asanza et al. [42] eliminaron el ruido de las señales de EEG de actividad motora e imaginaria utilizando un filtro Butterworth de doscientos órdenes de Respuesta a Impulsos Infinitos (IIR) de 8 a 30 Hz.
- Filtro de paso bajo
 - Rea et al. [30] prescindieron del ruido de las señales de EEG de la intención de movimiento y del movimiento activo utilizando un filtro de paso bajo Wavelet de longitud de descripción mínima gaussiana de paso bajo con 4 segundos de Ancho Completo-Máximo (FWHM).
 - Hauck et al. [43] utilizaron un filtro de paso bajo por debajo de 100 Hz para eliminar el ruido de las señales EEG de los movimientos inducidos.
 - Filtro Notch
 - Qiu et al. [31] emplearon un filtro notch a 50 Hz y un downsampling a 200 Hz para eliminar el ruido de las señales EEG de intención de movimiento y de movimiento activo.
 - Delisle-Rodriguez et al. [47] eliminaron el ruido de las señales de EEG de intención de movimiento y movimiento activo utilizando un filtro de muesca a 60 Hz, un espectrograma basado en la Transformada de Fourier de Tiempo Corto (SSTFT) y la geometría de Riemann.

- Ortiz et al. [37] descartaron el ruido de las señales de EEG de intención de movimiento y movimiento activo utilizando un filtro de muesca a 60 Hz.
- Filtro de paso de banda
 - Hsu et al. [32] prescindieron del ruido de las señales de EEG de intención de movimiento y de movimiento activo utilizando un filtro de paso de banda en bandas de frecuencia de 4-40 Hz.
 - Gu et al. [33] excluyeron el ruido de las señales de EEG de la intención de movimiento y del movimiento activo utilizando un filtro de paso de banda en bandas de frecuencia de 1-30 Hz y un Análisis de Componentes Independientes (ICA).
 - Gordleeva et al. [38] usaron un filtro de paso de banda en bandas de frecuencia de 8-15 Hz para eliminar el ruido de las señales de EEG de intención de movimiento y movimiento activo.
 - Chang et al. [39] utilizaron un filtro de paso de banda en bandas de frecuencia de 1-50 Hz para eliminar el ruido de las señales de EEG de intención de movimiento y movimiento activo.
 - Hoshino et al. [35] eliminaron el ruido de las señales de EEG de intención de movimiento y movimiento activo utilizando un filtro de paso de banda en las bandas de frecuencia de 0,5-100 Hz y un análisis de regresión lineal múltiple.
 - Kline et al. [34] descartaron el ruido de la señal de EEG del desplazamiento de CC y el ruido asociado al parpadeo utilizando un filtro de paso de banda entre 5 y 55 Hz con un roll-off de 20 dB/década.
 - Murphy et al. [40] emplearon la desincronización de la señal BCI Relacionada con el Evento EEG (ERD). Para ello, usa un filtro de paso de banda para las frecuencias de la banda beta (1-100 Hz) junto con una caja de herramientas de MATLAB hecha a medida (BCI2VR).
- Filtro espacial
 - Choi et al. [36] eliminaron el ruido de la señal de EEG de la intención de movimiento y del movimiento activo utilizando FB-CSP.
 - Jochumsen et al. [44] utilizaron un Filtro Espacial Optimizado (OSF). La salida del OSF (un canal) se filtró en paso de banda de 0,05 a 10 Hz con un filtro Butterworth de segundo orden y se redujo la muestra a 20 Hz.

La figura 2.5.1 resume todas las técnicas de preprocesamiento utilizadas en las señales de EEG.

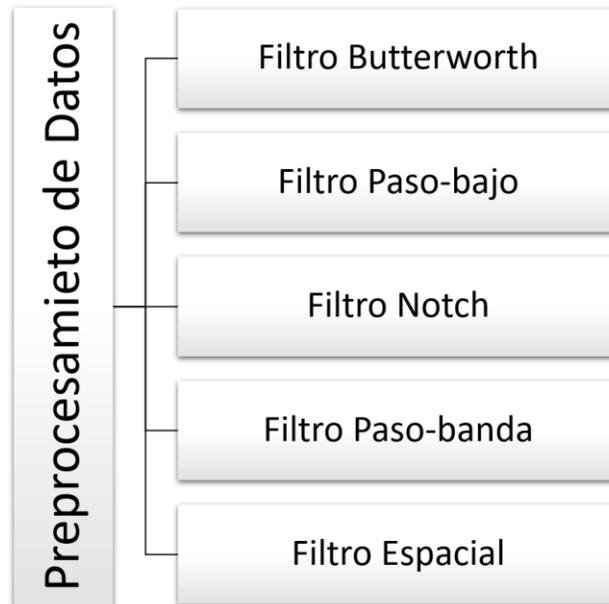


Figura 2.5.1 Taxonomía de alto nivel y trabajos relacionados con el preprocesamiento de datos. Referencias bibliográficas asociadas: filtro butterworth [42,45-47], filtro paso-bajo [30,43], filtro notch [31,37,47], filtro paso-banda [32-35,38-40], y filtro espacial [36,44]. [autoría propia]

2.6 Extracción de Características

Las señales EEG poseen información en el dominio del tiempo, razón por la cual una ventana temporal de 1 segundo de 16 electrodos a una frecuencia de 100Hz, puede representar una matriz de 100 filas por 16 columnas. Para el entrenamiento de algoritmos de inteligencia artificial se necesitan múltiples ejemplos de múltiples sujetos, esto puede conllevar una alta demanda de recursos computacionales. Por esta razón, es importante extraer características que resuman la información presente en una ventana temporal de datos EEG [42]. Existen algunos tipos de características que han sido utilizados en señales EEG como se describe a continuación:

- Dominio del tiempo
 - Jochumsen et al. [44] utilizaron seis características en el dominio del tiempo extraídas del segmento de datos de 2 segundos antes de la detección del movimiento. Las características eran: (i) la pendiente y (ii) el intercepto de una regresión lineal de todo el segmento de datos, (iii) la

pendiente y (iv) el intercepto de una regresión lineal del segmento de datos desde el punto de detección y 0,5 s antes de este punto, (v) la amplitud media de todo el segmento de datos, y (vi) el pico de máxima negatividad.

- Basadas en ERD/ERS
 - Qiu et al. [31] usaron la Perturbación Espectral Relacionada con Eventos (ERSP) y ERD para la extracción de características a partir de señales EEG altamente relacionadas con eventos en tareas de levantamiento de la pierna derecha.
 - Murphy et al. [40] aplicaron ERD para la extracción de características de la banda beta (16-24 Hz). Se calculó en tiempo real frente a la actividad de la línea de base cuando el sujeto estaba relajado.
- Basado en un banco de filtros
 - Hsu et al. [32] utilizaron el CSP de Banco de Filtros (FB-CSP) para la extracción de características a partir de señales EEG altamente relacionadas con eventos en tareas de paso a la izquierda y a la derecha y de imágenes motoras.
 - Gordleeva et al. [38] emplearon el Filtro de Patrón Espacial Común (CSP) para la extracción de características de señales EEG altamente relacionadas con eventos en tareas de imágenes motoras y de levantamiento de piernas con movimiento activo.
- Basándose en el análisis de potencia
 - Rea et al. [30] aplicaron el valor T para la extracción de características de las señales de EEG con alta resolución temporal en tareas de intención de movimiento y movimiento activo de movimientos de cadera con una restricción de rodilla y tobillo.
 - Hauck et al. [43] usaron la Relación Señal/Ruido de la potencia de campo global media (SNR) para la extracción de características de las señales de EEG de los movimientos inducidos.
 - Liu et al. [46] utilizaron las puntuaciones del índice de Gini de los nodos del árbol para la extracción de características de las señales de EEG relacionadas con la intención de movimiento y el movimiento activo.

- Chang et al. [39] emplearon el espectro de potencia sobre el canal principal para la extracción de características de señales EEG de movimiento activo al caminar.
- Ortiz et al. [37] aplicaron la Descomposición Modal Empírica (EMD) para las Funciones Modales Intrínsecas (IMFs) y la Variación de Potencia para las IMFs para la extracción de características de las señales EEG de las imágenes motoras de la marcha.
- Kline et al. [36] utilizaron el valor del espectro de potencia de todas las frecuencias estudiadas (alfa, beta y gamma) para cada electrodo del EEG.
- Do et al. [41] dispusieron de las características espacio-espectrales de la banda de frecuencias de 8-10 Hz para sujetos sanos y la banda de frecuencias de 10-12 Hz para sujetos con LME.
- Asanza et al. [42] usaron la Densidad Espectral de Potencia (PSD) de 8 a 30 Hz, calculada a 10 s de muestreo de cada electrodo de EEG.
- Basado en el Análisis de Correlación
 - Gwin y Ferris [45] aplicaron el Análisis de Componentes Independientes de Mezcla Adaptativa (AMICA) para la extracción de características de las señales EEG con una alta resolución temporal en movimientos isométricos e isotónicos de tobillo y rodilla.
 - Delisle-Rodriguez et al. [45] y Gurve, D. et al. [69] utilizaron un algoritmo de Selección de Características de Componentes de Vecindad (NCFS) para la extracción de características de las señales EEG de las imágenes motoras y del movimiento activo durante la tarea de pedaleo.
 - Gu et al. [33] usaron la Regresión Logística Multinomial Esparcida para la extracción de características de las señales EEG de las imágenes motoras durante la tarea de flexión dorsal del pie.
 - Hoshino et al. [35] aplicaron la Correlación de la Envolvente de Amplitud (AEC) para la extracción de características de las señales de EEG del movimiento activo durante los movimientos del tobillo, la flexión dorsal y la flexión plantar.
 - Choi et al. [36] utilizaron la Mejor Característica Individual basada en la Información Mutua (MIBIF) para la extracción de características de las señales EEG del movimiento activo durante la tarea de andar y sentarse.

La figura 2.6.1 resume todas las técnicas de extracción de características utilizadas en las señales de EEG registradas.

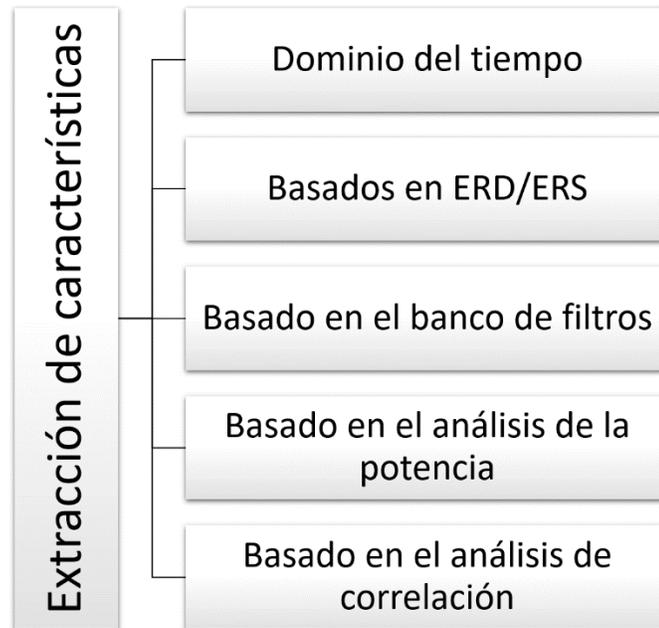


Figura 2.6.1 Taxonomía de alto nivel y trabajos relacionados para la extracción de características. Referencias bibliográficas asociadas: dominio del tiempo [44], basado en ERD/ERS [31,40], basado en banco de filtros [32,38], basado en análisis de potencia [30,34,37,39,41-43,46], y basado en análisis de correlación [33,35,36,45,47,48]. [autoría propia]

2.7 Algoritmos de Clasificación

Entre los algoritmos más utilizados en aplicaciones BCI para reconocimiento y clasificación de patrones EEG, se empieza con el uso los dos siguientes métodos sugeridos por la literatura:

- Clasificador bayesiano
 - Gwin y Ferris [45] utilizaron un clasificador lineal bayesiano ingenuo de cuatro vías para clasificar los movimientos isométricos e isotónicos de tobillo y rodilla con una precisión del 87%.
 - Do et al. [41] dispusieron de un clasificador bayesiano, realizando una validación cruzada estratificada de 10 veces y utilizando el 90% de los datos de EEG para entrenar. Este análisis fuera de línea, dio como resultado una precisión de clasificación del modelo del $94,8 \pm 0,8\%$ y del $77,8 \pm 2,0\%$ para sujetos sanos y con LME, respectivamente.
- Máquina de Vectores de Soporte (SVM)

- Hsu et al. [32] aplicaron Fuzzy SVM para clasificar las señales EEG en tareas de imágenes motoras de paso a la izquierda y a la derecha con una precisión del 86,25%.
- Gu et al. [33] utilizaron SVM para clasificar señales EEG en tareas de imágenes motoras durante la dorsiflexión del pie con una precisión del 67,13%.
- Choi et al. [36] usaron SVM para clasificar las señales EEG del movimiento activo durante la tarea de andar y sentarse, logrando una precisión del 80%.
- Jochumsen et al. [44] clasificaron las señales EEG de las tareas de movimiento ejecutado, imaginario y de intento aplicando el algoritmo de SVM con una precisión del $57 \pm 3\%$, $53 \pm 6\%$ y $47 \pm 7\%$, respectivamente.
- Liu et al. [46] utilizaron Random Forest para clasificar las señales EEG relacionadas con la intención de movimiento y el movimiento activo con una precisión del 85%.
- Análisis Lineal Discriminante (LDA)
 - Rea et al. [30] aplicaron LDA con kernel lineal para clasificar las señales de EEG en tareas de intención de movimiento y movimiento activo de movimientos de cadera con una restricción de rodilla y tobillo. Consiguieron una precisión del 67,77%.
 - Delisle-Rodriguez et al. [47] y Gurve, D. et al. [48] clasificaron las señales EEG de imágenes motoras y de movimiento activo durante la tarea de pedaleo utilizando LDA con precisiones del 92,85% y 96,66%, respectivamente.
 - Gordleeva et al. [38] clasificaron las señales de EEG en las tareas de imágenes motoras y movimiento activo de levantamiento de piernas con LDA y lograron una precisión del 65,7%.
 - Murphy et al. [40] clasificaron señales EEG de imágenes motoras con un modelo LDA offline. Este modelo se realizó para la detección en línea de la intención del sujeto de activar el interruptor mediante imágenes del movimiento de las extremidades inferiores. Los algoritmos utilizaron la caja de herramientas BCI2VR.
- Redes Neuronales (NN)

- Kline et al. [34] utilizaron una Red Neuronal (NN) implementada en Python 3.7 para clasificar el movimiento del miembro inferior derecho e izquierdo. El modelo utilizó la caja de herramientas Keras, logrando una precisión superior al 66%.
- Asanza et al. [42] emplearon una NN entrenada en Matlab y luego la implementaron en Arreglos de Compuertas Programables en Campo (FPGA). El modelo clasificó la actividad motora y las imágenes motoras de ambos pies, con precisiones del 92,1% y el 93,8%, respectivamente.

La figura 2.7.1 summarizes all the classification algorithms used on the recorded EEG signals.

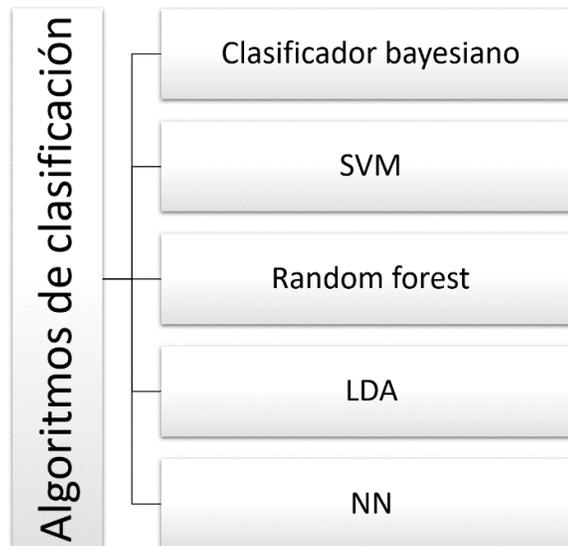


Figura 2.7.1 Taxonomía de alto nivel y trabajos relacionados con los algoritmos de clasificación. Referencias bibliográficas asociadas: clasificador bayesiano [41,45], SVM [32,33,36,44], bosque aleatorio [46], LDA [30,38,40,47,48,] y NN [34,42]. [autoría propia]

2.8 Discusión

Esta sección inicia con la discusión de las metodologías experimentales y los diferentes tipos de tareas realizadas por los voluntarios. La figura 2.8.1 resume las diferentes tareas ejecutadas por los participantes y los algoritmos reportados por los autores en las etapas de preprocesamiento, extracción de características y clasificación de las señales EEG. Estas tareas implican a las extremidades inferiores, y durante su ejecución se registraron las señales EEG de la corteza cerebral. En las aplicaciones que requieren actividad motora para controlar o probar dispositivos, los voluntarios ejecutaron tareas con movimiento

voluntario o activo [35,36,39,45,48]. En las aplicaciones destinadas a mejorar la coordinación visual y a controlar equipos protésicos, los sujetos realizaron imágenes motoras [32,33,37,40,41,49,50]. En aplicaciones de control de equipos protésicos, los voluntarios combinaron imágenes motoras [38] e intenciones de movimiento [30,42,46-48] con movimiento activo. Varios trabajos también dispusieron de tareas combinadas, como movimientos ejecutados e imaginarios para sujetos sanos e intentos de movimiento para pacientes con ictus [44]. Otras aplicaciones utilizan CGI de una persona caminando que los participantes siguieron para realizar una tarea de extremidades inferiores [34]. Por último, existen tareas relacionadas con los movimientos no voluntarios, como los movimientos inducidos [43] y los movimientos asistidos [31] para aplicaciones de rehabilitación y coordinación motora.

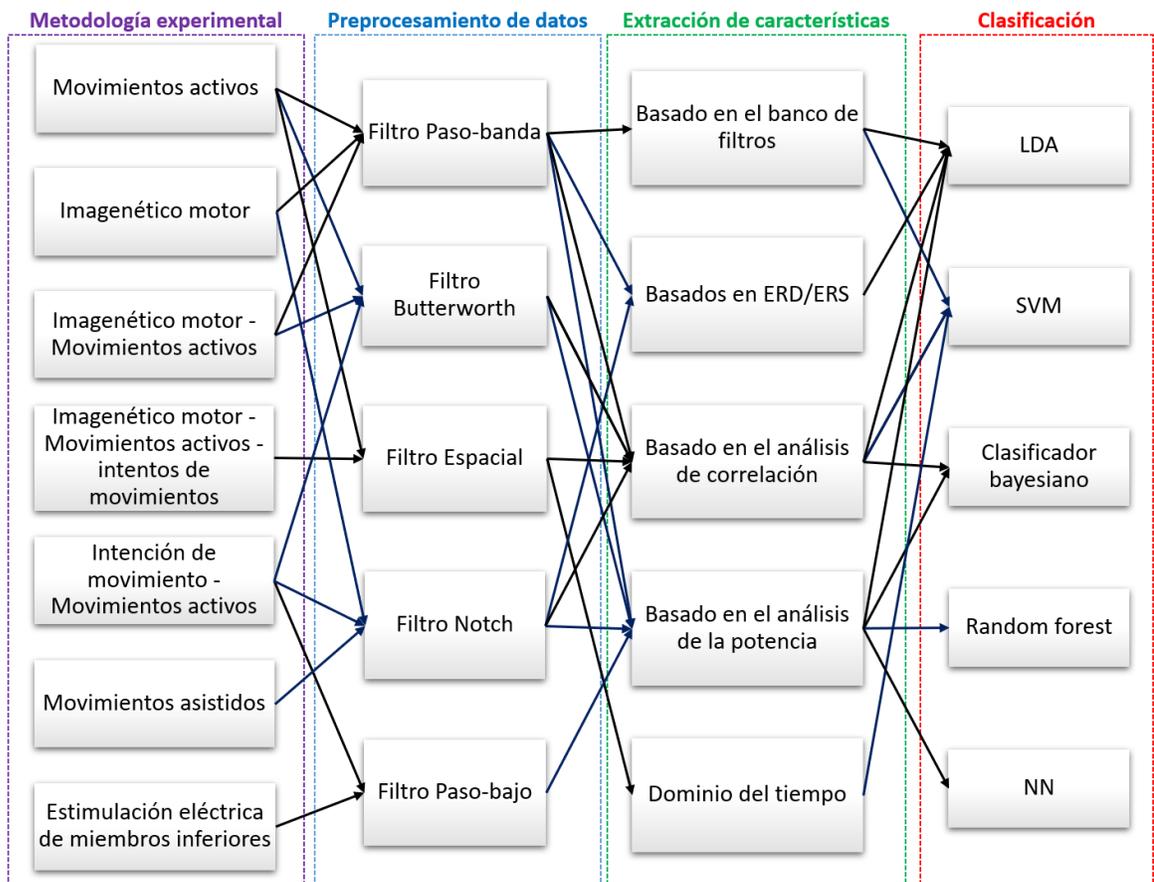


Figura 2.8.1 Diagrama de flujo conjunto que resume los tipos de tareas y algoritmos que se han utilizado en cada etapa. Referencias bibliográficas asociadas por tarea: Metodología experimental: movimientos activos [35,36,39,45,49], imaginería motora [32,33,37,41,49,50], imaginería motora-movimientos activos [34,38,40,42], imaginería motora-movimientos activos-intentos de movimiento [44], intención de movimiento-movimientos activos [30,45-47], movimientos asistidos [31], y estimulación eléctrica de miembros inferiores [43]; Preprocesamiento de datos: filtro pasa-banda [32-35,38-40], filtro butterworth [42,45,46,48], filtro espacial

[36,44], filtro notch [31,37,45], y filtro pasa-bajos [30,43]; Extracción de características: basada en banco de filtros [32,38], basada en ERD/ERS [31,40], basada en análisis de correlación [33,35,36,45,47,48], basada en análisis de potencia [30,34,37,39,41-43,46], y en el dominio del tiempo [44]; Clasificación: LDA [30,38,40,47,48], SVM [32,33,36,44], clasificador bayesiano [41,45], bosque aleatorio [46] y NN [34,42]. [autoría propia]

En cuanto a la etapa de preprocesamiento, se puede determinar que para las señales de EEG que implican movimiento activo, imágenes motoras y la combinación de ambos, se utilizan principalmente filtros pasa banda en rangos de frecuencia de 8 a 30Hz [32,33,35,38-40], capturando las ondas cerebrales Alfa (α), Mu (μ), Beta (β), así como las ondas cerebrales gamma (γ), hasta 55 Hz [34], como se muestra en la tabla 2.2.1. Además, varios trabajos informaron del uso de filtros de paso bajo para frecuencias inferiores a 100 Hz, eliminando así el ruido de las señales de EEG [30,43]. Otros autores suprimieron el ruido de la red eléctrica de las señales de EEG aplicando un filtro notch para 50 Hz [31] o 60Hz [37,47], dependiendo de la ubicación de la red eléctrica utilizada. Por otro lado, en aplicaciones relacionadas con la intención de movimiento con tareas de movimiento activo, se suelen emplear filtros Butterworth en rangos de frecuencia de 0,1 a 30 Hz, capturando las ondas cerebrales Delta (δ), Theta (θ), Alfa (α), Mu (μ) y Beta (β) [42,45,46,48]. Por último, también informamos de trabajos que utilizaron un filtro espacial para bandas de frecuencia de 0,05 a 10 Hz. Se utilizó un Filtro Espacial Optimizado (OSF), y la salida se filtró en paso de banda utilizando un filtro Butterworth de segundo orden para los movimientos ejecutados, imaginarios e intentados [44]. Para la intención de movimiento y el movimiento activo se utilizó un FB-CSP [36].

Para la etapa de extracción de características, se determinó que para las señales EEG de movimiento activo e imágenes motoras combinadas con el movimiento activo, usaron la extracción de características basada en un banco de filtros [32,38]. Para tareas como movimientos ejecutados e imaginarios para sujetos sanos e intentos de movimiento para pacientes con ictus, se utilizaron características en el dominio del tiempo [44]. Además, algunos autores aplicaron la extracción de características basada en el análisis de correlación para tareas motoras como el movimiento activo, la intención de movimiento con el movimiento activo y las imágenes motoras [33,35,36,45,47,48]. Por otro lado, otros autores utilizaron la extracción de características basada en el análisis de potencia para tareas como el movimiento activo, la intención de movimiento con movimiento activo, los movimientos inducidos y la imaginaria motora [30,34,37,39,41-43,46]. Además, se han usado técnicas basadas en ERD/ERS en tareas como los movimientos asistidos [31,40].

En la etapa de clasificación, se conoce que los autores emplearon SVM en tareas de imaginaria motora, logrando una precisión del 86,25%, 67,13% y 52,3% (promedio) [32,33,44]. Varios autores también han utilizado redes NN para clasificar el movimiento imaginario del miembro inferior izquierdo y derecho, logrando una precisión del 66,6% [34]. En la clasificación de la actividad motora y de las imágenes motoras de ambos pies, el modelo alcanzó una precisión del 92,1% y del 93,8%, respectivamente [42]. En la clasificación del movimiento activo, informaron de una precisión del 80% [36]. Los algoritmos de Clasificación basados en Naive Bayesian (NBC), la comparación de la potencia de las bandas de frecuencia se ha utilizado para clasificar las tareas de movimiento activo, logrando una precisión del 87% [35,45]. Otros algoritmos de clasificación bayesiana se usaron para clasificar las imágenes motoras cinestésicas (KMI), logrando una precisión del $94,8 \pm 0,8\%$ y del $77,8 \pm 2,0\%$ para sujetos sanos y con LME, respectivamente [41].

Algunos trabajos han utilizado el LDA para tareas como la intención de movimiento con movimiento activo, alcanzando precisiones del 67,77%, 92,85%, 96,66%, y más del 90% [30,40,47,48], y tareas de imaginaria motora con movimiento activo, con una precisión del 65,7% [38]. En las tareas de intención de movimiento con movimiento activo, se utilizó el algoritmo de clasificación Random Forest (RF), logrando una precisión del 85% [46].

2.9 Conclusiones

Este análisis se ha llevado a cabo partiendo de la base de que, por un lado, no hay un gran número de estudios basados en BCI o EEG centrados en la identificación de tareas motoras de las extremidades inferiores y, por otro lado, este tema no ha sido ampliamente explotado dentro de un marco convencional de reconocimiento de patrones (RP). Este es un aspecto importante ya que el RP proporciona ventajas sustanciales en términos de interpretabilidad y modularidad. En este estudio, se considera un sistema de RP [54] compuesto principalmente por etapas de adquisición de datos, preprocesamiento, extracción de características y clasificación. También, se presenta un resumen de artículos científicos especializados centrados en la detección de intenciones de movimiento de las extremidades inferiores mediante BCI.

En cuanto a las metodologías experimentales, se establecieron las siguientes tareas físicas para registrar las señales de EEG: para capturar las señales del movimiento activo, los

voluntarios realizaron movimientos isométricos e isotónicos de tobillo y rodilla [45]. Para adquirir las señales de las imágenes motoras y del movimiento activo, los voluntarios realizaron movimientos utilizando un sistema de control de exoesqueleto de extremidades inferiores [38]. En el caso de la imaginería motora, la adquisición de datos se llevó a cabo durante el paso de izquierda a derecha [32]. Por último, para capturar las señales de la intención de movimiento y el movimiento activo, las tareas consistían en pensar en pedalear durante un rato y luego pedalear realmente [48].

Los trabajos que informaron de la mayor precisión emplearon los siguientes algoritmos para el preprocesamiento: Filtro Butterworth en el rango de frecuencias de 8-30 Hz para clasificar las tareas de movimientos activos [45]; filtro pasa banda en el rango de frecuencias de 8-15 Hz para las tareas de imágenes motoras y movimientos activos [38]; filtro pasa banda para las frecuencias de 8-30 Hz en las tareas de imágenes motoras [32]. Finalmente, filtro Butterworth para las frecuencias de 0,1-30 Hz para las tareas de intención de movimiento y movimientos activos [48].

En la etapa de extracción de características, los trabajos con mayor precisión usaron los siguientes algoritmos: Análisis de Componentes Independientes de Mezcla Adaptativa (AMICA) para clasificar las tareas de movimiento activo [45]; Filtro de Patrones Espaciales Comunes (CSP) para tareas de imágenes motoras y movimientos activos [38]; Filtro-Banco CSP (FB-CSP) en tareas de imágenes motoras [32]; y finalmente, el algoritmo Neighborhood Component Feature Selection (NCFS) para tareas de intención de movimiento y movimientos activos [48].

En cuanto a los trabajos que realizaron la clasificación, se observa que, en la clasificación de señales durante las tareas de movimiento activo, el NBC logró la mayor precisión con un 87% [45]. Para la clasificación de la señal durante la imaginería motora cinestésica (KMI), el clasificador bayesiano logró la mayor precisión con un 94,8% [41]. En tareas de imágenes motoras y movimiento activo, LDA clasifica las intenciones motoras con una precisión del 65,7% [38]. SVM clasifica las intenciones en tareas de imaginería motora, con una precisión del 86,25% [32]. Por último, el algoritmo LDA vuelve a ser el más preciso a la hora de clasificar las intenciones motoras de las tareas de intención de movimiento y movimiento activo, con una precisión del 96,66% [48]. La tabla 2.9.1 resume los mejores algoritmos según su precisión en la clasificación de las señales durante cada tarea realizada por los voluntarios.

Tabla 2.9.1 Precisión de clasificación de los algoritmos para cada tipo de tarea. [autoría propia]

Task	Algorithm	Accuracy	Reference
Movimientos activos	Naive Bayesian Classifier	87%	[45]
Imagenético motor – Movimientos Activos	LDA	65.7%	[38]
Imagenético Motor	SVM	86.25%	[32]
Imágenes motoras cinestésicas (KMI)	Bayesian Classifier	94.8%	[41]
Intención de movimiento - Movimientos activos	LDA	96.66%	[48]

2.10 Publicaciones

Como resultado de este análisis se publicó un artículo titulado: “Identification of Lower-Limb Motor Tasks via Brain–Computer Interfaces: A Topical Overview”, el que fue publicado en la revista científica Multidisciplinary Digital Publishing Institute (MDPI) el 2022 [55].

2.11 Bibliografía

- [1] Feng, Z.; Sun, Y.; Qian, I.; Qi, Y.; Wang, Y.; Guan, C.; Sun, Y. Design a novel BCI for neurorehabilitation using concurrent LFP and EEG features: A case study. *IEEE Trans. Biomed. Eng.* 2021.
- [2] Bressan, G.; Cisotto, G.; Müller-Putz, G.R.; Wriessnegger, S.C. Deep learning-based classification of fine hand movements from low frequency EEG. *Future Internet* 2021, 13, 103.
- [3] Xu, S.; Zhu, L.; Kong, W.; Peng, Y.; Hu, H.; Cao, J. A novel classification method for EEG-based motor imagery with narrow band spatial filters and deep convolutional neural network. *Cogn. Neurody.* 2021.
- [4] Zhang, H.; Zhao, M.; Wei, C.; Mantini, D.; Li, Z.; Liu, Q. Eegdenoisenet: A benchmark dataset for deep learning solutions of eeg denoising. *J. Neural Eng.* 2021, 18, 056057.
- [5] Wang, C.; Wu, X.; Wang, Z.; Ma, Y. Implementation of a brain-computer interface on a lower-limb exoskeleton. *IEEE Access* 2018, 6, 38524–38534.
- [6] Vinoj, P.G.; Jacob, S.; Menon, V.G.; Rajesh, S.; Khosravi, M.R. Brain-Controlled Adaptive Lower Limb Exoskeleton for Rehabilitation of Post-Stroke Paralyzed. *IEEE Access* 2019, 7, 132628–132648.
- [7] Vouga, T.; Zhuang, K.Z.; Olivier, J.; Lebedev, M.A.; Nicoletis, M.A.; Bouri, M.; Bleuler, H. EXiO—A brain-controlled lower limb exoskeleton for rhesus macaques. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2017, 25, 131–141.
- [8] Lennon, O.; Tonellato, M.; Del Felice, A.; Di Marco, R.; Fingleton, C.; Korik, A.; Guanziroli, E.; Molteni, F.; Guger, C.; Othner, R.; et al. A systematic review establishing the current state-of-the-art,

the limitations, and the DESIRED checklist in studies of direct neural interfacing with robotic gait devices in stroke rehabilitation. *Front. Neurosci.* 2020, 14, 578.

[9] Comani, S.; Velluto, L.; Schinaia, L.; Cerroni, G.; Serio, A.; Buzzelli, S.; Sorbi, S.; Guarnieri, B. Monitoring neuro-motor recovery from stroke with high-resolution EEG, robotics and virtual reality: A proof of concept. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2015, 23, 1106–1116.

[10] Guger, C.; Allison, B.Z.; Mrachacz-Kersting, N. Recent Advances in Brain-Computer Interface Research—A Summary of the 2017 BCI Award and BCI Research Trends. In *Brain-Computer Interface Research*; Springer: Cham, Switzerland, 2019; pp. 115–127.

[11] Rosati, S.; Agostini, V.; Knaflitz, M.; Balestra, G. Muscle activation patterns during gait: A hierarchical clustering analysis. *Biomed. Signal Process. Control* 2017, 31, 463–469.

[12] Peng, Y. *Brain-Computer Interface for Cyberpsychology*. In *Analyzing Human Behavior in Cyberspace*; IGI Global: Hershey, PA, USA, 2019; pp. 102–122.

[13] Minguillon, J.; Lopez-Gordo, M.A.; Pelayo, F. Trends in EEG-BCI for daily-life: Requirements for artifact removal. *Biomed. Signal Process. Control* 2017, 31, 407–418.

[14] Lee, J.J.; Lee, D.R.; Shin, Y.K.; Lee, N.G.; Han, B.S.; You, S.J.H. Comparative neuroimaging in children with cerebral palsy using fMRI and a novel EEG-based brain mapping during a motor task—A preliminary investigation. *NeuroRehabilitation* 2013, 32, 279–285.

[15] Shin, Y.K.; Lee, D.R.; Hwang, H.J.; You, S.J.H.; Im, C.H. A novel EEG-based brain mapping to determine cortical activation patterns in normal children and children with cerebral palsy during motor imagery tasks. *NeuroRehabilitation* 2012, 31, 349–355.

[16] Gao, L.; Wang, J.; Chen, L. Event-related desynchronization and synchronization quantification in motor-related EEG by Kolmogorov entropy. *J. Neural Eng.* 2013, 10, 036023.

[17] Foster, J.J.; Sutterer, D.W.; Serences, J.T.; Vogel, E.K.; Awh, E. Alpha-band oscillations enable spatially and temporally resolved tracking of covert spatial attention. *Psychol. Sci.* 2017, 28, 929–941.

[18] Niedermeyer, E.; Da Silva, F.L. *Electroencephalography—Basic Principles, Clinical Applications, and Related Fields*; Urban & Schwarzenberg: Munich, Germany, 2020.

[19] Pineda, J.A. The functional significance of mu rhythms: Translating “seeing” and “hearing” into “doing”. *Brain Res. Rev.* 2005, 50, 57–68.

[20] Rangaswamy, M.; Porjesz, B.; Chorlian, D.B.; Wang, K.; Jones, K.A.; Bauer, L.O.; Rohrbaugh, J.; O’connor, S.J.; Kuperman, S.; Reich, T.; et al. Beta power in the EEG of alcoholics. *Biol. Psychiatry* 2002, 52, 831–842.

[21] McDermott, B.; Porter, E.; Hughes, D.; McGinley, B.; Lang, M.; O’Halloran, M.; Jones, M. Gamma band neural stimulation in humans and the promise of a new modality to prevent and treat Alzheimer’s disease. *J. Alzheimer’s Dis.* 2018, 65, 363–392.

[22] Bascil, M.S.; Tesneli, A.Y.; Temurtas, F. Spectral feature extraction of EEG signals and pattern recognition during mental tasks of 2-D cursor movements for BCI using SVM and ANN. *Australas. Phys. Eng. Sci. Med.* 2016, 39, 665–676.

[23] Zhang, Y.; Liu, B.; Ji, X.; Huang, D. Classification of EEG signals based on autoregressive model and wavelet packet decomposition. *Neural Process. Lett.* 2017, 45, 365–378.

[24] Chai, R.; Naik, G.R.; Nguyen, T.N.; Ling, S.H.; Tran, Y.; Craig, A.; Nguyen, H.T. Driver fatigue classification with independent component by entropy rate bound minimization analysis in an EEG-based system. *IEEE J. Biomed. Health Inform.* 2016, 21, 715–724.

- [25] Al-Qazzaz, N.K.; Hamid Bin Mohd Ali, S.; Ahmad, S.A.; Islam, M.S.; Escudero, J. Selection of Mother Wavelet Functions for Multi-Channel EEG Signal Analysis during a Working Memory Task. *Sensors* 2015, 15, 29015–29035.
- [26] Ghaderpour, E.; Pagiatakis, S.D.; Hassan, Q.K. A Survey on Change Detection and Time Series Analysis with Applications. *Appl. Sci.* 2021, 11, 6141.
- [27] Singla, R.; Haseena, B. Comparison of ssvp signal classification techniques using svm and ann models for bci applications. *Int. J. Inf. Electron. Eng.* 2014, 4, 6.
- [28] Gandhoke, G.S.; Belykh, E.; Zhao, X.; Leblanc, R.; Preul, M.C. Edwin Boldrey and Wilder Penfield's Homunculus: A life given by Mrs. Cantlie (in and out of realism). *World Neurosurg.* 2019, 132, 377–388.
- [29] Condylis, C.; Lowet, E.; Ni, J.; Bistrong, K.; Ouellette, T.; Josephs, N.; Chen, J.L. Context-dependent sensory processing across primary and secondary somatosensory cortex. *Neuron* 2020, 106, 515–525.
- [30] Rea, M.; Rana, M.; Lugato, N.; Terekhin, P.; Gizzi, L.; Brötz, D.; Fallgatter, A.; Birbaumer, N.; Sitaram, R.; Caria, A. Lower limb movement preparation in chronic stroke: A pilot study toward an fNIRS-BCI for gait rehabilitation. *Neurorehabilit. Neural Repair* 2014, 28, 564–575.
- [31] Qiu, S.; Yi, W.; Xu, J.; Qi, H.; Du, J.; Wang, C.; He, F.; Ming, D. Event-related beta EEG changes during active, passive movement and functional electrical stimulation of the lower limb. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2015, 24, 283–290.
- [32] Hsu, W.C.; Lin, L.F.; Chou, C.W.; Hsiao, Y.T.; Liu, Y.H. EEG classification of imaginary lower limb stepping movements based on fuzzy support vector machine with kernel-induced membership function. *Int. J. Fuzzy Syst.* 2017, 19, 566–579.
- [33] Gu, L.; Yu, Z.; Ma, T.; Wang, H.; Li, Z.; Fan, H. EEG-based classification of lower limb motor imagery with brain network analysis. *Neuroscience* 2020, 436, 93–109.
- [34] Kline, A.; Forkert, N.D.; Felfeliyan, B.; Pittman, D.; Goodyear, B.; Ronsky, J. fMRI-Informed EEG for brain mapping of imagined lower limb movement: Feasibility of a brain computer interface. *J. Neurosci. Methods* 2021, 363, 109339.
- [35] Hoshino, T.; Oguchi, K.; Inoue, K.; Hoshino, A.; Hoshiyama, M. Relationship between lower limb function and functional connectivity assessed by EEG among motor-related areas after stroke. *Top. Stroke Rehabil.* 2020, 28, 614–623.
- [36] Choi, J.; Kim, K.T.; Jeong, J.H.; Kim, L.; Lee, S.J.; Kim, H. Developing a motor imagery-based real-time asynchronous hybrid BCI controller for a lower-limb exoskeleton. *Sensors* 2020, 20, 7309.
- [37] Ortiz, M.; Iáñez, E.; Contreras-Vidal, J.L.; Azorín, J.M. Analysis of the EEG rhythms based on the empirical mode decomposition during motor imagery when using a lower-limb exoskeleton. A case of study. *Front. Neurobotics* 2020, 14, 48.
- [38] Gordleeva, S.Y.; Lobov, S.A.; Grigorev, N.A.; Savosenkov, A.O.; Shamshin, M.O.; Lukoyanov, M.V.; Khoruzhko, M.A.; Kazantsev, V.B. Real-time EEG–EMG human–machine interface-based control system for a lower-limb exoskeleton. *IEEE Access* 2020, 8, 84070–84081.
- [39] Chang, W.C.; Ko, L.W.; Yu, K.H.; Ho, Y.C.; Chen, C.H.; Jong, Y.J.; Huang, Y.P. EEG analysis of mixed-reality music rehabilitation system for post-stroke lower limb therapy. *J. Soc. Inf. Disp.* 2019, 27, 372–380.
- [40] Murphy, D.P.; Bai, O.; Gorgey, A.S.; Fox, J.; Lovegreen, W.T.; Burkhardt, B.W.; Atri, R.; Marquez, J.S.; Li, Q.; Fei, D.Y. Electroencephalogram-based brain–computer interface and lower-limb prosthesis control: A case study. *Front. Neurol.* 2017, 8, 696.

- [41] Do, A.H.; Wang, P.T.; King, C.E.; Chun, S.N.; Nenadic, Z. Brain-computer interface controlled robotic gait orthosis. *J. Neuroeng. Rehabil.* 2013, 10, 111.
- [42] Asanza, V.; Constantine, A.; Valarezo, S.; Peláez, E. Implementation of a Classification System of EEG Signals Based on FPGA. In *Proceedings of the 2020 Seventh International Conference on eDemocracy eGovernment (ICEDEG)*, Buenos Aires, Argentina, 22–24 April 2020; pp. 87–92.
- [43] Hauck, M.; Baumgärtner, U.; Hille, E.; Hille, S.; Lorenz, J.; Quante, M. Evidence for early activation of primary motor cortex and SMA after electrical lower limb stimulation using EEG source reconstruction. *Brain Res.* 2006, 1125, 17–25.
- [44] Jochumsen, M.; Khan Niazi, I.; Samran Navid, M.; Nabeel Anwar, M.; Farina, D.; Dremstrup, K. Online multi-class brain-computer interface for detection and classification of lower limb movement intentions and kinetics for stroke rehabilitation. *Brain-Comput. Interfaces* 2015, 2, 202–210.
- [45] Gwin, J.T.; Ferris, D.P. An EEG-based study of discrete isometric and isotonic human lower limb muscle contractions. *J. Neuroeng. Rehabil.* 2012, 9, 35.
- [46] Liu, D.; Chen, W.; Lee, K.; Chavarriaga, R.; Iwane, F.; Bouri, M.; Pei, Z.; del, R. Millán, J. EEG-based lower-limb movement onset decoding: Continuous classification and asynchronous detection. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2018, 26, 1626–1635.
- [47] Delisle-Rodriguez, D.; Cardoso, V.; Gurve, D.; Loterio, F.; Romero-Laisecca, M.A.; Krishnan, S.; Bastos-Filho, T. System based on subject-specific bands to recognize pedaling motor imagery: Towards a BCI for lower-limb rehabilitation. *J. Neural Eng.* 2019, 16, 056005.
- [48] Gurve, D.; Delisle-Rodriguez, D.; Romero-Laisecca, M.; Cardoso, V.; Loterio, F.; Bastos, T.; Krishnan, S. Subject-specific EEG channel selection using non-negative matrix factorization for lower-limb motor imagery recognition. *J. Neural Eng.* 2020, 17, 026029.
- [49] Chou, C.W.; Yu, H.Y.; Shih, Y.H.; Yiu, C.H.; Kwan, S.Y.; Yen, D.J.; Lin, Y.Y. Lateralisation value of lower limb behaviors in complex partial seizures of temporal lobe origin: A video-EEG analysis. *Seizure* 2004, 13, 35–39.
- [50] Tariq, M.; Trivailo, P.M.; Simic, M. EEG-based BCI control schemes for lower-limb assistive-robots. *Front. Hum. Neurosci.* 2018, 12, 312.
- [51] Al-Quraishi, M.S.; Elamvazuthi, I.; Daud, S.A.; Parasuraman, S.; Borboni, A. EEG-based control for upper and lower limb exoskeletons and prostheses: A systematic review. *Sensors* 2018, 18, 3342.
- [52] Schalk, G.; McFarland, D.; Hinterberger, T.; Birbaumer, N.; Wolpaw, J. BCI2000: A general-purpose brain-computer interface (BCI) system. *IEEE Trans. Biomed. Eng.* 2004, 51, 1034–1043.
- [53] Asanza, Victor; Montoya, Daniel; Peláez, Enrique; Loayza, Francis; Lorente-Leyva, Leandro L.; Peluffo-Ordóñez, Diego H.; González, Kléber (2021), “MILimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motorimagery Tasks”, Mendeley Data, V2, doi: 10.17632/w9xfz56txv.2
- [54] Duda, R.O.; Stork, D.G.; Hart, P.E. *Pattern Classification*, 2nd ed.; Wiley: Hoboken, NJ, USA, 2001.
- [55] Asanza, V.; Peláez, E.; Loayza, F.; Lorente-Leyva, L.L.; Peluffo-Ordóñez, D.H. Identification of Lower-Limb Motor Tasks via Brain–Computer Interfaces: A Topical Overview. *Sensors* 2022, 22, 2028. <https://doi.org/10.3390/s22052028>.

3 Capítulo 3 RQ1: ¿Cómo se puede detectar el patrón de actividad motora cortical de los sujetos con PCI al realizar tareas de intención motora de las extremidades inferiores?

Para responder esta pregunta de investigación, primero en la sección 3.1 se presenta una revisión literaria específica para la detección de intenciones motoras en sujetos que padecen PCI. Esta investigación permite entender cuáles son los pasos a seguir desde el registro de datos hasta la detección de actividad cortical motora en sujetos con PCI.

Luego en la sección 3.2 se propone una metodología experimental que describe detalladamente todos los aspectos que involucran el registro de señales EEG. Esta metodología experimental fue probada en 24 voluntarios, incluyendo la participación de sujetos con amputaciones en extremidades y un sujeto con PCI.

En la sección 3.3 se da respuesta a la pregunta de investigación que se analiza en este capítulo. Además, se discuten los resultados obtenidos como respuesta a esta pregunta de investigación. Finalmente, en la sección 3.4 se presentan los trabajos publicados en los papers: “Supervised pattern recognition techniques for detecting motor intention of lower limbs in subjects with cerebral palsy” [50]; y el artículo titulado “MILimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motor Imagery Tasks” [72].

3.1 Detección de intenciones motoras en sujetos con PCI

La Parálisis Cerebral (PC) es una de las principales afecciones que impiden a los sujetos que la padecen tener un control libre sobre sus miembros, actualmente el uso de señales de Electroencefalografía (EEG) para controlar los dispositivos de rehabilitación es una alternativa muy útil. Sin embargo, estas señales de EEG son susceptibles al ruido y es necesario un filtrado antes de la extracción de características y la clasificación. Existe una variedad de algoritmos que detectan las intensidades motoras en las extremidades superiores, como Máquina de Vectores de Soporte de Mínimos Cuadrados (LS-SVM), con características de densidad espectral. Sin embargo, en el presente trabajo nos proponemos determinar los algoritmos de extracción de características y clasificación que permitan detectar satisfactoriamente las intensidades motoras en miembros inferiores.

3.1.1 Introducción

El trastorno de PC infantil es una de las principales causas de deterioro psicomotor en la población más vulnerable (niños de entre 4 y 18 años) [1-3]. Una de las técnicas utilizadas para determinar la intención motora es a través del análisis de las señales presentes en la corteza motora cerebral; existen técnicas invasivas y no invasivas para captar estas señales. La técnica no invasiva de registro de señales EEG es susceptible al ruido eléctrico [4], los artefactos, los movimientos relativos, el contacto de los electrodos, el parpadeo, la actividad muscular, el ritmo cardíaco y las señales electromagnéticas ambientales, entre otros [5,6].

Las técnicas para capturar la actividad de la corteza motora en las miembros inferiores son difíciles de detectar porque se generan en el giro motor situado en la cara interna de la fisura longitudinal en la corteza motora primaria [7]. La investigación sobre la actividad cortical motora se centra principalmente en el análisis de las extremidades superiores de los niños con parálisis cerebral [8-11]; asimismo, no se ha investigado la actividad de la corteza motora en las extremidades inferiores de sujetos con parálisis cerebral, basada en la Electroencefalografía para la Interfaz Cerebro-Ordenador EEG-BCI [12].

Además, la actividad cortical motora en sujetos con parálisis cerebral (Hemiplejía, Diplejía y Tetraplejía) es proporcionalmente más alta que en los sujetos con parálisis cerebral. La Hemiplejía, Diplejía y Tetraplejía está proporcionalmente relacionada al Sistema de Clasificación de la Función Motora Gruesa (GMFCS) [8,11,13-16]. El GMFCS se divide en 5 niveles que describen las capacidades motoras de los sujetos en cada nivel, esto se describe en la tabla 3.1.1.1.

Tabla 3.1.1.1 Sistema de Clasificación de la Función Motora Gruesa (GMFCS). [autoría propia]

Nivel	Descripción
I	Función motora casi normal.
II	Marcha independiente, pero limitaciones para correr y saltar.
III	El sujeto es asistido por dispositivos para la marcha y silla de ruedas para las distancias largas.
IV	El sujeto puede ponerse de pie para las transferencias, pero tiene una mínima capacidad de caminar, utiliza una silla de ruedas para desplazarse.

v	Falta de control de la cabeza, no puede sentarse de forma independiente, es dependiente de todos los aspectos de la atención.
----------	---

Por lo tanto, las señales obtenidas del EEG de esta región motora son complejas de interpretar y comprender. Lee et al. [11], demostraron que la actividad cortical de los miembros superiores en sujetos con un nivel de PC superior a III, tiene actividad en áreas corticales irregulares, en consecuencia, en esta investigación nos centraremos en los sujetos que poseen habilidades motoras residuales de tipo I, II y III según el GMFCS (como se muestra en la tabla 3.1.1.1), facilitando la adquisición e interpretación de las señales del EEG [5].

3.1.2 Objetivos

Como objetivo general, se desea detectar las intenciones motoras de los miembros inferiores, mediante técnicas de reconocimiento de patrones supervisados y caracterización no estacionaria de señales, para la atención computarizada de sujetos con PC, que puedan ser utilizados en EEG-BCI.

Los objetivos específicos son:

- Implementar una metodología experimental basada en EEG-BCI, que permita detectar la actividad cortical motora de sujetos con PC, al realizar tareas de intención de las extremidades inferiores.
- Adaptar los actuales algoritmos de caracterización utilizados en EEG-BCI, para extraer características adecuadas de las intenciones motoras de las extremidades inferiores.
- Desarrollar una metodología, basada en algoritmos de clasificación supervisados utilizados en EEG-BCI, para realizar una detección eficiente de las intenciones motoras de las extremidades inferiores.

3.1.3 Estado del Arte

La población más afectada, por algún tipo de discapacidad, es los niños entre 4 y 18 años y los adultos mayores de 30 años [17]. El trastorno PC infantil es una de las principales causas de discapacidad psicomotriz en el paciente, siendo los niños la población más

vulnerable [1-3]. Existen técnicas de rehabilitación que mejoran las capacidades de los sujetos con PC [13]. Estas incluyen tareas motoras de los miembros superiores e inferiores, aprovechando la plasticidad cerebral, especialmente en la población infantil para mejorar el rendimiento de la actividad cortical en pacientes [18,19]. La plasticidad cerebral tiene un mejor rendimiento en niños mientras el paciente tiene habilidades motoras residuales [8,20].

La plasticidad cerebral juega un papel importante en la rehabilitación [21-24] y aún más en los niños [8,18-20], mejorando su rendimiento motor y de coordinación sensorial [8,20]; pero estas terapias suelen utilizar bioseñales generadas por la actividad muscular en pequeñas proporciones como las señales de Electromiografía (EMG), siendo un problema para las personas que han nacido con problemas motores y sin tono muscular [13,25,26]. Por ello, el uso de técnicas no invasivas mediante electrodos de superficie distribuidos con el "Sistema Internacional 10-20" [27], para obtener la actividad eléctrica del EEG en el cerebro, es una de las técnicas no invasivas más utilizadas en BCI (EEG-BCI), que requiere menos equipamiento y, por tanto, es una alternativa económica [4,28] aplicable en terapias de rehabilitación [12,29-31].

Las Interfaces Cerebro-Ordenador (BCI) permiten a los sujetos con parálisis cerebral interactuar con dispositivos que les ayudan a realizar tareas musculares [13,25,26,32]. La actividad cortical motora medida con sistemas EEG-BCI es más evidente en la banda de frecuencia de 13-30 Hz, o banda Beta, y en la banda de frecuencia de 8-12 Hz, o banda Mu [5]. Generalmente, las técnicas utilizadas para determinar las intenciones motoras en estos rangos de frecuencia (Beta y Mu) son: Medición de la Densidad Espectral de Potencia (PSD) [33-35]; medición de los Potenciales Relacionados con Eventos (ERP) [36], particularmente a los 300 ms (P300) [36,37]; la Desincronización Relacionada con Eventos (ERD) y la Sincronización Relacionada con Eventos (ERS); y, la relación característica definida como ERD/ERS [10,38,39], que permite visualizar la actividad motora cortical [40]. Estas características han sido evaluadas en estudios de sujetos con parálisis cerebral durante tareas motoras de los miembros superiores [33,41,42], y han demostrado que la actividad cortical motora es irregular, además la capacidad motora gruesa del sujeto se vuelve caótica [11].

Actualmente, el uso de técnicas de análisis de big data basadas en Inteligencia Computacional y algoritmos de aprendizaje automatizado (supervisados y no

supervisados), permiten extraer características y clasificar las intenciones motoras de los pacientes [33,43-50]. Para ejemplo, algunas de las técnicas utilizadas en la clasificación son Máquinas de Vectores de Soporte (SVM) [47,51], Red Neuronal (NN) [48-50,52], o el Análisis Discriminante Lineal (LDA) [33]. Según [33,41,42], se ha demostrado que el algoritmo SVM es capaz de detectar intenciones motoras de los miembros superiores con un mayor accuracy, las características utilizadas con PSD y ERD/ERS. La comparación de los algoritmos se muestra en la tabla 3.1.3.1.

Tabla 3.1.3.1 Comparación de algoritmos de clasificación BCI-EEG [33,41,42].

Criterios de Comparación	Características	Resultados de Clasificación
Accuracy (%)	PSD	LS-SVM > Linear-SVM > PNN > MLNN > LVQ
		Linear-SVM > LDA
	ERD/ ERS	Linear-SVM > ELM > LDA
		Adaboost-ELM > Adaboost-SVM > Adaboost-LDA
Computational time (s)	PSD	LS-SVM < PNN < LVQ < MLNN < Linear-SVM

3.1.4 Metodología

La siguiente metodología resume los pasos realizados desde el registro de datos hasta la clasificación de tareas motoras. En la siguiente sección se describe en detalle la metodología y sus resultados. Estos pasos fueron reportados por los autores de los trabajos en esta revisión literaria. La investigación se llevó a cabo en 5 etapas: Diseño experimental, recolección de datos, preprocesamiento, caracterización de señales, selección de características y finalmente, clasificación.

3.1.4.1 Diseño Experimental

El diseño experimental estableció un protocolo que incluye al sujeto que permanece sentado en una cómoda silla [53], mientras una pantalla de ordenador indica aleatoriamente las tareas a realizar. Algunas de las tareas que se reportan son las siguientes:

- Ejecución del movimiento (ME): El sujeto realiza una extensión de la extremidad superior o inferior, levantando la extremidad cómodamente como sea posible. A

continuación, el sujeto debe flexionar el miembro superior o inferior para llevarlo a la posición original [8,41,54].

- Imágenes kinestésico-motoras (KMI): El sujeto debe imaginar el movimiento de la extremidad hasta alcanzar la extensión de la extremidad superior o inferior y su flexión posterior, basándose en la experiencia cinestésica en el ejercicio ME [8].
- Observación del movimiento (OOM): El sujeto en un monitor de ordenador observa la animación de extensión y flexión del miembro superior o inferior [8].
- Imágenes visuales motoras (VMI): El sujeto reproduce mentalmente la animación de extensión y flexión de la extremidad superior o inferior observada en el ejercicio OOM [8].

Estas tareas se combinan con las siguientes instrucciones: Mano derecha, mano izquierda, ambas manos y ambos pies [55-57]. Cada tarea dura 6s, seguidos de un descanso de 10s, permitiendo que el sujeto se relaje y evite la posible fatiga. Durante la realización de la actividad, cada sujeto realiza dos veces todas las tareas. Idealmente, se repiten 5 veces cada actividad con cada sujeto [57].

3.1.4.2 Recolección de Datos

La recolección de datos se realiza con sujetos que tienen habilidades motoras residuales para realizar tareas de intención motora [5]; Por lo tanto, esta actividad se desarrolla con pacientes con PC (Hemiplejia, Diplejia y Tetraplejia) de tipo I, II y III; Según el GMFCS [13-16].

3.1.4.3 Pre-procesamiento de Datos

Los datos de EEG adquiridos por métodos superficiales son muy susceptibles al ruido o a los artefactos [5, 6]. El pre-procesamiento tiene como objetivo reducir la relación señal/ruido (SNR) de los datos de EEG en el rango de 0,1 - 60 Hz [54] (Bandas Mu y Beta); para ello utilizaremos, filtros de paso de banda de coeficientes constantes (Butterworth-IIR o Wiener-FIR) [5] utilizando el Biosig-Toolbox y Matlab como lenguaje de programación [9].

Las señales EEG filtradas se segmentan manualmente en ventanas temporales de 6 segundos [52]. Cada ventana temporal representa una de las tareas: ME, KMI, OOM y VMI.

3.1.4.4 Caracterización de Señales

En el cerebro, todas las tareas mentales y especialmente las Imagenético Motoras (IM) tienen diferentes potencias en el rango de frecuencia de los ritmos Mu y Beta [54]. Por lo tanto, comenzamos utilizando dos de los métodos sugeridos por la literatura, para la extracción de características en aplicaciones BCI:

- Welch o el Periodograma de Densidad Espectral de Potencia (PSD), que nos permite tener la distribución de potencia de la señal en función de la frecuencia [33-35].
- Desincronización Relacionada con Eventos (ERD) y Sincronización Relacionada con Evento (ERS), o también llamadas (ERD / ERS); es una característica relacionada con los Ritmos Sensoriomotores (SMR) [9,10,28,38-41,57].

3.1.4.5 Selección de Características

En las aplicaciones EEG-BCI, la combinación de diferentes tipos de características, producen datos redundantes de altas dimensiones que no contribuyen al clasificador. S. Mozaffar y R. Chai en [45,46] respectivamente, sugieren utilizar el Análisis de Componentes Independientes (ICA), que mejora el rendimiento de los algoritmos de clasificación de los algoritmos de clasificación, garantizando que las características entregadas son estadísticamente independientes y no tienen información redundante [44]. Sin embargo, hay muchas técnicas de optimización basadas en Algoritmos Genéticos (GA) [44], que podrían ser exploradas en el futuro.

3.1.4.6 Clasificación

Entre los algoritmos más utilizados en las aplicaciones BCI, para reconocimiento y clasificación de los patrones EEG, de las intenciones de los miembros superiores de la extremidad superior, utilizamos los siguientes algoritmos:

- Máquina de Vectores de Soporte de Mínimos Cuadrados (LS-SVM) con características PSD, ya que tiene una mejor tasa de éxito que el Análisis lineal (LDA) [42] y Redes Neuronales (NN), Red Neuronal Probabilística (PNN), Red Neuronal Multicapa (MLNN), Cuantificación Vectorial Quantization (LVQ) [33].

- Linear-SVM con características PSD y ERD/ERS, porque tiene una mejor tasa de éxito que Extreme Learning Machine (ELM) y LDA [41,42].
- El modelo Adaboost como la Máquina de Aprendizaje Extremo (Adaboost-ELM), que ha demostrado que con las características ERD/ERS hay más precisión en la clasificación de señales MI-EEG que con Adaboost-SVM y Adaboost-LDA [41,58,59].
- La Red Neural (NN) con características ERD/ERS, a pesar de tener un bajo índice de éxito que LSSVM y Linear-SVM, queremos determinar su rendimiento en el miembro inferior [33].

En la detección de las intensidades motoras de los miembros superiores, el algoritmo LSSVM con características PSD tiene una mejor tasa de éxito, con un menor tiempo de procesamiento, que las Redes Neuronales Artificiales [33]; Y Adaboost-ELM con características ERD/ERS tiene una mejor tasa de éxito que Adaboost-SVM y LDA [41].

Para la detección de las intensidades motoras de los miembros superiores, como se demuestra en la tabla 3.1.3.1, es posible detectar los patrones de actividad cortical motora de los sujetos con PCI. Con esto, se justifica el uso de las etapas de diseño experimental, recolección de datos, preprocesamiento, caracterización de señales, selección de características y clasificación. Además, se plantea la importancia para mejorar la calidad de vida de las personas en sujetos con PCI, mediante del desarrollo de algoritmos que permitan extraer características adecuadas de las intenciones motoras de los miembros inferiores; y, desarrollar algoritmos efectivos de clasificación supervisada para el análisis EEG-BCI.

3.2 Metodología experimental para el registro de señales EEG

En esta sección se presenta la metodología experimental desarrollada para el registro de señales de Electroencefalografía (EEG) en las extremidades superiores e inferiores. Esta metodología se ha probado en sujetos sanos, en sujetos con amputación y en un sujeto con PCI. Además, se detalla el conjunto de datos "MILimbEEG" generado con el registro de 24 sujetos de prueba.

3.2.1 Antecedentes

En los últimos años se ha investigado los sistemas robóticos basados en la Interfaz Cerebro-Ordenador (BCI) [60]. Estos sistemas proporcionan al usuario un canal de comunicación que capta la amplitud de las ondas cerebrales y las transforma en una señal controlada por ordenador, para comunicar la intención del usuario a dispositivos externos [61].

Las señales biomédicas EEG son el resultado de la medición de la diferencia de potencial eléctrico, generada en la superficie del cuero cabelludo, por la actividad neuronal correspondiente a cada área cerebral [62]. Podemos medir estas señales de forma invasiva y no invasiva, siendo este último método el que permite realizar grabaciones de bajo coste con alta resolución temporal [62]. La detección precisa y automática de la actividad neuronal de las extremidades superiores e inferiores mediante EEG puede ser útil para la rehabilitación de personas que sufren limitaciones o discapacidades de movilidad, permitiendo mejorar su calidad de vida [60].

Sin embargo, para muchas aplicaciones de BCI basadas en datos de EEG, el proceso de adquisición de datos es susceptible al ruido. En el caso de los dispositivos de EEG de bajo coste, este problema está causado principalmente por: El parpadeo; el movimiento relativo entre el cuero cabelludo y los electrodos; los cambios de impedancia entre el cuero cabelludo y los electrodos de superficie; y, el tejido adiposo o el pelo que se interpone. Las técnicas de Inteligencia Artificial (IA) se utilizan para superar estas dificultades, ya que reducen la complejidad de los datos ruidosos y aumentan la precisión de la clasificación [61,62].

La clasificación de señales de EEG ha hecho posible el desarrollo de aplicaciones de BCI. Estos avances ayudan a las personas con limitaciones de movilidad a controlar dispositivos electrónicos, robóticos o protésicos [60]. La mayoría de los estudios sobre tecnología de asistencia utilizan datos de EEG registrados en la corteza motora para clasificar la intención del sujeto [63].

Por lo tanto, los principales retos para los dispositivos BCI basados en EEG son la baja tasa de transferencia de información, la alta tasa de error y el desarrollo de técnicas de clasificación de datos EEG multiclase, especialmente para los datos procedentes de esos dispositivos de bajo coste [64]. Así, en este trabajo, proponemos una metodología

experimental para el registro de señales de EEG en sujetos, mientras realizan tareas de extremidades superiores e inferiores. Concretamente, los sujetos realizan tareas motoras y de imaginería motora.

3.2.2 Metodología

Los voluntarios fueron reclutados entre colegas investigadores de la ESPOL y pacientes del Hospital Luis Vernaza de Guayaquil, Ecuador. El registro de señales EEG de los 24 sujetos de prueba que participaron en el experimento, dio como resultado un conjunto de datos que contiene 2.976 archivos “.CSV”. Cada archivo “.CSV” tiene 501 filas, de las cuales la primera enumera los electrodos de 0 a 15, y las 500 filas restantes corresponden a 500 muestras. Además, cada archivo tiene 17 columnas, de las cuales la primera indica el número de muestreo y las 16 columnas restantes representan 16 electrodos de EEG de superficie. En esta investigación se incluye medidas estadísticas sobre la información demográfica de todos los sujetos de prueba reclutados. Por último, se detalla la metodología experimental utilizada para registrar las señales de EEG en un conjunto de datos durante la ejecución de las tareas de las extremidades superiores e inferiores. Este conjunto de datos se denomina “MILimbEEG” y contiene señales de EEG adquiridas durante tareas motoras y de imágenes motoras. Los datos recogidos facilitan la evaluación de modelos de detección y clasificación de señales EEG dedicados al reconocimiento de tareas.

Para reclutar a los sujetos de prueba, contactamos a colegas de investigación y pacientes del neurocirujano Dr. Kleber González. Como resultado, reclutamos un total de 24 sujetos adultos (sin distinción de sexo) con una edad media de 28 años. Además, los voluntarios tienen características específicas, como:

- Un sujeto de prueba con una amputación de la extremidad inferior derecha.
- Un sujeto de prueba con amputación bilateral de la extremidad superior.
- Un sujeto de prueba con Parálisis Cerebral Infantil (PCI).
- Algunos sujetos sanos de prueba son Post Covid-19 con una prueba negativa.

3.2.3 Equipamiento

Para el registro de las señales de EEG utilizamos la placa de biosensores OpenBCI Cyton + Daisy (www.openbci.com) [65]. Este dispositivo no invasivo funciona con una frecuencia

de muestreo de 125 Hz y tiene 16 electrodos secos con dos referencias de tierra, distribuidos en el sistema internacional 10-20. Además, utilizamos el auricular de EEG Ultracortex "Mark IV" [66], de tamaño medio, para colocar los 16 electrodos de EEG. Este auricular fue impreso en 3D con una impresora Prusa i3MK3S [67]. La página web con los archivos STereoLithography (STL) para imprimir el casco está disponible en el siguiente enlace: <https://github.com/Human-Machine-Interface/OpenBCI>. La figura 3.2.3.1 muestra el hardware OpenBCI (Cyton + Daisy) con los electrodos colocados en el casco.

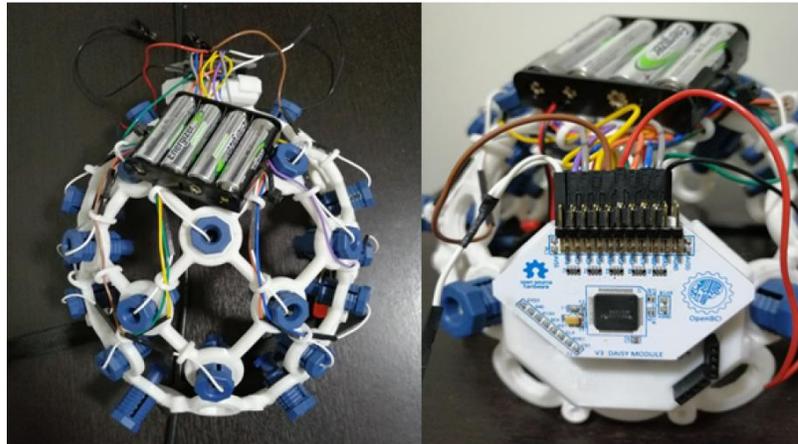


Figura 3.2.3.1 A la izquierda el casco y a la derecha la tarjeta electrónica Cyton y Dasy de OpenBCI. [autoría propia]

El dispositivo OpenBCI se conecta de forma inalámbrica al ordenador donde se ejecuta su respectivo software [65]. Este programa permite visualizar en tiempo real el registro de cada electrodo. Además, se comunica con otros programas en el mismo ordenador a través de Lab Streaming Layer (LSL). LSL es una capa de transición que transmite datos en tiempo real vía streaming [68].

Un programa de Python recibe, a través de LSL, los datos de EEG registrados por los 16 electrodos del dispositivo OpenBCI. Para poder comunicarse con Python, es necesario instalar la biblioteca pylsl. Python almacena los datos registrados como archivos de Valores Separados por Comas (CSV) en períodos fijos. El programa escrito en Python se puede encontrar en el siguiente repositorio: https://github.com/Human-Machine-Interface/OpenBCI_Data_Acquisition. La figura 3.2.3.2 muestra cómo interactúan los programas durante el registro de las señales de EEG.

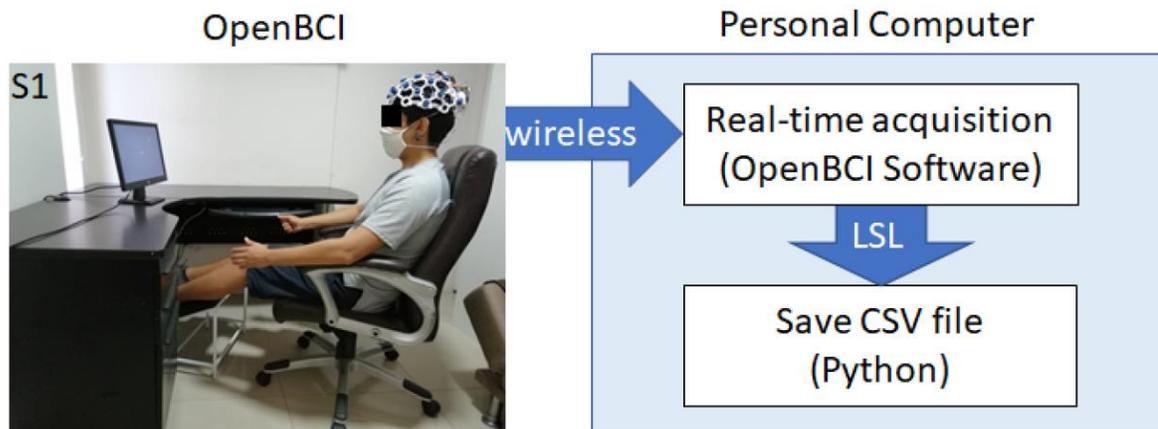


Figura 3.2.3.2 Sistema completo de adquisición de señales EEG en tiempo real para miembros superiores e inferiores. [autoría propia]

3.2.4 Consentimiento Informado

Para la recolección de datos, utilizamos formularios de consentimiento informado de cada participante, después de haberles hecho saber que los datos recogidos son confidenciales y se utilizan exclusivamente para fines de investigación. A continuación, un extracto del documento de consentimiento informado:

"Este formulario de consentimiento tiene como objetivo proporcionarle una explicación clara de la naturaleza de esta investigación y de su papel como participante. El objetivo de este estudio es registrar la actividad neuronal de los voluntarios mediante electrodos de Electroencefalografía de Superficie (EEGs) mientras realizan tareas motoras sencillas sin ningún riesgo para los participantes.

Si acepta participar en este estudio, se le pedirá que responda a preguntas en una entrevista (o que complete una encuesta, o lo que sea). Esta conversación le llevará aproximadamente 5 minutos de su tiempo. Lo que hablemos durante estas sesiones se grabará para que el investigador pueda transcribir posteriormente las ideas que usted haya expresado. La participación en este estudio es estrictamente voluntaria. La información recogida será confidencial y se utilizará exclusivamente para los fines de esta investigación. No se revelará ninguna información personal. Sus respuestas al cuestionario y a la entrevista se codificarán mediante un número de identificación, por lo que serán anónimas. Una vez transcritas las entrevistas, los archivos grabados se codificarán.

Si tiene alguna pregunta sobre este proyecto, puede formularla en cualquier momento de su participación. Asimismo, puede retirarse del proyecto en cualquier momento sin que se le penalice de ninguna manera. Si alguna de las preguntas durante la entrevista le resulta incómoda, tiene derecho a hacérselo saber al investigador o a no responderla."

Cada voluntario recibe y firma un formulario de consentimiento en el que se indica lo siguiente:

"Acepto participar en esta investigación de forma voluntaria. He sido informado de que el propósito de este estudio es recoger datos sobre la actividad cerebral mediante Electroencefalografía (EEG) no invasiva mientras se realizan tareas motoras sencillas y sin riesgo para el participante.

Considero que la información ha sido detallada y suficiente. He tenido la oportunidad de hacer preguntas y discutir el experimento en el que voy a participar. Mis preguntas han sido respondidas satisfactoriamente. Se me ha explicado claramente la finalidad de los experimentos previstos. He leído la hoja de información adjunta para los sujetos de control.

Reconozco que la información que proporcione en el curso de esta investigación es estrictamente confidencial y no se utilizará para ningún otro fin que no sea este estudio sin mi consentimiento. Se me ha informado de que puedo hacer preguntas sobre el proyecto en cualquier momento y de que puedo retirarme del mismo en cualquier momento sin ninguna sanción personal. Si tengo alguna pregunta sobre mi participación en este estudio, puedo ponerme en contacto con los investigadores en vasanza@espol.edu.ec o llamar al +593-982659680.

Entiendo que se me entregará una copia de este formulario de consentimiento y que puedo solicitar información sobre los resultados de este estudio cuando se haya completado. Para ello, puedo ponerme en contacto con Víctor Asanza en el número de teléfono o la dirección de correo electrónico indicados anteriormente. Sé que esta prueba se realiza con fines de investigación y, por tanto, doy mi consentimiento".

3.2.5 Metodología Experimental

La bioseguridad es un conjunto de criterios normados y protocolos que se deben utilizar en múltiples procedimientos realizados en investigación científica, cuyo principal objetivo es la

prevención de riesgos o infecciones derivadas de la exposición a agentes potencialmente infecciosos con riesgo biológico [69].

Durante el registro de datos, se observó a un sujeto a la vez. Los participantes no interactuaron entre sí. Seguimos las directrices de bioseguridad sobre COVID-19 establecidas por la Organización Mundial de la Salud (OMS) [70]. El uso de máscaras KN95 fue obligatorio, tanto para los sujetos de prueba como para el personal de registro. A los participantes que reportaron Covid-19 se les pidió que presenten una prueba de Covid-19 negativa antes de la grabación del EEG.

3.2.5.1 Configuración del entorno y equipos

La sala donde se registraron los datos del EEG fue adecuadamente ventilada y las superficies de contacto se desinfectaron después de realizar la prueba a cada participante. Además, el casco y los 16 electrodos secos del EEG se desinfectaron después de cada prueba. La sala de registro de datos estuvo equipada con una iluminación LED blanca artificial equivalente a 500 lux. La sala de grabación tenía paredes blancas, sin cuadros ni dibujos, que pudieran distraer la atención de los sujetos de la prueba. El entorno de la prueba estuvo climatizado a 25 grados Celsius.

El personal evita llevar ropa de colores brillantes que puedan distraer a los sujetos durante el experimento. En primer lugar, se da a cada sujeto de prueba instrucciones muy claras sobre la realización de las tareas y, a continuación, se lleva a cabo una breve sesión de prueba.

Se pide a los voluntarios se sienten en un cómodo sillón reclinable con las extremidades superiores colocadas en los reposabrazos con un ángulo de 145 grados en los codos. Mientras tanto, los miembros inferiores se apoyan en un reposapiés con una altura de 30 cm, colocado en un ángulo de 145 grados con respecto a los muslos. Para el experimento, se coloca un monitor de 17" a una distancia de 1,5 m de la cabeza del sujeto, cuidadosamente alineado con sus ojos. A continuación, se coloca el casco Ultracortex "Mark IV" en la cabeza de cada participante. Por último, utilizando el software OpenBCI como retroalimentación ya que permite ver el nivel de conexión entre el cuero cabelludo y cada electrodo EEG. Además, el software OpenBCI permite hacer uso de un filtro activo aplicado a cada uno de los 16 electrodos EEG, este filtro fue configurado en los rangos de

frecuencia entre 7 a 31Hz. La figura 3.2.5.1.1 muestra el montaje completo del experimento.

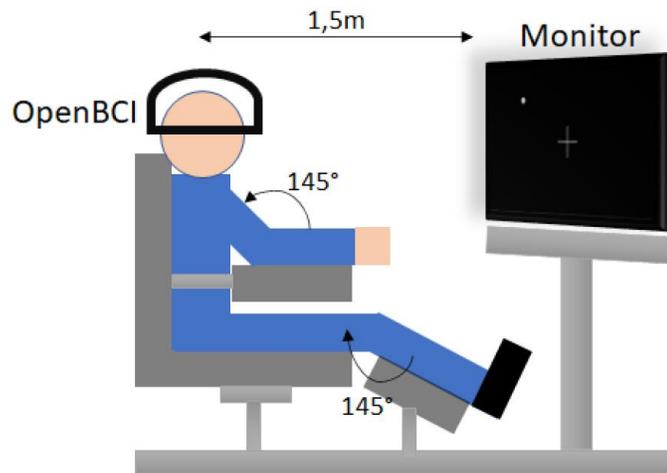


Figura 3.2.5.1.1 Configuración del Experimento. [autoría propia]

Antes de comenzar el experimento de registro de la señal de EEG, se deja al sujeto de prueba solo en la sala de registro de datos.

La secuencia, que incluye el estímulo inicial de la línea de base, se presenta una sola vez para comenzar el experimento. A continuación, se presentan los seis estímulos visuales que indican la tarea a realizar cinco veces cada uno. Por último, se presenta una señal de descanso entre las tareas. La figura 3.2.5.1.2 muestra todas las señales de los estímulos visuales.

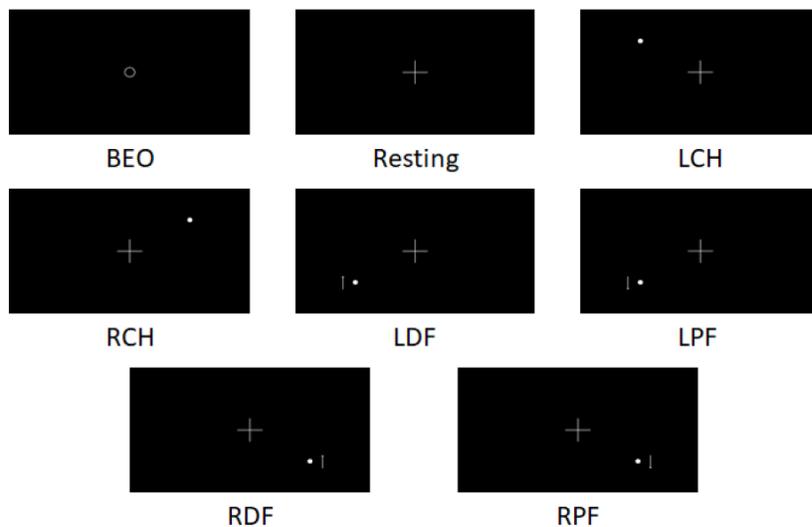


Figura 3.2.5.1.2 Estímulos visuales utilizados durante el experimento. [autoría propia]

En total, cada sujeto genera 62 archivos “.CSV” en cada experimento. Los sujetos realizan dos experimentos, uno ejecutando las tareas motoras y el otro imaginando que las realizan. Las tareas se describen a continuación:

- Registro de una línea de Base con los Ojos Abiertos (BEO) sin ninguna orden de tarea: sólo una vez al principio de cada ejecución.
- Cierre de la Mano Izquierda (CLH): cinco veces por corrida experimental.
- Cierre de la Mano Derecha (CRH): cinco veces por corrida experimental.
- Flexión Dorsal del Pie Izquierdo (DLF): cinco veces por corrida experimental.
- Flexión Plantar del Pie Izquierdo (PLF): cinco veces por corrida experimental.
- Flexión Dorsal del Pie Derecho (DRF): cinco veces por corrida experimental.
- Flexión Plantar del Pie Derecho (PRF): cinco veces por corrida experimental.
- Descanso entre tareas (Rest): después de cada tarea, en total 31 archivos.

3.2.6 Descripción de los Datos

El registro de las señales EEG del cuero cabelludo de cada sujeto de prueba, representa la actividad cerebral correspondiente a la tarea motora realizada por el sujeto de prueba. Este registro de datos se convirtió en archivos que fueron almacenados por cada experimento ejecutado por los sujetos de prueba.

Para cada uno de los 24 sujetos de prueba, creamos una carpeta con todos los archivos “.CSV” registrados. El nombre de cada carpeta lleva como prefijo la letra S seguida del ID del sujeto, por ejemplo, para el sujeto 10, el nombre de la carpeta es S10. Como se muestra en la tabla 3.2.6.1, el nombre de cada uno de los archivos “.CSV” tiene un código único que incluye el ID del sujeto, numero repetición del experimento o corrida, actividad motoras realizada, tipo de actividad motora realizada (BEO, CLH, CRH, DLF, PLF, DRF, PRF) y finalmente el número de repetición de la tarea.

Tabla 3.2.6.1 Explicación de la codificación de cada archivo “.CSV”. [autoría propia]

Identificador	Descripción	Ejemplo
Sujeto ID	Es el identificador que se asigna a cada sujeto de ensayo para ocultar su identidad.	Sx; tal que x puede ser cualquier número de 1 a 24.
Número de repetición del	Cada sujeto podía realizar el experimento más de una repetición.	Rx; tal que x puede ser cualquier número de repetición entre 1 y 4.

experimento o corrida	Sólo un sujeto se ofreció a realizar hasta 4 repeticiones.	
Actividad motora o imagenético motora	Durante cada repetición se pidió a cada sujeto que realizara una carrera ejecutando las tareas motoras (M) y otra ejecución con las tareas imagenético motoras (I).	Mx; representa una tarea de Motor y x es la Etiqueta de la tarea realizada. Ix; representa una tarea de imagenético motora y x es la etiqueta de la tarea realizada.
Etiqueta	Es el identificador de la tarea realizada donde 1 es para BEO, 2 para CLH, 3 para CRH, 4 para DLF, 5 para PLF, 6 para DRF, 7 para PRF y finalmente 8 para Rest.	M2; representa una tarea motora de CLH.
Número de repetición de la tarea	Este es el indicador de la repetición de cada tarea, cada tarea se presenta aleatoriamente hasta 5 veces por corrida.	S24R116_5 es del sujeto 24, repetición 1, tarea Imagen DRF y finalmente 5 es la repetición de esa tarea en el registro.

Los seis estímulos visuales para indicar qué tarea debe realizarse se presentan de forma aleatoria. Durante la presentación de todos los estímulos, incluido el estímulo de reposo, se registran las señales de EEG y se almacenan en archivos “.CSV”. Todos los archivos “.CSV” generados tienen 4 segundos de grabación a una frecuencia de muestreo de 125Hz.

Al final de la prueba, a todos los sujetos se les permite descansar y, a continuación, se les pide que respondan a una pequeña encuesta sobre la siguiente información:

- Nacionalidad: Ecuatoriana u otra.
- Fecha de nacimiento: Año, Mes, Día.
- Sexo: Masculino o Femenino.
- ¿Es usted diestro (RH) o zurdo (LH)?.
- Indique su Peso: en kilogramos.
- Indique su altura: en metros.
- Nivel de estudios: III nivel, II nivel o I nivel.
- ¿Consume bebidas energéticas? Sí o No.

- ¿Consume bebidas alcohólicas? Sí o No.
- ¿Fuma? Sí o No.
- ¿Practica algún deporte? Sí o No.
- ¿Está actualmente bajo tratamiento médico? Sí o No. En caso afirmativo, indique la medicación y la fecha de la última dosis.
- ¿Ha sufrido alguna pérdida de extremidades? Sí o No. En caso afirmativo, indique en qué extremidad.
- ¿Sufre algún trastorno neurológico? Sí o No. En caso afirmativo, indique cuál.
- ¿Ha sido infectado con COVID-19? Sí o No. En caso afirmativo, indique la fecha.

3.2.7 Información demográfica de los participantes

Los 24 voluntarios son de nacionalidad ecuatoriana. Sólo un participante es zurdo. Tres participantes han tenido Covid-19, pero presentan una prueba de covid-19 negativa para ser inscritos. Dos de los participantes reclutados tienen amputaciones, uno en ambas extremidades superiores y otro en la extremidad inferior derecha.

Sólo uno de los participantes tiene antecedentes médicos de enfermedad neurológica: Hidrocefalia como complicación de una intervención coronaria percutánea para tratar un infarto ventricular. Además, este voluntario es el único que declara estar tomando medicamentos, anticonvulsivos y pastillas para dormir. Otros resultados estadísticos son los siguientes:

- En cuanto al nivel de estudios: 78,6% Licenciados, 10,3% Graduados, 7,1% Básico y 4% Ninguno.
- En cuanto al consumo de bebidas energéticas: 71,4% Nunca, 14,3% Poco frecuente, 10,3% Casi nunca y 4% Nunca.
- En cuanto al consumo de alcohol 42,9% casi nunca, 28,6% con poca frecuencia, 21,4% nunca y 7,1% con frecuencia.
- En cuanto al consumo de cigarrillos: el 92,9% nunca y el 7,1% con poca frecuencia.
- En cuanto a la práctica de algún deporte: 42,9% con poca frecuencia, 28,6% con frecuencia y 28,6% casi nunca.

3.2.8 Notas de Usuario

Luego de creada la base de datos con los 24 sujetos de prueba, se procedió a realizar un análisis de clasificación de las tareas motoras. Para estas pruebas se crearon códigos en Matlab con los datos y estos son los que se describen en esta sección.

En el siguiente repositorio, presentamos un ejemplo de código programado en MatLab y los datos sobre los que podemos utilizarlo: https://github.com/Human-Machine-Interface/OpenBCI_Classification_Example . El código incluye desde el pre-procesamiento de los datos hasta su clasificación, como se detalla a continuación:

- Preparación del conjunto de datos en bruto.
- Preprocesamiento del conjunto de datos sin procesar.
- Extracción de características.
- Información estadística de Error Cuadrático Medio (RMS) en el conjunto de datos de EEG.
- Selección de características.
- Clasificación de tareas motoras y de imágenes.

3.2.8.1 Preparación del conjunto de datos en bruto

Antes de pre-procesar los datos es importante cargar la dirección donde están ubicados los datos en el workspace de Matlab, para lo cual usamos un proceso automático para la búsqueda de la ubicación de los archivos. Esto se describe a continuación:

Primero, establecemos la carpeta donde se encuentran las funciones, utilizando la función `addpath(genpath('./src'))`.

Los datos se ubican en la carpeta de datos utilizando la función `addpath(path=fullfile('./data/'))`.

Finalmente, utilizamos la función `folders = FindFolders(path)` para generar un vector con los nombres de todas las carpetas dentro de data. Como las carpetas de todos los sujetos están dentro de la carpeta data, el vector generado tiene nombres desde S1 hasta S24. Los datos pueden visualizarse utilizando la función `plot(dataNew)`, como se muestra en la figura 3.2.8.2.1 (a).

3.2.8.2 Pre-procesamiento del conjunto de datos en bruto

El pre-procesamiento de los datos es importante porque es la etapa donde podemos mejorar la calidad de los datos para mejorar la calidad de las características a ser extraídas. En este caso, se procedió a normalizar los datos registrados de cada uno de los 16 electrodos EEG, como se explica a continuación:

Antes de pre-procesar los archivos “.CSV”, hay que cargarlos con la función `readtable`, que muestra cada archivo como una tabla. Luego, con la función `dataNew=table2array(data)` convertimos el archivo de la tabla en un array de valores dobles. En la etapa de pre-procesamiento, los datos brutos se normalizan mediante la función `DataNorm = fNormalization(dataNew)`. Los datos pueden ser visualizados utilizando la función `plot(DataNorm)`, como se muestra en la figura 3.2.8.2.1 (b).

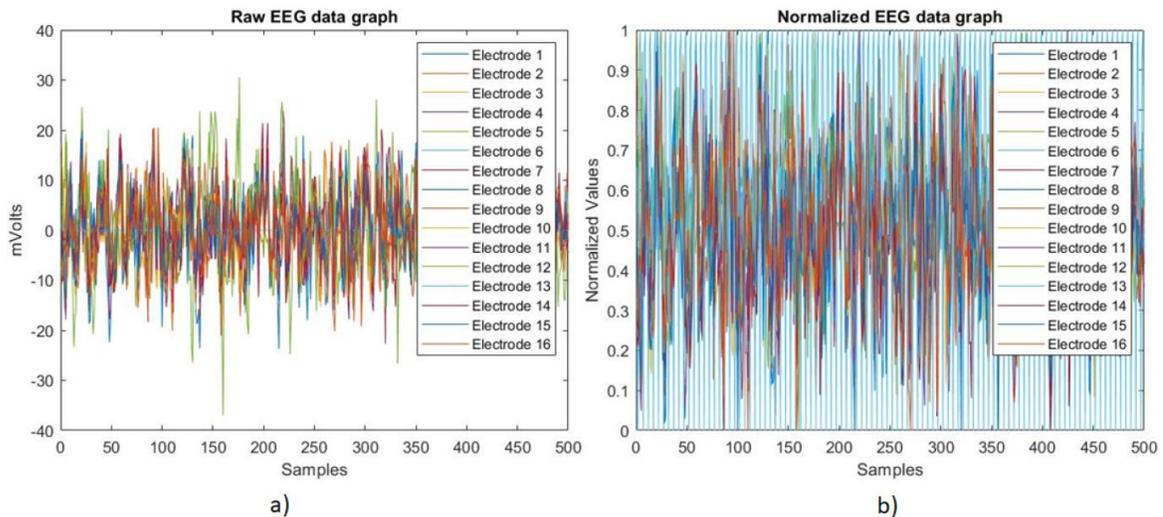


Figura 3.2.8.2.1 Gráfico de los datos de EEG sin procesar (a) y de los datos de EEG normalizados (b), del sujeto 3 y de la tarea 8 (Descanso). [autoría propia]

En esta etapa de pre-procesamiento, también creó un filtro activo en el rango de frecuencias de 7 a 31 Hz, como se indica en la sección 3.2.5.1.

3.2.8.3 Extracción de características

Cada uno de los 124 archivos generados, pertenecientes a cada sujeto representa una de las ocho tareas posibles. La función `Label = fLabelEEG(filenamees(j).name)` permite conocer la tarea a la que pertenece cada archivo. Este número se conoce como etiqueta. Se pueden utilizar muchos métodos para la extracción de características. En este código,

por ejemplo, utilizamos el valor RMS de cada electrodo por archivo, este valor es la característica extraída de cada electrodo. Así, la función `DataRMS = [rms(DataNorm) Label]`, convierte cada archivo en un vector de 16 valores al que añadimos la etiqueta respectiva según la tarea que representa. Finalmente, obtenemos una matriz de datos llamada "allData" que contiene 2976 filas x 17 columnas, tal como se muestra en la figura 3.2.8.3.1.

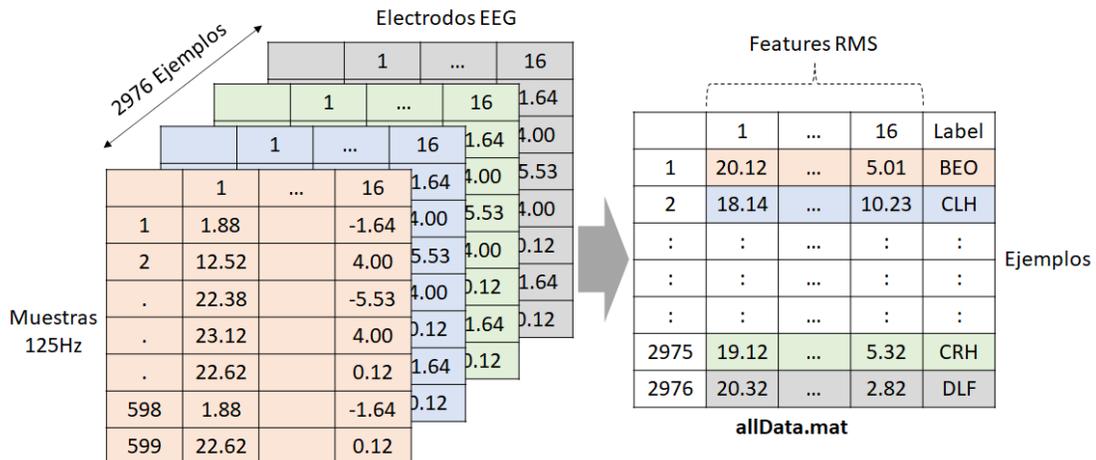


Figura 3.2.8.3.1 Gráfico de extracción de características de 2976 archivos, consolidados en un solo archivo llamado "allData" de 2976 ejemplos por 16 características y una etiqueta. [autoría propia]

3.2.8.4 Información estadística rms en el conjunto de datos de EEG

Se extrajo información estadística de cada electrodo utilizando la función `datastats`. Los electrodos muestran valores medios cercanos a cero y valores bajos de desviación estándar. Estos resultados muestran qué electrodos tienen el menor ruido de baja frecuencia (Offset Voltaje). Un ejemplo de las estadísticas calculadas desde el archivo allData se muestra en la figura 3.2.8.4.1.

```
Electrode_1 = datastats(allData(:,1))%RMS Electrode 1

Electrode_1 = struct with fields:
    num: 2981
    max: 0.8861
    min: 0.1890
    mean: 0.5340
    median: 0.5298
    range: 0.6971
    std: 0.0788
```

Figura 3.2.8.4.1 Gráfico de estadísticas determinadas de las características RMS desde el electrodo 1 analizados en el archivo allData. [autoría propia]

3.2.8.5 Selección de características

Para la selección de características, una matriz de correlación puede identificar los electrodos con una alta correlación [71]. La función `corrcoef(allData(:,1:16))` permite calcular la matriz de correlación entre electrodos. Los resultados indican que no hay electrodos altamente correlacionados y, por tanto, no tienen información redundante. Finalmente, el archivo se almacena en formato “.CSV” utilizando la función `csvwrite('AllDataRMS.csv',allData)`. Como se puede observar en la figura 3.2.8.5.1, no existen electrodos con una alta correlación, llegando en uno de los casos a obtener como valor máximo de 44% de similitud. Por esta razón no se elimino ninguno de los electrodos por tener valores mayores a un 75% de correlación [71].

```
DataFeatures=allData(:,1:16);
%corrplot(DataNorm)
R = corrcoef(DataFeatures)

R = 16x16
    1.0000    0.3258    0.0505    0.1336    0.3021    0.4249    0.2972   -0.0915 ...
    0.3258    1.0000    0.1169    0.2849    0.3231    0.4410    0.3995    0.0498
    0.0505    0.1169    1.0000    0.2200   -0.1182    0.0962    0.1569    0.2449
    0.1336    0.2849    0.2200    1.0000    0.2037    0.3318    0.4034    0.2891
    0.3021    0.3231   -0.1182    0.2037    1.0000    0.3632    0.3192   -0.0652
    0.4249    0.4410    0.0962    0.3318    0.3632    1.0000    0.7088    0.2830
    0.2972    0.3995    0.1569    0.4034    0.3192    0.7088    1.0000    0.3364
   -0.0915    0.0498    0.2449    0.2891   -0.0652    0.2830    0.3364    1.0000
    0.0580    0.0077   -0.1384    0.0303   -0.0375    0.0467   -0.0127    0.0536
    0.0687   -0.0133   -0.0554    0.1849    0.0053    0.0585    0.0217    0.2217
    ⋮
```

Figura 3.2.8.5.1 Matriz de correlación para determinar los electrodos características redundantes. [autoría propia]

3.2.8.6 Clasificación de las tareas motrices e imaginarias

En el archivo AllDataRMS, que contiene 2976 filas x 17 columnas, las primeras 16 columnas son las características y la última columna es la Etiqueta. Para cargar el archivo csv, utilizamos la función `allData = fLoad_EEG_csv(path,'AllDataRMS.csv')`, luego, con la función `fldxLabelEEG_M(allData)` [72], encontramos el índice de cada Etiqueta. Para el proceso de clasificación, se realizan las siguientes pruebas:

- Caso 1 - Toda la tarea: En esta prueba de clasificación se detectaron todas las actividades motoras (CLH, CRH, DLF, PLF, DRF, PRF) como una sola clase vs el baseline BEO.

- Caso 2 - Tarea de miembros superiores: Aquí se detectó todas las actividades motoras de extremidades superiores (CLH, CRH) como una sola clase vs el baseline BEO.
- Caso 3 - Tarea de miembros inferiores: Para este análisis se detectaron todas las actividades motoras de extremidades inferiores (DLF, PLF, DRF, PRF) como una sola clase vs el baseline BEO.
- Caso 4 - Tarea de miembros superiores derechos: Para la clasificación se detectó las actividades motoras de extremidad superior derecha (CRH) vs el baseline BEO.
- Caso 5 - Tarea de extremidades superiores izquierdas: Se clasificó las actividades motoras de extremidad superior izquierda (CLH) vs el baseline BEO.
- Caso 6 - Tarea de miembros inferiores derechos: En esta prueba de clasificación se detectó las actividades motoras de extremidad inferior derecha (DRF, PRF) vs el baseline BEO.
- Caso 7 - Tarea de miembros inferiores derechos dorsal: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (DRF) vs el baseline BEO.
- Caso 8 - Tarea de miembros inferiores derechos plantar: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (PRF) vs el baseline BEO.
- Caso 9 - Tarea de miembros inferiores izquierdos: En esta prueba de clasificación se detectó las actividades motoras de extremidad inferior izquierda (DLF, PLF) vs el baseline BEO.
- Caso 10 - Tarea de miembros inferiores izquierdos dorsal: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (DLF) vs el baseline BEO.
- Caso 11 - Tarea de miembros inferiores izquierdos plantar: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (PLF) vs el baseline BEO.

3.2.9 Resultados

Los 24 sujetos reclutados eran de nacionalidad ecuatoriana. De todos los sujetos de prueba reclutados, sólo uno era zurdo. De todos los sujetos de prueba, tres son sujetos post covid-

19, que durante la inscripción presentaron una prueba covid-19 negativa. Dos de los sujetos reclutados tienen amputaciones, uno de los sujetos en ambas extremidades superiores y otro en la extremidad inferior derecha.

De los sujetos de prueba, sólo uno presentaba el siguiente trastorno neurológico: ICP por infarto ventricular con hidrocefalia. Además, este sujeto fue el único que declaró estar tomando los siguientes medicamentos: anticonvulsivos y medicación para el sueño.

Algunos de los datos demográficos obtenidos de los voluntarios son las siguientes:

- En cuanto al nivel de estudios: 78,6% Pregrado, 10,3% Postgrado, 7,1% Básico y 4% Ninguno.
- Respecto al consumo de bebidas energéticas: 71,4% Nunca, 14,3% Poco frecuente, 10,3% Casi nunca y 4% Nunca.
- En cuanto al consumo de alcohol: El 42,9% casi nunca, el 28,6% con poca frecuencia, el 21,4% nunca y el 7,1% con frecuencia.
- En cuanto al consumo de cigarrillos: el 92,9% nunca y el 7,1% con poca frecuencia.
- En cuanto a la práctica de algún deporte: 42,9% con poca frecuencia, 28,6% con frecuencia y 28,6% casi nunca.

Los resultados obtenidos con el código de prueba y con los datos registrados en el sujeto de prueba con PC, se muestran en la Tabla 3.2.9.1.

Tabla 3.2.9.1 Resultados de la clasificación con tareas motoras e imagenético motor. [autoría propia]

Tareas	Motora	Imagenético motor
Caso 1	Less than (40.0%)	Less than (40.0%)
Caso 2	Ensemble Subspace KNN (54.7%)	Weighted KNN (55.3%)
Caso 3	Fine KNN (43.7%)	Weighted KNN (40.8%)
Caso 4	Ensemble Subspace KNN (73.3%)	Quadratic Discriminant (67.5%)
Caso 5	Ensemble Subspace KNN (74.6%)	Fine KNN (71.7%)
Caso 6	Fine KNN (58.3%)	Weighted KNN (55.0%)
Caso 7	SVM Cubic SVM (73.8%)	Weighted KNN (69.2%)
Caso 8	Ensemble Subspace KNN (73.3%)	Fine KNN (75.8%)
Caso 9	Cubic SVM (55.6%)	Weighted KNN (52.8%)
Caso 10	Medium Neural Network (73.3%)	Quadratic Discriminant (70.4%)
Caso 11	Fine KNN (67.9%)	Medium Gaussian SVM (67.9%)

3.2.10 Declaración de disponibilidad de datos

Se puede acceder a los datos relativos a las imágenes y anotaciones en:

- nombre del repositorio: MILimbEEG;
- número de identificación de los datos: DOI: 10.17632/w9xfz56txv.1;
- URL directa a los datos: <https://data.mendeley.com/datasets/w9xfz56txv/2>;
- fecha de acceso: 17 de septiembre de 2021.

3.3 Conclusiones

El trastorno de PC representa una de las principales causas de discapacidad que afecta a la calidad de vida de las personas y de sus familias, que deben dedicar tiempo a su cuidado, con un impacto directo en la economía familiar y en su relación con la sociedad [3]. Asimismo, las estadísticas de la Organización Mundial de la Salud (OMS) [73-75], muestran que la PC es la principal causa de discapacidad física en la población de niños entre 4 y 18 años, y en adultos mayores de 30 años [8]. La prevalencia mundial de la PC es de 1,5 a 5,6 casos por cada 1.000 nacidos vivos [13,26,74].

Las técnicas terapéuticas utilizadas para mejorar el control postural y el equilibrio de los sujetos con parálisis cerebral han sido: Realidad Virtual (RV) en juegos interactivos [76,77], terapia / actividades asistidas con caballos [78,79], y entrenamiento en cinta rodante [80, 81]. Además, hay técnicas de rehabilitación que utilizan con menor frecuencia: programa de psicomotricidad [82], entrenamiento de tareas dirigido a mejorar el equilibrio [83], terapia de restricción de movimientos del lado sano [84], entrenamiento de resistencia progresiva [85], electroestimulación funcional [86], cinesiterapia en suelo o piscina [2] y vibración de todo el cuerpo [87]. De las técnicas mencionadas, el entrenamiento en cinta rodante (con o sin apoyo parcial de peso) ha demostrado ser más eficaz que la aplicación de fisioterapia convencional [2].

La mayoría de los sujetos con PC no tienen la capacidad de controlar sus extremidades y la medición de las señales biomédicas que les permiten controlar los dispositivos para la rehabilitación, como los exoesqueletos en las cintas rodantes [80,81], se hace difícil. A diferencia de las señales EMG que requieren un esfuerzo muscular para generar

bioseñales [25,26], el EEG solo con movimientos de imagen genera una actividad bioeléctrica que puede ser utilizada en el control de estos dispositivos [88].

Los resultados mostrados en la tabla 3.2.9.1 nos demuestran que sí es posible realizar la detección de intenciones motoras en sujetos con PCI, llegando a obtener un accuracy de hasta un 74.6%. Las pruebas de clasificación que involucra la detección de intenciones motoras en extremidades inferiores son:

- Caso 3 - Tarea de miembros inferiores: Para este análisis se detectaron todas las actividades motoras de extremidades inferiores (DLF, PLF, DRF, PRF) como una sola clase vs el baseline BEO.
- Caso 6 - Tarea de miembros inferiores derechos: En esta prueba de clasificación se detectó las actividades motoras de extremidad inferior derecha (DRF, PRF) vs el baseline BEO.
- Caso 7 - Tarea de miembros inferiores derechos dorsal: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (DRF) vs el baseline BEO.
- Caso 8 - Tarea de miembros inferiores derechos plantar: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (PRF) vs el baseline BEO.
- Caso 9 - Tarea de miembros inferiores izquierdos: En esta prueba de clasificación se detectó las actividades motoras de extremidad inferior izquierda (DLF, PLF) vs el baseline BEO.
- Caso 10 - Tarea de miembros inferiores izquierdos dorsal: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (DLF) vs el baseline BEO.
- Caso 11 - Tarea de miembros inferiores izquierdos plantar: En esta prueba de clasificación se detectó la actividad motora de extremidad inferior derecha (PLF) vs el baseline BEO.

Los resultados mostrados en la tabla 3.2.9.1 demuestran que es posible la clasificación con un accuracy de 73.8% en la detección de actividad motora de flexión dorsal en la extremidad inferior derecha (DRF). Además, es posible detectar con un accuracy de 73.3% la actividad motora de flexión plantar en la extremidad inferior derecha (PRF).

Por otro lado, se logró clasificar con un accuracy de 73.3% la actividad motora de flexión dorsal en la extremidad inferior derecha (DLF). Finalmente, la detección de actividad motora de flexión plantar en la extremidad inferior derecha (PLF) logro obtener un accuracy de 67.9%.

Estos resultados demuestran que es posible realizar la detección de actividad motora de extremidades inferiores en sujetos con PCI. Además, la metodología experimental demuestra ser útil en el registro de señales EEG no invasiva tanto para sujeto sanos, sujetos con amputación en extremidad superior, sujetos con amputación en extremidad inferior y en sujetos con PCI leve.

Como trabajo futuro se propone, realizar el registro en más sujetos con PCI además de incluir tareas motoras basadas en movimientos asistidos por exoesqueleto. Esto debido a que en el registro de las señales EEG en el sujeto con PCI, se reportó un mayor esfuerzo en las extremidades inferiores debido a su baja tonalidad muscular.

3.4 Publicaciones

El estudio presentado en este capítulo dio como resultado un artículo científico titulado: “Supervised pattern recognition techniques for detecting motor intention of lower limbs in subjects with cerebral palsy”, el que fué presentado en el Congreso IEEE, denominado “Ecuador Technical Chapters Meeting (ETCM)”, en el 2017 [60].

El dataset presentado en este capítulo dio como resultado el artículo titulado “MILimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motor Imagery Tasks” el mismo que se encuentra disponible en el siguiente enlace: <https://data.mendeley.com/datasets/w9xfz56txv/2> [72]. Este trabajo fue enviado a la revista MDPI DATA (www.mdpi.com/journal/data) y este trabajo actualmente está en proceso de revisión.

3.5 Bibliografía

[1] Arias Armijos, M. P. (2016). Características epidemiológicas y clínicas de la parálisis cerebral, en el servicio de Hospitalización de Pediatría del Hospital Vicente Corral Moscoso. Enero 2014-Junio 2015.

[2] Gómez-Regueira, N., & Vinas-Diz, S. (2016). Mejora del control postural y equilibrio en la parálisis cerebral infantil: revisión sistemática. *Fisioterapia*, 38(4), 196-214.

- [3] Zapata, L. F. G., & Mesa, S. L. R. (2011). Alimentar y nutrir a un niño con parálisis cerebral. Una mirada desde las percepciones. *Invest Educ Enferm [Internet]*, 29(1), 28-39.
- [4] Gomez-Pilar, J., Corralejo, R., Nicolas-Alonso, L. F., Álvarez, D., & Hornero, R. (2016). Neurofeedback training with a motor imagery-based BCI: neurocognitive improvements and EEG changes in the elderly. *Medical & biological engineering & computing*, 1-12.
- [5] Minguillon, J., Lopez-Gordo, M. A., & Pelayo, F. (2017). Trends in EEGBCI for daily-life: Requirements for artifact removal. *Biomedical Signal Processing and Control*, 31, 407-418.
- [6] Guger, C., Schlogl, A., Neuper, C., Walterspacher, D., Strein, T., & Pfurtscheller, G. (2001). Rapid prototyping of an EEG-based braincomputer interface (BCI). *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 9(1), 49-58.
- [7] 'The Central Nervous System' (Online), Available: <http://classes.midlandstech.edu/carterp/Courses/bio210/Chap12/lecture1.htm>, (Accessed:4-2-2017)
- [8] Shin, Y. K., Lee, D. R., Hwang, H. J., You, S. J. H., & Im, C. H. (2012). A novel EEG-based brain mapping to determine cortical activation patterns in normal children and children with cerebral palsy during motor imagery tasks. *NeuroRehabilitation*, 31(4), 349-355.
- [9] Müller-Putz, G. R., Scherer, R., Pfurtscheller, G., & Rupp, R. (2005). EEG-based neuroprosthesis control: a step towards clinical practice. *Neuroscience letters*, 382(1), 169-174.
- [10] Gao, L., Wang, J., & Chen, L. (2013). Event-related desynchronization and synchronization quantification in motor-related EEG by Kolmogorov entropy. *Journal of neural engineering*, 10(3), 036023.
- [11] Lee, J. J., Lee, D. R., Kyum Shin, Y., Lee, N. G., Han, B. S., & You, S. J. H. (2013). Comparative neuroimaging in children with cerebral palsy using fMRI and a novel EEG-based brain mapping during a motor task—a preliminary investigation. *NeuroRehabilitation*, 32(2), 279-285.
- [12] Kinney-Lang, E., Auyeung, B., & Escudero, J. (2016). Expanding the (kaleido) scope: exploring current literature trends for translating electroencephalography (EEG) based brain–computer interfaces for motor rehabilitation in children. *Journal of Neural Engineering*, 13(6), 061002.
- [13] Gómez-Regueira, N., & Vinas-Diz, S. (2016). Mejora del control postural y equilibrio en la parálisis cerebral infantil: revisión sistemática. *Fisioterapia*, 38(4), 196-214.
- [14] Agarwal, A., & Verma, I. (2012). Cerebral palsy in children: An overview. *Journal of clinical orthopaedics and trauma*, 3(2), 77-81.
- [15] Rosero Cobos, A. M. (2014). Influencia de las Actividades de Integración Sensorial en el Desarrollo Psicomotor en niños con Parálisis Cerebral de 2 a 6 años que asisten al Instituto de Educación Especial del Carchi.
- [16] Arias Armijos, M. P. (2016). Características epidemiológicas y clínicas de la parálisis cerebral, en el servicio de Hospitalización de Pediatría del Hospital Vicente Corral Moscoso. Enero 2014-Junio 2015.
- [17] <http://www.consejodiscapacidades.gob.ec/estadistica/index.html>
- [18] Johnston, M. V. (2004). Clinical disorders of brain plasticity. *Brain and Development*, 26(2), 73-80.
- [19] Boatman, D., Freeman, J., Vining, E., Pulsifer, M., Miglioretti, D., Minahan, R., ... & McKhann, G. (1999). Language recovery after left hemispherectomy in children with late-onset seizures. *Annals of neurology*, 46(4), 579-586.

- [20] Das, A. K., Suresh, S., & Sundararajan, N. (2016). A discriminative subject-specific spatio-spectral filter selection approach for EEG based motor-imagery task classification. *Expert Systems with Applications*, 64, 375-384.
- [21] Mrachacz-Kersting, N., Jiang, N., Stevenson, A. J. T., Niazi, I. K., Kostic, V., Pavlovic, A., ... & Farina, D. (2016). Efficient neuroplasticity induction in chronic stroke patients by an associative brain-computer interface. *Journal of neurophysiology*, 115(3), 1410-1421.
- [22] Pichiorri, F., Fallani, F. D. V., Cincotti, F., Babiloni, F., Molinari, M., Kleih, S. C., ... & Mattia, D. (2011). Sensorimotor rhythm-based brain-computer interface training: the impact on motor cortical responsiveness. *Journal of neural engineering*, 8(2), 025020.
- [23] Young, B. M., Nigogosyan, Z., Walton, L. M., Song, J., Nair, V. A., Grogan, S. W., ... & Williams, J. C. (2015). Changes in functional brain organization and behavioral correlations after rehabilitative therapy using a brain-computer interface. Interaction of BCI with the underlying neurological conditions in patients: pros and cons.
- [24] Daly, J. J., & Wolpaw, J. R. (2008). Brain-computer interfaces in neurological rehabilitation. *The Lancet Neurology*, 7(11), 1032-1043.
- [25] Toledo-González M. Concepto. Etiología. Alto riesgo del recién nacido. In Toledo González M, ed. *Parálisis cerebral*. Madrid: Departamento de estudios y publicaciones del SEREM; 1977. p. 25-45.
- [26] Bringas-Grande, A., Fernández-Luque, A., García-Alfaro, C., Barrera-Chacon, M., Toledo-Gonzalez, M., & Domínguez Roldan, J. M. (2002). Parálisis cerebral infantil: estudio de 250 casos. *Rev Neurol*, 35(9), 812-17.
- [27] Jasper, H. H. (1958). The ten twenty electrode system of the international federation. *Electroencephalography and clinical neurophysiology*, 10, 371-375.
- [28] Guger, C., Daban, S., Sellers, E., Holzner, C., Krausz, G., Carabalona, R., ... & Edlinger, G. (2009). How many people are able to control a P300-based brain-computer interface (BCI)?. *Neuroscience letters*, 462(1), 94-98.
- [29] Ang, K. K., Chua, K. S. G., Phua, K. S., Wang, C., Chin, Z. Y., Kuah, C. W. K., ... & Guan, C. (2014). A randomized controlled trial of EEG-based motor imagery brain-computer interface robotic rehabilitation for stroke. *Clinical EEG and neuroscience*, 1550059414522229.
- [30] Wolpaw, J. R. (2007). Brain-computer interfaces as new brain output pathways. *The Journal of physiology*, 579(3), 613-619.
- [31] Koo, B., Lee, H. G., Nam, Y., Kang, H., Koh, C. S., Shin, H. C., & Choi, S. (2015). A hybrid NIRS-EEG system for self-paced brain computer interface with online motor imagery. *Journal of neuroscience methods*, 244, 26-32.
- [32] Tsui, C. S. L., Gan, J. Q., & Roberts, S. J. (2009). A self-paced brain-computer interface for controlling a robot simulator: an online event labelling paradigm and an extended Kalman filter based algorithm for online training. *Medical & biological engineering & computing*, 47(3), 257-265.
- [33] Bascil, M. S., Tesneli, A. Y., & Temurtas, F. (2016). Spectral feature extraction of EEG signals and pattern recognition during mental tasks of 2-D cursor movements for BCI using SVM and ANN. *Australasian physical & engineering sciences in medicine*, 39(3), 665-676.
- [34] Özgen, C. (2011). CLASSIFICATION OF MOTOR IMAGERY TASKS IN EEG SIGNAL AND ITS APPLICATION TO A BRAINCOMPUTER INTERFACE FOR CONTROLLING ASSISTIVE ENVIRONMENTAL DEVICES (Doctoral dissertation, MIDDLE EAST TECHNICAL UNIVERSITY).

- [35] Stoica, P., & Moses, R. L. (2005). *Spectral Analysis of Signals*: Prentice Hall. Upper Saddle River, NJ.
- [36] Gu, Z., Yu, Z., Shen, Z., & Li, Y. (2013). An online semi-supervised brain-computer interface. *IEEE Transactions on Biomedical Engineering*, 60(9), 2614-2623.
- [37] Donchin, E., Spencer, K. M., & Wijesinghe, R. (2000). The mental prosthesis: assessing the speed of a P300-based brain-computer interface. *IEEE transactions on rehabilitation engineering*, 8(2), 174-179.
- [38] Zhang, L., & Zheng, C. (2005, November). Cortical lateralization analysis by kolmogorov entropy of EEG. In *Panhellenic Conference on Informatics* (pp. 798-807). Springer Berlin Heidelberg.
- [39] Lotte, F., Bougrain, L., & Clerc, M. (2015). *Electroencephalography (EEG)Based Brain-Computer Interfaces*. Wiley Encyclopedia of Electrical and Electronics Engineering.
- [40] Lubar, J. O., & Lubar, J. F. (1984). Electroencephalographic biofeedback of SMR and beta for treatment of attention deficit disorders in a clinical setting. *Biofeedback and self-regulation*, 9(1), 1-23.
- [41] Gao, L., Cheng, W., Zhang, J., & Wang, J. (2016). EEG classification for motor imagery and resting state in BCI applications using multi-class Adaboost extreme learning machine. *Review of Scientific Instruments*, 87(8), 085110.
- [42] Singla, R., & Haseena, B. A. (2014). Comparison of ssvp signal classification techniques using svm and ann models for bci applications. *International Journal of Information and Electronics Engineering*, 4(1), 6.
- [43] Rambabu, C., & Murthy, B. R. (2014). EEG signal with feature extraction using SVM and ICA classifiers. *International Journal of Computer Applications*, 85(3).
- [44] Boudria, Y., Feltane, A., & Besio, W. (2014). Significant improvement in one-dimensional cursor control using Laplacian electroencephalography over electroencephalography. *Journal of neural engineering*, 11(3), 035014.
- [45] Mozaffar, S., & Petr, D. W. (2002). Artifact extraction from EEG data using independent component analysis. *Information Telecommunication and Technology Center, University of Kansas, Lawrence, KS, Tech. Rep. ITTC-FY2003-TR-03050-02*.
- [46] Chai, R., Naik, G., Nguyen, T. N., Ling, S., Tran, Y., Craig, A., & Nguyen, H. (2016). Driver fatigue classification with independent component by entropy rate bound minimization analysis in an EEG-based system. *IEEE journal of biomedical and health informatics*.
- [47] Gunn, S. R. (1998). Support vector machines for classification and regression. *ISIS technical report*, 14, 85-86.
- [48] Bascil, M. S., Tesneli, A. Y., & Temurtas, F. (2015). Multi-channel EEG signal feature extraction and pattern recognition on horizontal mental imagination task of 1-D cursor movement for brain computer interface. *Australasian Physical & Engineering Sciences in Medicine*, 38(2), 229-239.
- [49] Hazrati, M. K., & Erfanian, A. (2010). An online EEG-based brain-computer interface for controlling hand grasp using an adaptive probabilistic neural network. *Medical engineering & physics*, 32(7), 730-739.
- [50] Bascil, M. S., & Oztekin, H. (2012). A study on hepatitis disease diagnosis using probabilistic neural network. *Journal of medical systems*, 36(3), 1603-1606.
- [51] Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9(3), 293-300.

- [52] Temurtas, F. (2009). A comparative study on thyroid disease diagnosis using neural networks. *Expert Systems with Applications*, 36(1), 944-949.
- [53] 'El HTMC cuenta con el primer laboratorio de neurofisiología' (Online), Available: <http://www.htmc.gob.ec/index.php/sala-de-prensa/85-elhtmc-cuenta-con-el-primer-laboratorio-de-neurofisiologia>, (Accessed:4-2-2017)
- [54] Sajedi, F., Ahmadlou, M., Vameghi, R., Gharib, M., & Hemmati, S. (2013). Linear and nonlinear analysis of brain dynamics in children with cerebral palsy. *Research in developmental disabilities*, 34(5), 1388-1396.
- [55] Iturrate, I., Escolano, C., Antelis, J., & Minguez, J. (2009, May). Dispositivos robóticos de rehabilitación basados en Interfaces cerebroordenador: silla de ruedas y robot para teleoperación. In III International Congress on Domotics, Robotics and Remote-Assistance for All, Barcelona, Spain (pp. 124-134).
- [56] Rodríguez-Bermúdez, G., García-Laencina, P. J., Brizion, D., & Roca-Dorda, J. (2013). Adquisición, procesamiento y clasificación de señales EEG para diseño de sistemas BCI basados en imaginación de movimiento. *Revista V Jornadas de introducción a la investigación de la UPCT (1888-8356)*, 6.
- [57] Wilson, J. A., Schalk, G., Walton, L. M., & Williams, J. C. (2009). Using an EEG-based brain-computer interface for virtual cursor movement with BCI2000. *JoVE (Journal of Visualized Experiments)*, (29), e1319-e1319.
- [58] Gomez-Pilar, J., Corralejo, R., Nicolas-Alonso, L. F., Álvarez, D., & Hornero, R. (2016). Neurofeedback training with a motor imagery-based BCI: neurocognitive improvements and EEG changes in the elderly. *Medical & biological engineering & computing*, 54(11), 1655-1666.
- [59] Y. Freund and R. Schapire, "A decision theoretic generalization of on-line learning and an application to boosting," *J. Comput. Syst. Sci.* 55, 119–139 (1997).
- [60] Asanza, V.; Pelaez, E.; Loayza, F. Supervised pattern recognition techniques for detecting motor intention of lower limbs in subjects with cerebral palsy. 2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM). IEEE, 2017, pp. 1–5.
- [61] J. Fuentes-Gonzalez, A. Infante-Alarcón, V. Asanza and F. R. Loayza, "A 3D-Printed EEG based Prosthetic Arm," 2020 IEEE International Conference on E-health Networking, Application & Services (HEALTHCOM), 2021, pp. 1-5, doi: 10.1109/HEALTHCOM49281.2021.9399035.
- [62] Asanza, V.; Peláez, E.; Loayza, F.; Lorente-Leyva, L.L.; Peluffo-Ordóñez, D.H. Identification of Lower-Limb Motor Tasks via Brain–Computer Interfaces: A Topical Overview. *Sensors* 2022, 22, 2028. <https://doi.org/10.3390/s22052028>.
- [63] Asanza, V.; Ochoa, K.; Sacarelo, C.; Salazar, C.; Loayza, F.; Vaca, C.; Peláez, E. Clustering of EEG occipital signals using k-means. 2016 IEEE Ecuador Technical Chapters Meeting (ETCM), 2016, pp. 1–5. doi:10.1109/ETCM.2016.7750874.
- [64] Hu, X.; Yan, H.; Casey, T.; Wu, C.H. Creating a safe haven during the crisis: How organizations can achieve deep compliance with COVID-19 safety measures in the hospitality industry. *International Journal of Hospitality Management* 2021, 92, 102662.
- [65] Knierim, M. T., Berger, C., & Reali, P. (2021). Open-source concealed EEG data collection for Brain-computer-interfaces-neural observation through OpenBCI amplifiers with around-the-ear cEEGrid electrodes. *Brain-Computer Interfaces*, 8(4), 161-179.
- [66] Aldridge, A., Barnes, E., Bethel, C. L., Carruth, D. W., Kocturova, M., Pleva, M., & Juhar, J. (2019, April). Accessible electroencephalograms (EEGs): A comparative review with openbci's

- ultracortex mark IV headset. In 2019 29th International Conference Radioelektronika (RADIOELEKTRONIKA) (pp. 1-6). IEEE.
- [67] Livolsi, F., May, T., Caputo, D., Fouladi, K., & Eslami, B. (2021). Multiscale Study on Effect of Humidity on Shape Memory Polymers Used in Three-Dimensional Printing. *Journal of Manufacturing Science and Engineering*, 143(9).
- [68] Razavi, M., Janfaza, V., Yamauchi, T., Leontyev, A., Longmire-Monford, S., & Orr, J. (2022). OpenSync: An open-source platform for synchronizing multiple measures in neuroscience experiments. *Journal of neuroscience methods*, 369, 109458.
- [69] Ahmad, T., HAROON, H., DHAMA, K., Sharun, K., Khan, F. M., Ahmed, I., ... & Hui, J. (2020). Biosafety and biosecurity approaches to restrain/contain and counter SARS-CoV-2/COVID-19 pandemic: a rapid-review. *Turkish journal of biology*, 44(SI-1), 132-145.
- [70] Hu, X., Yan, H., Casey, T., & Wu, C. H. (2021). Creating a safe haven during the crisis: How organizations can achieve deep compliance with COVID-19 safety measures in the hospitality industry. *International Journal of Hospitality Management*, 92, 102662.
- [71] Zhang, W., Li, X., & Zhao, L. (2018). A fast hyperspectral feature selection method based on band correlation analysis. *IEEE Geoscience and Remote Sensing Letters*, 15(11), 1750-1754.
- [72] Asanza, Victor; Montoya, Daniel; Peláez, Enrique; Loayza, Francis; Lorente-Leyva, Leandro L.; Peluffo-Ordóñez, Diego H.; González, Kléber (2021), "MLimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motor Imagery Tasks", Mendeley Data, V2, doi: 10.17632/w9xfz56txv.2.
- [73] Schapire, R. E. (2003). The boosting approach to machine learning: An overview. In *Nonlinear estimation and classification* (pp. 149-171). Springer New York.
- [74] Montesdeoca Castillo, A. E. (2014). Equipamiento para desarrollar actividades escolares para niños con parálisis cerebral espástica leve y moderada de 5 a 11 años.
- [75] Mikolajewska, E., & Mikolajewski, D. (2014). The prospects of brain—computer interface applications in children. *Central European Journal of Medicine*, 9(1), 74-79.
- [76] Brien, M., & Sveistrup, H. (2011). An intensive virtual reality program improves functional balance and mobility of adolescents with cerebral palsy. *Pediatric Physical Therapy*, 23(3), 258-266.
- [77] Tarakci, D., Ozdinciler, A. R., Tarakci, E., Tutuncuoglu, F., & Ozmen, M. (2013). Wii-based balance therapy to improve balance function of children with cerebral palsy: a pilot study. *Journal of physical therapy science*, 25(9), 1123-1127.
- [78] Kwon, J. Y., Chang, H. J., Lee, J. Y., Ha, Y., Lee, P. K., & Kim, Y. H. (2011). Effects of hippotherapy on gait parameters in children with bilateral spastic cerebral palsy. *Archives of physical medicine and rehabilitation*, 92(5), 774-779.
- [79] Lee, C. W., Kim, S. G., & Na, S. S. (2014). The effects of hippotherapy and a horse riding simulator on the balance of children with cerebral palsy. *Journal of physical therapy science*, 26(3), 423-425.
- [80] Mattern-Baxter, K. (2009). Effects of partial body weight supported treadmill training on children with cerebral palsy. *Pediatric physical therapy*, 21(1), 12-22.
- [81] Grecco, L. A. C., Zanon, N., Sampaio, L. M. M., & Oliveira, C. S. (2013). A comparison of treadmill training and overground walking in ambulant children with cerebral palsy: randomized controlled clinical trial. *Clinical rehabilitation*, 0269215513476721.

- [82] Luisa, A. A. M., Gabriel, R. L. O., & Antonia, C. (2010). Eficacia del programa de psicomotricidad para el equilibrio postural en niños con hemiparesia espástica de nivel de desarrollo motor cortical. *Revista Mexicana de Neurociencia* Julio-Agosto, 11(4), 269-278.
- [83] Ballaz, L., Huffenus, A. F., Lamarre, C., Koclas, L., & Lemay, M. (2012). Effect of Forced Use Therapy on posture in children with hemiplegic cerebral palsy: a pilot study. *Journal of rehabilitation medicine*, 44(3), 268-271.
- [84] Zipp, G. P., & Winning, S. (2012). Effects of constraint-induced movement therapy on gait, balance, and functional locomotor mobility. *Pediatric Physical Therapy*, 24(1), 64-68.
- [85] Bandholm, T., Jensen, B. R., Nielsen, L. M., Rasmussen, H., Bencke, J., Curtis, D., ... & Sonne-Holm, S. (2012). Neurorehabilitation with versus without resistance training after botulinum toxin treatment in children with cerebral palsy: a randomized pilot study. *NeuroRehabilitation*, 30(4), 277-286.
- [86] Karabay, □., Dogan, A., Arslan, M. D., Dost, G., & Ozgirgin, N. (2012). Effects of functional electrical stimulation on trunk control in children with diplegic cerebral palsy. *Disability and rehabilitation*, 34(11), 965-970.
- [87] El-Shamy, S. M. (2014). Effect of whole-body vibration on muscle strength and balance in diplegic cerebral palsy: a randomized controlled trial. *American Journal of Physical Medicine & Rehabilitation*, 93(2), 114-121.
- [88] Guger, C., Schlogl, A., Neuper, C., Walterspacher, D., Strein, T., & Pfurtscheller, G. (2001). Rapid prototyping of an EEG-based braincomputer interface (BCI). *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 9(1), 49-58.

4 Capítulo 4 RQ2: ¿Cómo podrían adaptarse los actuales algoritmos de caracterización utilizados en el EEG-BCI para extraer características adecuadas de las intenciones motoras de las extremidades inferiores?

En el capítulo 3 se presenta el diseño de una metodología experimental para el registro de señales de Electroencefalografía (EEG) y además se creó una base de datos de 24 voluntarios, entre los cuales existen sujetos con amputaciones y con Parálisis Cerebral Infantil (PCI).

Para responder la segunda pregunta de investigación nos centramos en la extracción de características de las señales bioeléctricas. En la sección 4.1 se introduce el uso de características basadas en la Densidad Espectral de Potencia (PSD) en la detección de tareas motoras e imagenético motoras basado en señales EEG. Los datos utilizados en esta sección pertenecen a una base de datos libre y fueron registradas de forma superficial en la corteza motora. Además, se presenta el preprocesamiento de los datos y el análisis de cinco algoritmos de clustering para detectar tareas motoras e imaginarias de extremidades superiores e inferiores.

En la sección 4.2 se presenta el diseño experimental para el registro de señales de Electroencefalografía (EEG) en 20 sujetos de prueba sometidos a Potenciales Evocados Visualmente en Estado Estable (SSVEP). También se implementa un sistema de clasificación basado en señales SSVEP-EEG de la región occipital del cerebro, obtenidas con el dispositivo Emotiv EPOC. Las características utilizadas están basadas en tiempo, frecuencia y PSD.

En la sección 4.3 se presenta un análisis estadístico de la distribución de las señales normales de EEG, para determinar la necesidad de realizar preprocesamiento, así como el uso de filtros para eliminar cualquier componente de la señal EEG, que no esté en el rango de frecuencias de funcionamiento del área occipital. En esta sección se emplean características basadas en tiempo y frecuencia. Finalmente, se utilizó un algoritmo no supervisado para agrupar las señales según sus características frecuenciales y temporales.

En la sección 4.4 se presenta una aplicación basada en la detección de la amplitud de la señal EEG durante procesos de concentración. Esta es una característica temporal que

nos permite detectar el nivel de atención del sujeto de prueba. La detección es utilizada para realizar el control de una prótesis de mano en tiempo real.

En la sección 4.5 se realiza un análisis similar empleando las mismas etapas y algoritmos de clustering que la sección 4.1, pero esta vez comprobando la detección de intensiones motoras en extremidades superiores basados en señales de Electromiografía (EMG).

En la sección 4.6 se da respuesta a la pregunta de investigación que se analiza en este capítulo. Además, se discuten los resultados obtenidos como respuesta a esta pregunta de investigación. Finalmente, en la sección 4.7 se presentan los trabajos ya publicados que reportan los hallazgos de ésta pregunta de investigación: a) “EEG signal clustering for motor and imaginary motor tasks on hands and feet” [1]; b) “SSVEP-EEG Signal Classification based on Emotiv EPOC BCI and Raspberry Pi” [2]; c) “Clustering of EEG occipital signals using k-means” [3]; d) “A 3D-Printed EEG based Prosthetic Arm” [4]; y e) “EMG Signal Processing with Clustering Algorithms for motor gesture Tasks” [5].

4.1 Extracción de características basadas en densidad espectral en la detección de tareas motoras e imagenético motoras de señales EEG

En el análisis de los algoritmos de aprendizaje no supervisado, se realizaron pruebas con señales de Electroencefalografía (EEG) relacionados a tareas motoras e magnético motoras. Los datos EEG fueron preprocesados, incluyendo el diseño de un filtro para la reducción del ruido, fuera del espectro de frecuencias esperado en el que operan las señales de EEG. A continuación, utilizamos la extracción de características basadas en la densidad espectral. Por último, se realiza la aplicación de cinco algoritmos de clustering para detectar tareas motoras en tareas motoras imaginarias. Los resultados mostraron que los algoritmos K-means, K-medoids, así como los algoritmos de Clustering Jerárquico, fueron los mejores para detectar la actividad motora, y el Clustering Jerárquico para tareas imaginarias de las manos.

4.1.1 Introducción

Las señales biomédicas EEG permiten medir la diferencia de potencial generada en el cuero cabelludo; estas señales representan las actividades neuronales correspondientes a cada zona del cerebro [6]. Una de las aplicaciones más conocidas de las señales de EEG

son las Interfaces Cerebro-Ordenador (BCI). Las aplicaciones basadas en BCI permiten a los sujetos con algún tipo de discapacidad motora interactuar con algunos dispositivos o prótesis [7].

Durante una actividad motora o motora imaginaria, las señales eléctricas, del orden de los microvoltios (μV), se generan en la corteza motora del cerebro [8, 9]. Existen dos métodos para medir estas señales de EEG: Invasivo y superficial [10]. La medición invasiva se realiza mediante electrodos insertados directamente en la superficie del cerebro; este método se considera arriesgado e innecesario en algunos casos. El método superficial permite detectar la actividad de las neuronas mediante electrodos colocados en el cuero cabelludo; es el método más común para la medición porque puede realizarse con un riesgo mínimo para el sujeto [9].

La adquisición de datos de EEG tiene problemas de interferencia causados por los electrodos utilizados en la piel para recoger las señales procedentes de la red eléctrica, o los movimientos relativos entre los electrodos, el parpadeo, la actividad muscular, el ritmo cardíaco la respiración, etc. [11,12].

El desarrollo de tecnologías para mejorar el proceso de rehabilitación, en sujetos con discapacidades motoras, es en particular para aquellos que no tienen la capacidad de controlar sus movimientos debido a enfermedades, tales como: defectos de nacimiento, accidentes cerebrovasculares, traumatismos y otras; la medición de las señales bioeléctricas, que los sujetos generan mientras realizan actividades motoras imaginarias, podría permitirnos determinar la intencionalidad del sujeto. Además, dada la susceptibilidad de estas señales, al ruido generado por las técnicas y tecnologías de medición utilizadas, algunas metodologías de análisis y preprocesamiento de las señales EEG como en Guger, C. et al. [12].

En este trabajo, se utilizó un método de preprocesamiento de las señales de EEG para eliminar los componentes de ruido y un mecanismo de extracción de características que posteriormente podría utilizarse para determinar la intención motora del sujeto; el conjunto de datos procesados se evaluaron con algoritmos de clustering.

4.1.2 Trabajos relacionados

Hasta donde sabemos, las técnicas para detectar la actividad motora cortical correspondiente a los miembros inferiores, no han sido bien estudiadas porque son difíciles de detectar, se registran en el giro motor central situado en la cara interna de la fisura longitudinal del cerebro [13]. Por esta razón, algunas técnicas de visualización topográfica, basadas en datos de EEG de la actividad cortical motora, se centran principalmente en las extremidades superiores [14-16].

La actividad cortical motora medida con sistemas EEG-BCI es más evidente en la banda de frecuencia de 13-30 Hz o banda β y en la banda de frecuencia de 8-12 Hz o banda μ [10]. Es común utilizar la Densidad Espectral de Potencia (PSD) para medir las características para determinar la intención motora en la banda de frecuencia β y μ [17-19].

Algunos algoritmos de aprendizaje automatizado (supervisado y no supervisado), que se han utilizado para detectar intenciones motoras en las extremidades superiores son: Máquinas de Vectores de Soporte (SVM) [18,20-25], Redes Neuronales (NN) [18,19,22], Análisis Discriminante Lineal (LDA) [18,21], y Algoritmos de Clustering [6,8,26]. Investigaciones recientes muestran que los algoritmos de clasificación SVM tienen un mejor rendimiento en la detección de intenciones motoras en los miembros superiores [16,18,25]. En este trabajo, realizamos una comparación entre algunos algoritmos de clustering, para determinar su rendimiento en la detección de tareas motoras.

4.1.3 Dataset

Para este trabajo, utilizamos un conjunto de datos de registros de señales EEG de sujetos sanos utilizando un sistema BCI-2000, disponible en el sitio web de Physio Net: <https://www.physionet.org/physiobank/database/eegmmidb/>.

El conjunto de datos consta de 14 archivos que siguen el Formato Europeo de Datos (EDF) [17], con una frecuencia de muestreo de 160Hz, con las grabaciones de la actividad cerebral de 25 sujetos sanos, a los que se les pidió que realizaran diferentes tareas imaginarias y motoras mientras que las señales de EEG se registraron utilizando 64 electrodos colocados en la superficie del cuero cabelludo.

Cada uno de los 14 archivos EDF de cada sujeto contiene las señales adquiridas durante la realización de las siguientes tareas: Línea de base con los ojos abiertos; línea de base con los ojos cerrados; tarea 1 (abrir y cerrar la mano izquierda o la derecha); tarea 2 (imaginar que se abre y se cierra la mano izquierda o derecha); tarea 3 (abrir y cerrar ambas manos o ambos pies); y, tarea 4 (imaginar que se abren y cierran las dos manos o los dos pies). Las tareas 1 y 2 tienen una duración de 1 minuto cada una; las tareas 2, 3 y 4 tienen una duración de dos minutos cada una. El archivo EDF correspondiente a cada tarea tiene 30 acciones organizadas en orden aleatorio e identificadas por tres anotaciones (T0, T1 y T2), que indican el tipo de actividad realizada: T0 corresponde al descanso. T1 corresponde al inicio del movimiento (real o imaginario) de la mano izquierda (almacenada en los archivos: 3, 4, 7, 8, 11 y 12), y de ambas manos (almacenadas en los archivos: 5, 6, 9, 10, 13 y 14). T2 corresponde al inicio del movimiento (real o imaginario) de la mano derecha (almacenado en archivos 3, 4, 7, 8, 11 y 12) y para ambos pies (almacenados en los archivos 5, 6, 9, 10, 13 y 14) [17].

Dado que nuestro objetivo es permitir que posteriormente se determine la intención motora, nos hemos centrado en detectar y diferenciar la actividad motora imaginaria de la actividad motora real, por lo que las tareas 3 y 4 que hemos utilizado, corresponden a los archivos EDF 5, 6, 9, 10, 13 y 14 para cada sujeto. Para cada uno de los 25 sujetos, se obtuvo 6 archivos EDF con 30 acciones. Para facilitar el análisis, cada archivo EDF se agrupó con la anotación T1 y T2, y se guardó en dos archivos Matlab. Todos estos 300 (25 x 6 x 2) archivos “.Mat” tienen 4.599 filas con muestras de señales de EEG x 64 columnas (electrodos), que se utilizaron para extraer las características y para los algoritmos de clustering. Y, se utilizó Matlab V9.2.0.556344 (The Mathworks, Natick, MA) para el análisis completo.

La figura 4.1.3.1 muestra algunas muestras de la señal EEG, correspondientes a la tarea motora imaginaria de ambas manos; este gráfico contiene 4.599 muestras de los 64 electrodos de superficie capturados simultáneamente. Además, se puede observar que todo el conjunto de 64 señales contiene componentes de Corriente Directa (DC), tendencias o artefactos DC.

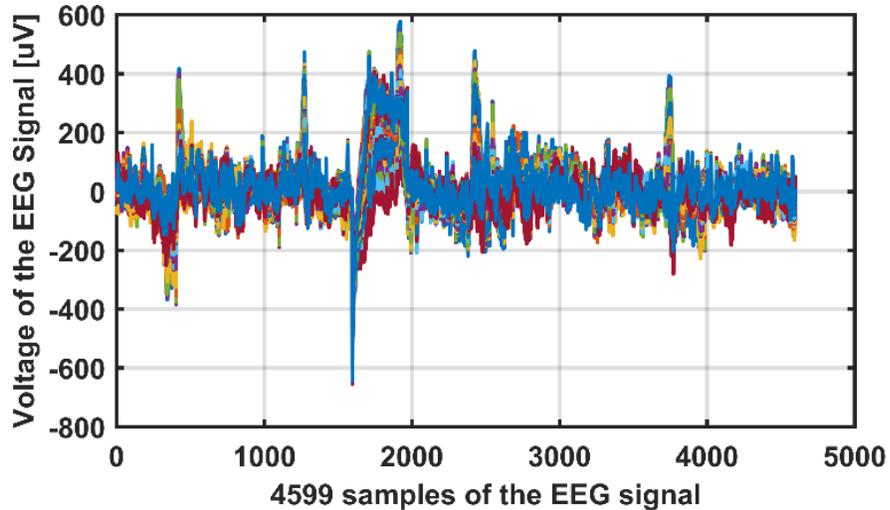


Figura 4.1.3.1 Artefacto de DC presente en los 64 electrodos del EEG de la tarea motora imaginaria. [autoría propia]

La metodología propuesta en la sección 4.1.4, considera realizar un análisis del dominio de la frecuencia y determinar la presencia de ruido generado por la red de distribución de energía. Para este análisis, se aplicó la Transformada Rápida de Fourier (FFT) a cada uno de los 300 archivos “.Mat”. Todos los electrodos tienen una fuerte actividad, debido a la presencia de artefactos de DC para los valores cercanos a 0 Hz de frecuencia.

4.1.4 Metodología

Una vez identificadas las evidencias de la presencia y el tipo de ruido en las señales de EEG, se diseñó un filtro Butterworth, para producir una respuesta en frecuencia, lo más plana posible, y evitar la distorsión de la señal original en el dominio de la frecuencia [12,19]. El filtro Paso de Banda de Coeficientes Constantes (Butttherworth-IIR o Wiener-FIR) se diseñó para el rango de frecuencias entre 7 y 30 Hz [11,27].

Cada uno de los 300 archivos “.Mat” con datos filtrados, se distribuyó aleatoriamente en un único archivo “Data.Mat”, donde las filas representan los eventos de la actividad motora (archivos EDF 5, 9 y 13) para ambas manos (T1) y ambos pies (T2); y, la actividad motora imaginaria (archivos EDF 6, 10 y 14) de ambas manos (T1) y ambos pies (T2).

La figura 4.1.4.1 muestra el valor máximo de la PSD y la frecuencia que se produce en los 21 electrodos situados en la corteza motora. Los electrodos del 1 al 21 tienen actividad eléctrica neuronal correspondiente a tareas motoras o tareas imaginarias motoras [8,11].

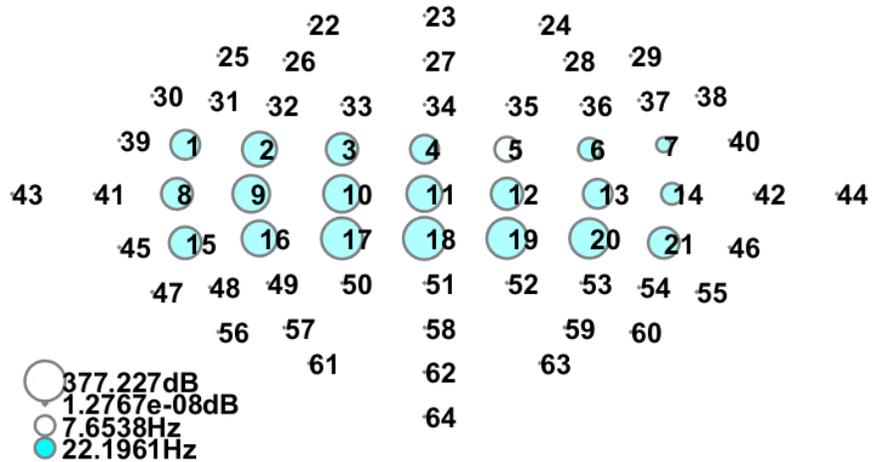


Figura 4.1.4.1 Distribución de 64 electrodos de superficie. [autoría propia]

Se utilizó un periodograma o PSD de Welch para extraer la Densidad Espectral de potencia (PSD), lo que nos permite tener la distribución de potencia de la señal en función de la frecuencia [22,25]. Las columnas del archivo "Data.Mat" contienen características de PSD como: El valor máximo de PSD, la frecuencia, la media aritmética y la varianza. Todas estas 84 (21 x 4) características se añadieron como columnas en un nuevo archivo "Features.Mat", cuyas filas corresponden a los 300 eventos, como se ha indicado anteriormente.

Además, se añadió una columna con el indicador del evento en cada fila, con el fin de validar los resultados de los algoritmos de clustering. La figura 4.1.4.2 muestra los valores de la norma de características de una tarea motora imaginaria de ambas manos; las primeras 42 características son 21 valores máximos de PSD y 21 valores de frecuencia, respectivamente. Las 42 características restantes son 21 valores de media aritmética y 21 de varianza del valor PSD, respectivamente.

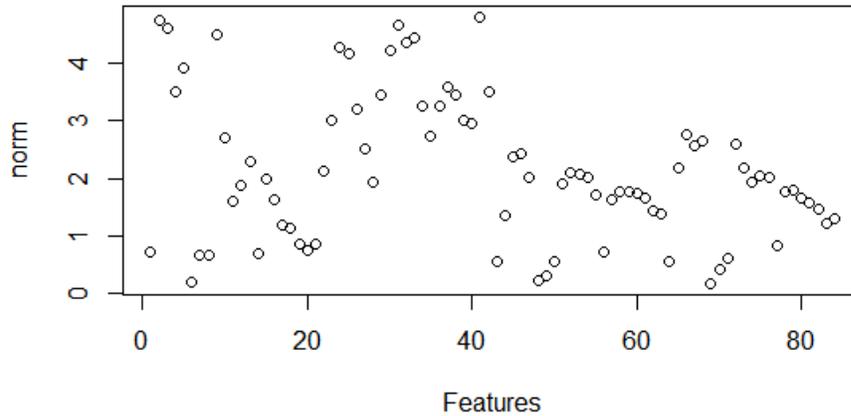


Figura 4.1.4.2 84 características en la tarea motora imaginaria ambas manos. [autoría propia]

El primer algoritmo con el que se probaron los datos de “Features.mat” fue el de clustering con K-means. Este algoritmo, basado en la distancia euclidiana al centroide del clúster, se utilizó con 4 centroides (k = 4) [28]. La figura 4.1.4.3 muestra los datos agrupados utilizando tipos convexos, lo que permite que todas las características tengan una mejor agrupación.

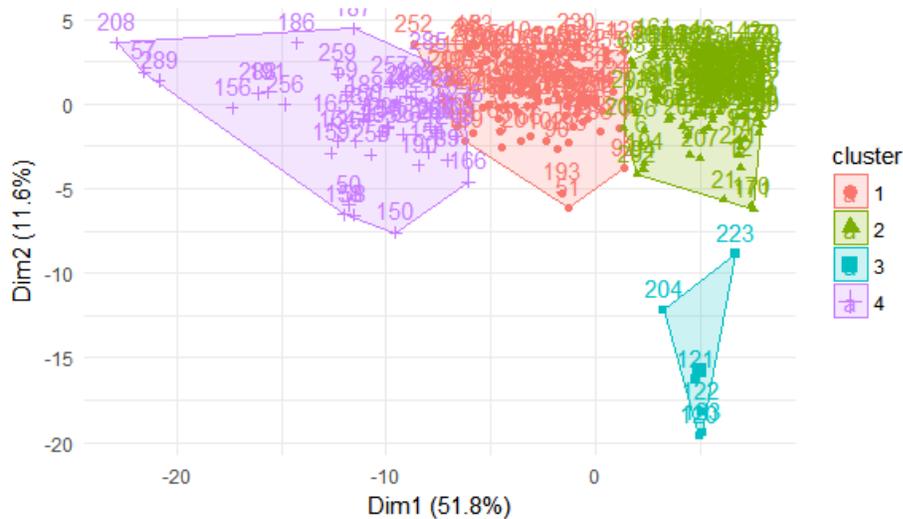


Figura 4.1.4.3 Algoritmo K-means, con nueve centroides. [autoría propia]

Otro algoritmo de agrupación probado fue el de K-medoids, que se basa en la distancia de la Norma de Manhattan al centroide del clúster. La diferencia con K-means es que este algoritmo elige los puntos de datos como centroides. La figura 4.1.4.4 muestra las características del clustering utilizando el tipo convexo.

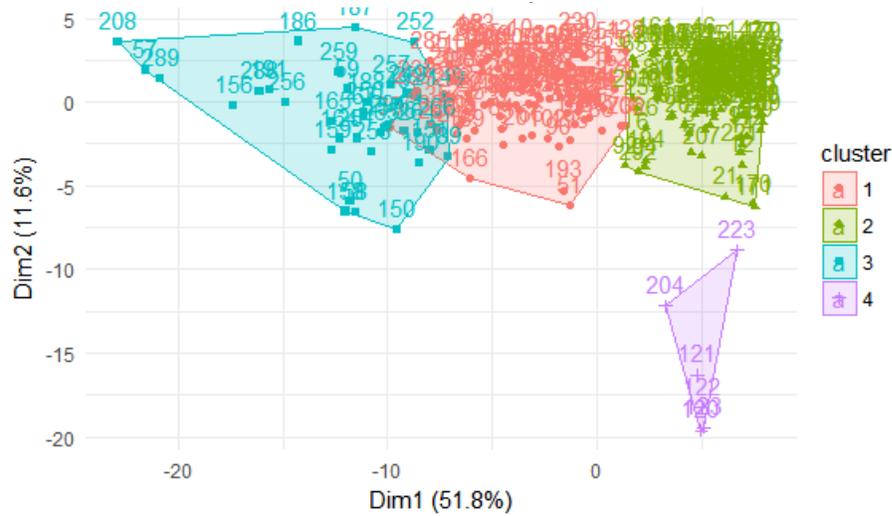


Figura 4.1.4.4 Algoritmo K-medoids, con nueve centroides. [autoría propia]

Un tercer algoritmo utilizado fue el Clustering Basado en la Densidad (DBSCAN), este algoritmo necesita la distancia mínima entre puntos como parámetro para ser considerado en el mismo clúster (EPS), la figura 4.1.4.5 muestra el cálculo de la distancia óptima entre puntos para ser considerados en el mismo cluster (EPS) [6].

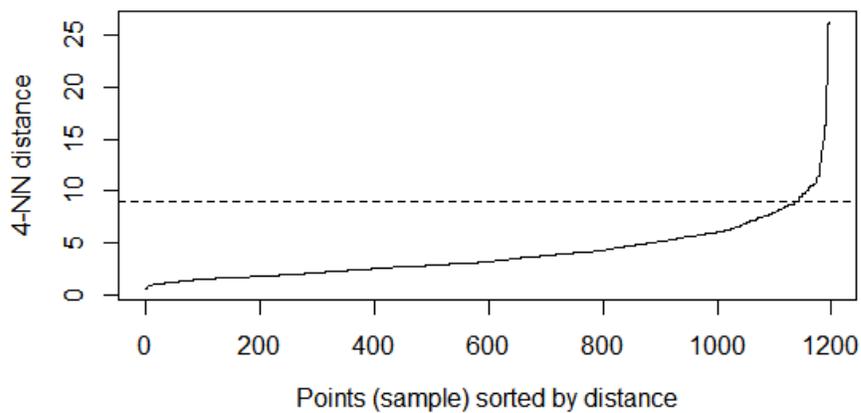


Figura 4.1.4.5 Cálculo de la distancia EPS óptima para DBSCAN con distancia mínima = 9. [autoría propia]

DBSCAN es una asignación basada en la densidad y fue evaluado con un valor de punto mínimo = 4. El resultado de la agrupación utilizando el tipo convexo se muestra en la figura 4.1.4.6, como se ve en la imagen, este algoritmo no permite la detección de las 4 tareas motoras del experimento.

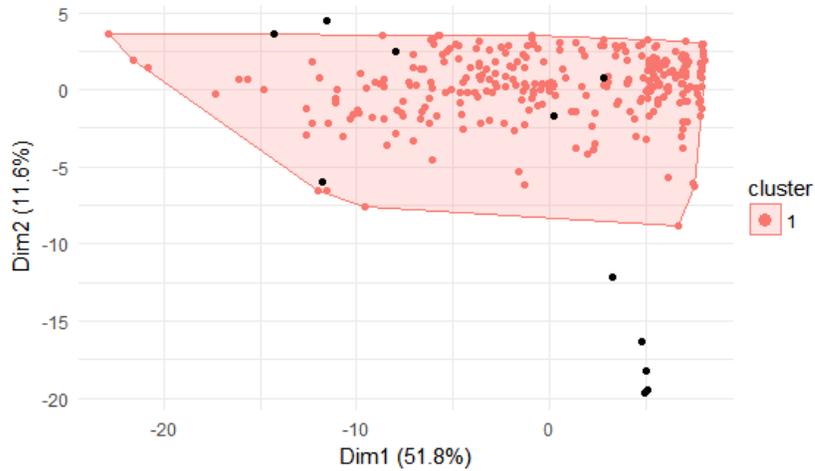


Figura 4.1.4.6 Resultados del clustering con DBSCAN. [autoría propia]

También se utilizó el clustering de densidad espectral con el conjunto de datos, este algoritmo utiliza 4 centroides ($k = 4$). La figura 4.1.4.7 muestra los datos agrupados utilizando el tipo convexo, a diferencia de los algoritmos K-means y K-medoids el Clustering Espectral tiene más características en el cluster 4.

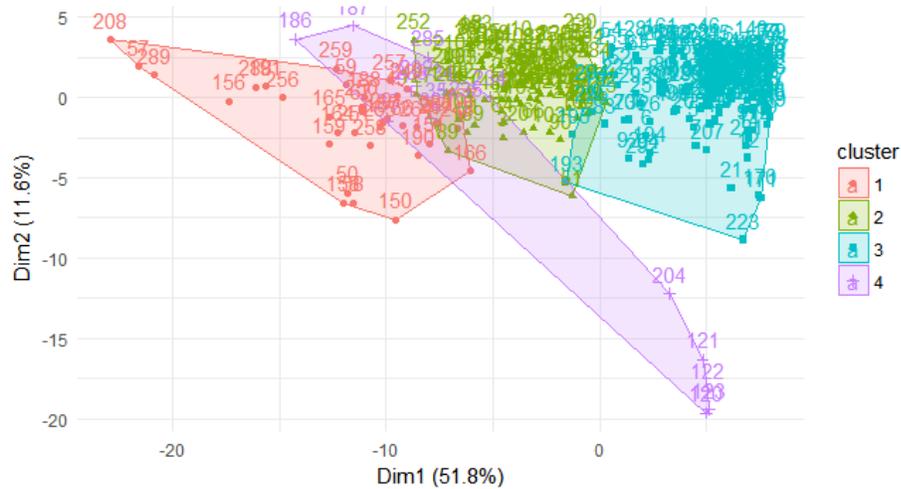


Figura 4.1.4.7 Resultados del algoritmo Clustering espectral. [autoría propia]

El algoritmo de Clustering Jerárquico construye un árbol con los resultados de este algoritmo en el conjunto de datos, como se muestra en la figura 4.1.4.8. El cluster jerárquico presenta un comportamiento como los algoritmos K-means y K-medoids, con un pequeño cluster que contiene pocos elementos [18].

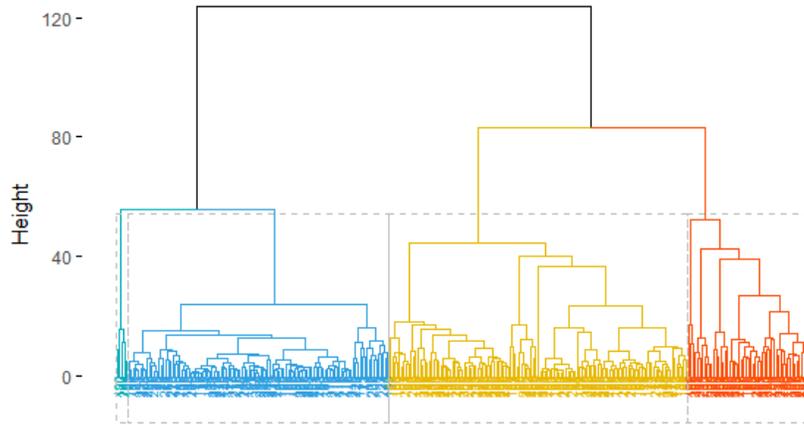


Figura 4.1.4.8 Resultados de Clustering Jerárquico. [autoría propia]

4.1.5 Análisis de los Resultados

Después de identificar las características del ruido, el preprocesamiento tiene como objetivo reducir la Relación Señal/Ruido (SNR) de los datos del EEG, en el rango de 7 - 30 Hz (ritmos μ y β) aplicando el filtro diseñado [9]. Las 4.599 muestras de los 64 electrodos de superficie, capturadas simultáneamente en el dominio del tiempo, se muestran en la figura 4.1.5.1, también se puede observar el efecto de la eliminación del ruido, causado por la presencia de artefactos de corriente continua, también se observa una señal sin desfases ni tendencias. Los componentes de frecuencia de las señales filtradas también se muestran en la figura 4.1.5.1, donde la actividad se muestra en el rango de 7-30 Hz.

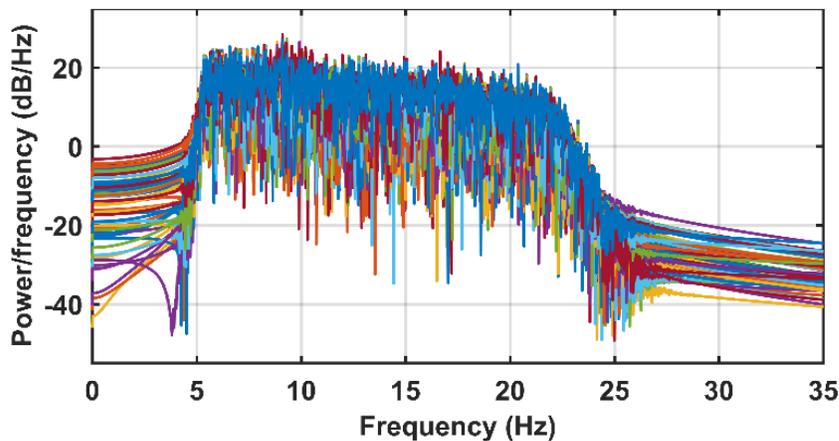


Figura 4.1.5.1 Frequency analysis with the FFT of the filtered EEG signals. [autoría propia]

La figura 4.1.5.2 muestra los valores óptimos del número de clusters para cada uno de los algoritmos de clustering utilizados en este trabajo (K-medios, K-medoides, DBSCAN, Clustering Espectral y Clustering Jerárquico). Para identificar las cuatro tareas o eventos,

el número de clusters definido fue 4, estas tareas son: Actividad motora de ambas manos (T1); de ambos pies (T2); actividad motora imaginaria de ambas manos (T1); y, actividad motora imaginaria de ambos pies (T2).

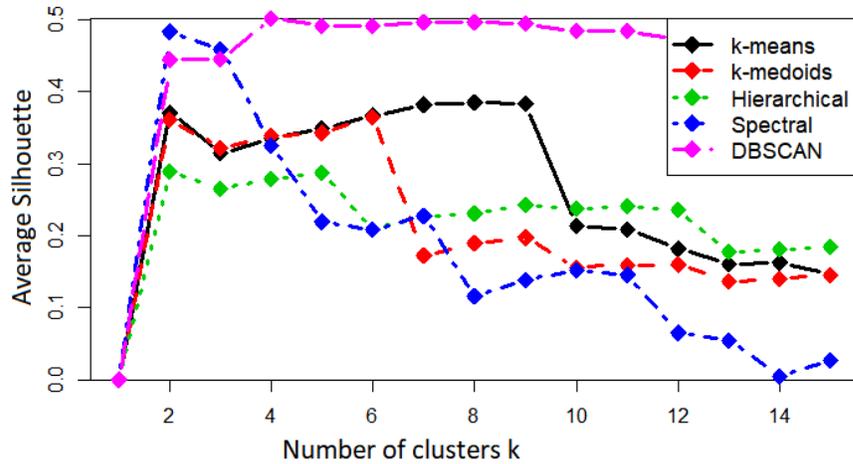


Figura 4.1.5.2 Explorar el número óptimo de cluster para todo el algoritmo de cluster. [autoría propia]

La figura 4.1.5.3 muestra los resultados del porcentaje correcto de cada algoritmo de clustering; el porcentaje se calculó comparando el cluster asignado a cada tarea por el algoritmo frente a la anotación proporcionada en el conjunto de datos. Los resultados corresponden a: Cluster 1 - Actividad motora de ambas manos (T1); Cluster 2 - Actividad motora actividad motora de ambos pies (T2); Cluster 3 – actividad motora imaginaria de ambas manos (T1); y, el Cluster 4 - actividad motora imaginaria de ambos pies (T2).

Los resultados muestran que ninguno de los algoritmos de clustering pudo detectar la actividad motora de ambos pies; el algoritmo de Clustering Jerárquico detecta mejor la actividad motora de ambas manos; el algoritmo kmedoids detecta mejor la actividad motora imaginaria de ambas manos; y, el clustering espectral detecta mejor la actividad motora imaginaria de ambos pies.

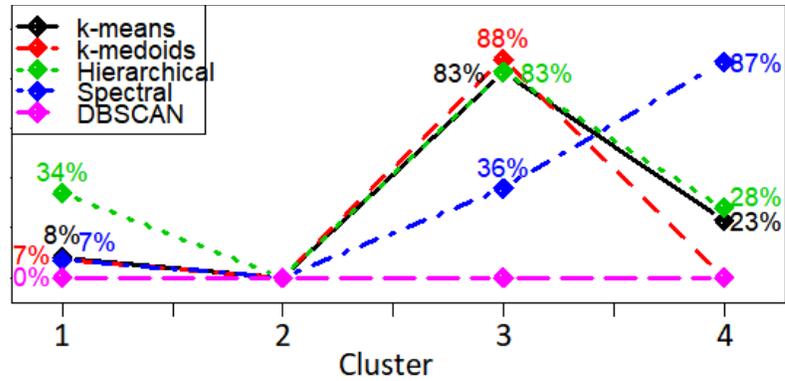


Figura 4.1.5.3 Porcentaje de éxito de todos los algoritmos de agrupación. [autoría propia]

4.2 Clasificación de señales SSVEP-EEG de la región occipital del cerebro

Para probar los algoritmos de aprendizaje supervisado, se realizó una metodología experimental que permite el registro de datos EEG de la región occipital del cerebro. Estos datos se utilizaron para entrenar algoritmos basados en Inteligencia Artificial (IA) en un Raspberry Pi 4 Modelo B. Finalmente, este trabajo demuestra la posibilidad de clasificar con tiempos de hasta 1,8 ms en sistemas embebidos con baja capacidad de cómputo.

4.2.1 Introducción

En los últimos años se han desarrollado numerosas investigaciones sobre sistemas robóticos basados en la Interfaz Cerebro-Ordenador (BCI). Estos sistemas proporcionan al usuario un canal de comunicación que permite obtener de las ondas cerebrales, la posibilidad de comunicar la intención del usuario a dispositivos externos, transformándose en una señal controlada por el ordenador. Alcivar-Molina et al. [29] y Han et al. [30], en sus estudios se han centrado en mejorar o sustituir las funciones en personas con discapacidades motoras. En este contexto, Chen et al. [31], Erkan y Akbaba [32] han demostrado que la técnica no invasiva de técnicas de Electroencefalografía (EEG) han sido utilizadas ampliamente para capturar la actividad cerebral y utilizarla como los datos de origen para BCI, principalmente por la alta resolución de tiempo resolución temporal y el método de bajo coste. A pesar de ello, muchas aplicaciones de BCI basadas en datos de EEG, la utilizan en la adquisición de datos aunque es altamente ruidosa y susceptible al ruido, principalmente en los dispositivos EEG de bajo coste, como el parpadeo, el movimiento relativo entre el cuero cabelludo y los electrodos, los cambios de impedancia

entre el cuero cabelludo y los electrodos de superficie, el tejido adiposo y el cabello. Para superar estas dificultades, se ha utilizado técnicas de IA para reducir la complejidad de los datos ruidosos y aumentar la precisión de la clasificación de los datos. La mayoría de los trabajos de BCI basados en dispositivos de bajo coste se centran en la clasificación de datos binarios, como el control de sillas de ruedas virtuales en 2D realizado por Huang et al. [33], o como lo realizado por Chouhan et al. [34] y Ghaemi et al. [35] para obtener las direcciones de los movimientos de las manos, o lo realizado por Fuentes-González et al. [36] para el control de brazo protésico basado en EEG. También, algunos trabajos realizaron un proceso de extracción de características a las señales EEG, filtradas utilizando ventanas temporales de datos a vectores que contienen información relevante [37]. Esta reducción de la dimensionalidad de la información permite reducir el coste computacional y en algunos casos mejorar la precisión de los algoritmos de clasificación [37,38]. La clasificación de las señales EEG ha permitido desarrollar aplicaciones BCI, asistiendo a personas con capacidad reducida mediante el control de dispositivos electrónicos, robóticos o protésicos dispositivos [39]. La mayoría de los estudios de asistencia para clasificar la intención del sujeto con capacidades reducidas utilizan datos de EEG registrados en la región de la corteza motora [40]. Las ondas alfa de la región frontal del cerebro [41] o también la actividad cerebral registrada en la región occipital del cerebro durante el Señales Potenciales Visuales Evocados de Estado Estable (SSVEP) [42]. Por lo tanto, los principales retos para los dispositivos EEG BCI son la baja tasa de transferencia de información, la alta tasa de error, y el desarrollo de técnicas de clasificación de datos EEG, especialmente para los datos procedentes de estos dispositivos de bajo coste. En esta sección se presenta una metodología para emplear técnicas de aprendizaje automático, utilizando un Raspberry-Pi de bajo coste para aprovechar las ventajas de IA y procesar los datos de EEG capturados desde un dispositivo de auriculares Emotive, para clasificar la intención de cinco sujetos diferentes y ser utilizados en cualquier dispositivo de control.

En este trabajo, la adquisición de señales de EEG de la región occipital del cerebro se realiza durante los estímulos visuales aplicados a los sujetos de prueba. Además, se realiza un preprocesamiento de la señal EEG para eliminar componentes de ruido y un mecanismo de extracción de características para clasificar y determinar el estímulo visual que el sujeto está observando. Los datos preprocesados se utilizan para extraer características para la posterior clasificación de las intenciones.

4.2.2 Trabajos relacionados

Las investigaciones anteriores en este campo han permitido establecer métodos algo más eficaces para abordar los diferentes retos como la adquisición, el preprocesamiento el análisis y la clasificación de las señales EEG.

4.2.2.1 Adquisición de señales SSVEP-EEG

Existe una tendencia notable en el uso de interfaces de estímulos visuales parpadeantes, asignando una frecuencia única a una acción, lo que permite reconocer las intenciones del usuario [43]. El rango de frecuencias óptimo para la clasificación de dichas señales ha sido un tema de investigación en solitario. Ahora se sabe que la existencia de diferentes tipos de ondas cerebrales varía, dependiendo de la actividad cognitiva del individuo y del nivel de atención [43].

Algunos estudios exploran las ondas alfa cerebrales con resultados favorables, utilizando una banda de frecuencia entre [8-16] Hz. En estos casos la adquisición de señales SSVEP-EEG se centra en la actividad de las regiones occipital y parietal del sujeto con una alta tasa de clasificación [30]. Otros autores han ampliado su investigación para analizar la onda beta para un rango de [5-20] Hz, en las regiones parietal y occipital delanteras. Esto requiere una mayor capacidad computacional para el dispositivo de procesamiento de datos [44].

4.2.2.2 Pre-procesamiento

Durante la realización de los experimentos hay diferentes fuentes de señales externas que no se originan en el cerebro, conocidas como artefactos. Estas señales pueden influir negativamente en las ondas obtenidas [43]. Por esta razón, es conveniente desarrollar una etapa de preprocesamiento para organizar los datos y eliminar cualquier error.

Entre las múltiples técnicas utilizadas para eliminar las interferencias producidas por la línea de alimentación o los artefactos DC, están los filtros digitales del tipo Noche [45], Butterworth [32,46], métodos de eliminación de ruido basados Wavelet [31,42], etc. Algunos estudios, aplican algoritmos adicionales para eliminar las tendencias lineales de los datos [45].

4.2.2.3 Análisis de las señales SSVEP-EEG

Tras el preprocesamiento de los datos, la literatura se refiere a la extracción de características como una forma de facilitar el análisis de la señal en el dominio del tiempo o de la frecuencia [43]. Recientemente, las características utilizadas por los autores en la investigación de señales EEG han sido Relación Señal-Ruido (SNR) [31], Valor de Bloqueo de Fase (PLV) [30], Combinación Mínima de Energía (MEC) [32], Respuesta Evocada Máxima (MER) [44], Espectro de Amplitud [47], entre otros.

Además, existen métodos de estandarización para obtener valores como Zscore [32], utilizados para escalar los resultados de las características. Esto hace posible su comparación y selección de un conjunto de características, que logra una alta tasa de precisión.

4.2.2.4 Selección de características

En aplicaciones anteriores, se han aplicado varios métodos de selección de características, estos métodos de post-procesamiento eligen las características que contribuyen a una clasificación satisfactoria de las intenciones del usuario, lo que se traduce en un aumento de la calidad de los resultados posteriores [43].

4.2.2.5 Métodos de clasificación

En la etapa final de procesamiento, las investigaciones anteriores describen diferentes formas de clasificar las características obtenidas en los pasos previos. Los algoritmos basados en el Análisis de Correlación Canónica (CCA), por ejemplo han sido ampliamente adoptados debido a la precisión obtenida; investigaciones anteriores, mediante el Análisis de Correlación Canónica de Banco de Filtros (FBCCA), se ha logrado un 91,78% de precisión, con una muestra de 12 sujetos de estudio, y el uso de 10 electrodos [45]. Además, existe la Máquinas de Vectores de Soporte (SVM), un conjunto de algoritmos de aprendizaje con resultados en el 88% de los casos, con la ayuda de 9 sujetos de prueba [44].

En los últimos años se ha creado una variedad de herramientas basadas en las RNA para la etapa de procesamiento, con las que se han logrado hasta un 80% de clasificación exitosa utilizando Redes Neurales Convolucionales Compactas (CCNN) [46].

4.2.3 Dataset

En esta sección se analiza la organización de los datos y como fueron analizados para el preprocesamiento de señales.

4.2.3.1 Organización del experimento

Gracias a la gestión del grupo de investigación en neurociencias y al comité técnico de la Universidad de Técnica de Machala (UTMACH), se reclutaron veinte sujetos adultos (sin discriminación de género) con edades comprendidas entre los 20 y los 35 años, que fueron recibidos por el personal encargado de realizar el experimento.

El personal encargado del experimento respetó las medidas de bioseguridad del COVID-19, ordenadas por el Ministerio de Salud Pública del Gobierno de Ecuador, las que incluyen: uso obligatorio de mascarillas, área de experimentación ventilada, superficies de contacto debidamente desinfectadas, así como la limpieza de todos los utensilios utilizados antes y después del experimento (<https://www.salud.gob.ec/medidas-de-proteccion-basicas-contra-el-nuevo-coronavirus/>).

La sala en la que se llevó a cabo el experimento estaba completamente limpia, con luz natural y paredes blancas, sin imágenes ni dibujos que distrajeran la atención de los sujetos. Durante el registro de datos, en algunos casos se registraron ruidos de bajo nivel entre 30 y 55 decibelios (dB) procedentes de fuentes como el aire acondicionado y, ocasionalmente, el paso del vehículo, que proporcionó un ruido muy bajo de entre 10 y 30 dB.

Cada sujeto recibió y firmó un consentimiento informado en el que se indicaba que su participación en este estudio era estrictamente voluntaria y anónima. Además, se informó a los sujetos de que los datos recogidos serían confidenciales y de que su uso era exclusivo para fines de investigación.

Se pidió a los sujetos que se sentaran en un sillón reclinable y cómodo, con los miembros superiores colocados en los reposabrazos del sillón y con un ángulo de 90 grados con respecto a los muslos. Esto puede verse en la figura 4.2.3.1.1.

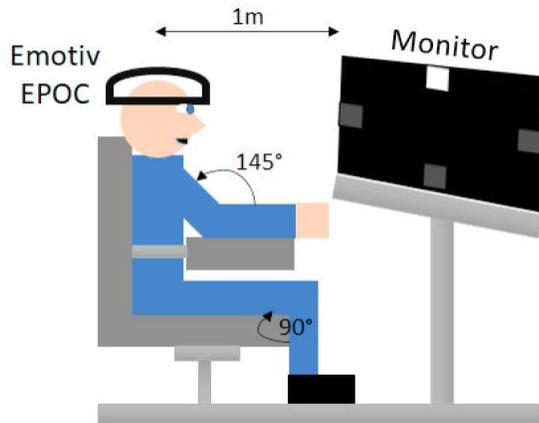


Figura 4.2.3.1.1 Puesta en marcha durante la adquisición de datos. [autoría propia]

4.2.3.2 Dispositivo de adquisición de datos

El dispositivo de registro de señales EEG se colocó en cada sujeto, algunas de las descripciones técnicas incluyen una frecuencia de muestreo de 128 Hz, este dispositivo tiene 14 electrodos y dos referencias de tierra, distribuidos en el sistema internacional 10-20 como se muestra en la figura 4.2.3.2.1.

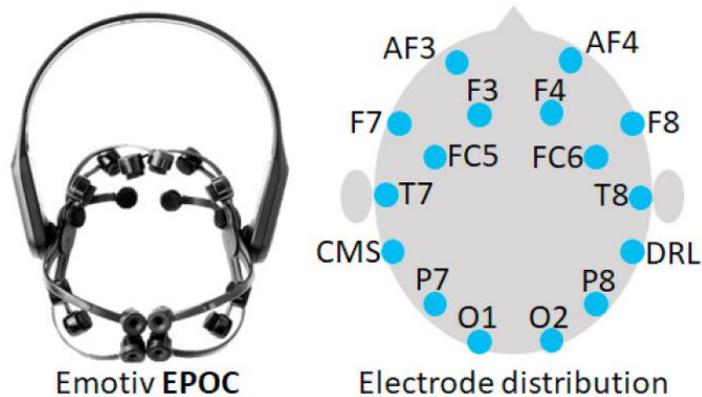


Figura 4.2.3.2.1 Disposición de los electrodos Emotiv Epoc. [autoría propia]

Durante el proceso de registro de la señal EEG, se utilizó un gel inductivo para reducir la impedancia entre el electrodo y la escala, lo que mejoró significativamente la integración de las señales registradas:

- EEG.AF3: Electrodo ubicado en el área frontal del cerebro en el hemisferio izquierdo.
- EEG.F7: Electrodo situado en el área frontal temporal del cerebro en el hemisferio izquierdo.

- EEG.F3: Electrodo situado en el área frontal del cerebro en el hemisferio izquierdo.
- EEG.FC5: Electrodo situado en el área frontal central del cerebro en el hemisferio izquierdo.
- EEG.T7: Electrodo situado en el área temporal del cerebro en el hemisferio izquierdo.
- EEG.P7: Electrodo situado en el área parietal del cerebro en el hemisferio izquierdo.
- EEG.O1: Electrodo situado en el área occipital del cerebro en el hemisferio izquierdo.
- EEG.O2: Electrodo situado en la zona occipital del cerebro en el hemisferio derecho.
- EEG.P8: Electrodo situado en el área parietal del cerebro en el hemisferio derecho.
- EEG.T8: Electrodo situado en el área temporal del cerebro en el hemisferio izquierdo.
- EEG.FC6: Electrodo situado en el área frontal central del cerebro en el hemisferio derecho.
- EEG.F4: Electrodo situado en el área frontal del cerebro en el hemisferio derecho.
- EEG.F8: Electrodo situado en el área frontal temporal del cerebro en el hemisferio derecho.
- EEG.AF4: Electrodo situado en el área frontal del cerebro en el hemisferio derecho.

4.2.3.3 Metodología experimental

Se reclutaron 20 estudiantes universitarios diestros sanos de la Universidad Técnica de Machala (UTMACH). Antes de iniciar la adquisición de datos, cada sujeto de prueba recibió instrucciones sobre las tareas a realizar y se llevó a cabo una breve sesión de prueba. Las tareas que los sujetos de prueba realizaron durante el proceso de adquisición se describen en la sección 4.2.3.1; primero, se pidió al sujeto que visualizara el símbolo \oplus en el centro de la pantalla para registrar la Tarea de Reposo, durante 3,5 segundos. En ese momento, el sujeto de prueba sólo visualiza el centro del monitor totalmente relajado sin realizar ninguna tarea. Como se muestra en la figura 4.2.3.4.1, en el monitor se presentaron al sujeto cuatro estímulos visuales de prueba, con una duración aleatoria de entre 3 y 3,5 segundos cada uno. La secuencia que incluye los cuatro estímulos visuales y la tarea de

reposo se mostró 40 veces a cada sujeto de prueba. A continuación, las especificaciones de los estímulos que indican la tarea que realizó el sujeto de prueba:

- Estímulo visual de 7Hz situado en la parte superior de la pantalla, mientras que el resto de los estímulos se atenúan en 80.
- Estímulo visual de 9Hz situado en la parte inferior de la pantalla, mientras que el resto de los estímulos se atenúan en 80.
- Estímulo visual de 11 Hz situado en la parte derecha de la de la pantalla, mientras que el resto de los estímulos se atenúan en 80.
- Estímulo visual de 13 Hz situado en el lado izquierdo de la pantalla, mientras que el resto de los estímulos se atenúan en 80.

4.2.3.4 Datos registrados

El número de sujetos de prueba que participaron voluntariamente fueron veinte, con una edad media de 27 ± 3 años, cuya información demográfica es la siguiente:

- Diez de los sujetos de prueba eran ecuatorianos.
- Diez de los sujetos de prueba eran asiáticos.

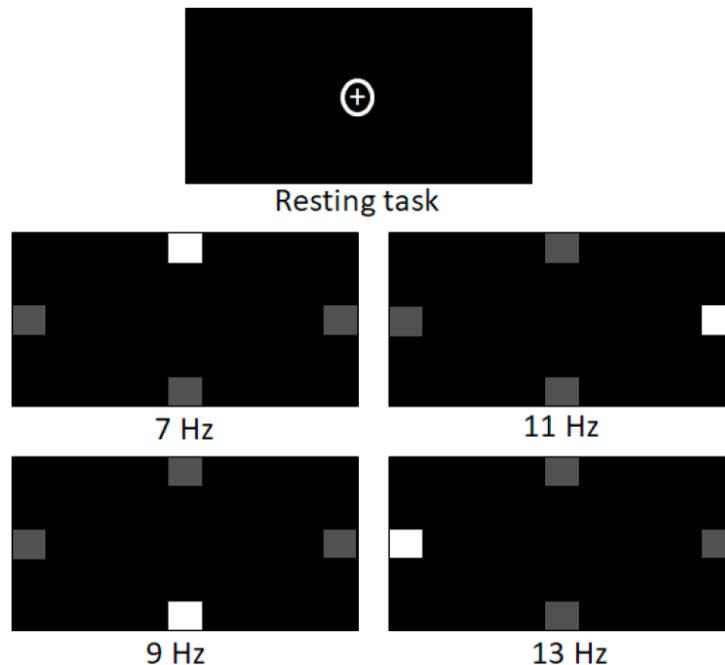


Figura 4.2.3.4.1 Estímulos visuales utilizados durante el experimento. [autoría propia]

Cada uno de los 20 sujetos de prueba realizó sesiones de once minutos, durante los cuales se les mostró 40 repeticiones de la secuencia de los 4 estímulos visuales (7 Hz, 9 Hz, 11 Hz y 13 Hz) y la tarea de reposo. Los programas utilizados para adquisición de datos fueron el software Emotiv PRO y Matlab. Emotiv PRO es el programa que establece la conexión entre el dispositivo Emotiv EPOC vía bluetooth, y guarda los registros en un archivo “.CSV” para cada uno de los sujetos de prueba. El software Matlab se encargó de mostrar los estímulos visuales, tal como se muestra en la figura 4.2.3.4.1, así como sincronizar los “MarkerValueInt”, cuyos valores son entre 1 – 5, que indican el momento en que el sujeto de prueba recibe los estímulos ópticos de 7Hz, 9Hz 11Hz, 13Hz y la tarea de reposo. La figura 4.2.3.4.2 representa la arquitectura de los programas utilizados durante la adquisición de datos.

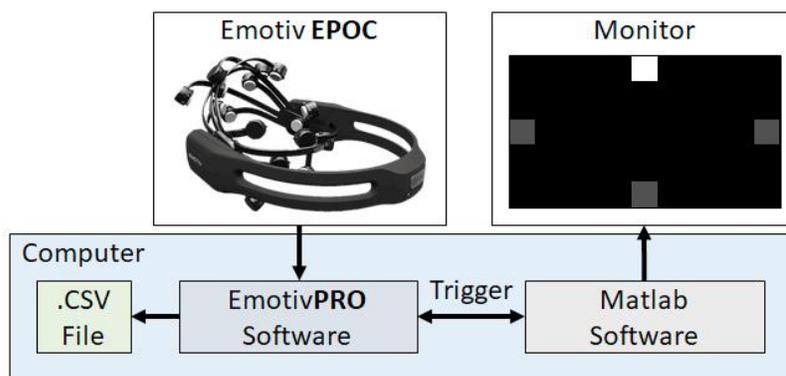


Figura 4.2.3.4.2 Estructura de los códigos utilizados en el proceso de adquisición. [autoría propia]

Esta arquitectura generó un archivo “.CSV” para cada sujeto de prueba, estos veinte archivos se encuentran en 1 archivo “EmotivData.zip”, y están publicados en IEEEDataport [48].

4.2.4 Metodología

Después de analizar los veinte archivos “.CSV” de la carpeta “1_EmotivData.zip” se eliminaron los datos del sujeto número once del conjunto de datos ya que tenía tiempos de adquisición diferentes al resto de los sujetos, esto debido a los bajos niveles de tensión (nivel de batería 1) del equipo de adquisición de datos. Esta anomalía se detectó sólo en este sujeto de prueba. Los diecinueve archivos “.CSV” restantes fueron procesados en Python, identificando el MarketValueInt (Etiqueta), luego se procedió a dividir en doscientos nuevos archivos “.CSV” (resultados de cuarenta repeticiones y cinco estímulos) que

representan doscientas tareas de visualización de estímulos almacenados en carpetas separadas: 7Hz, 9Hz, 11Hz 13Hz y Baseline (tarea de reposo). Además, sólo los archivos EEG.O1, EEG.O2 fueron seleccionados. La información se organizó en una carpeta "2_Raw Data.zip", disponible en IEEE-Dataport [48] a través de las siguientes subcarpetas:

- La carpeta "7Hz" contiene 748 archivos ".CSV".
- La carpeta "9Hz" contiene 754 archivos ".CSV".
- La carpeta "11Hz" contiene 756 archivos ".CSV".
- La carpeta "13Hz" contiene 759 archivos ".CSV".
- La carpeta "Resting Task" contiene 759 archivos ".CSV".

4.2.4.1 Preprocesamiento de datos

Los valores aberrantes de cada estímulo en 2_Raw Data.zip file fueron descubiertos. Para ello, se utilizó el método Rango Inter cuartil (IQR) [47], y se consideró un valor aberrante que estaba fuera de los límites superior e inferior calculados por el método mencionado; además, cualquier valor con esta condición fue sustituido por su límite más cercano. También, se utilizó un filtro Butterworth (IIR) de orden 20, de paso de banda, con un límite de frecuencia de 5 Hz a 30 Hz., este rango incluye las frecuencias de los estímulos visuales comprendidos entre 7 Hz y 13 Hz, los resultados están en la carpeta "3_Filtered Data.zip" en IEEE-Dataport [48].

De forma aleatoria, el conjunto de datos se dividió en un 70% para el conjunto de de entrenamiento, el 15% para el conjunto de validación y el 15% para el conjunto de prueba. Se aplicó la técnica de aumento de datos al conjunto de entrenamiento, añadiendo ruido blanco con diferentes amplitudes a la señal de EEG. Con esta técnica se triplicó el conjunto de entrenamiento, utilizando ruido blanco con amplitudes de 0,5 y 5 (que dieron los mejores resultados).

4.2.4.2 Extracción de características

Para la extracción de características, se desarrolló el algoritmo 4.1, que permite extraer 21 características de los conjuntos de entrenamiento, validación y pruebas: media, peso medio I, peso medio II, detector logarítmico, mediana, varianza, diferencia media absuelta, frecuencia media, frecuencia máxima, frecuencia central de la varianza, MaximumPSD, histograma de amplitud (10 rangos).

Algoritmo 4.1. Extracción de características. [autoría propia]

```
Result: Extracted features
for folder in DataFolders do
  for files in folder do
    for electrode in electrodes do
      Apply extract_features function to each file.
      Add extracted features to a dataframe.
    end
  end
  Export dataframe to csv format
end
```

Para la extracción de las características, se utilizó por separado la red de entrenamiento sin calibración de datos y la red de entrenamiento con calibración de datos. A continuación, en ambos casos, las características de la red de entrenamiento se normalizaron mediante la función de MinMaxScaler, como se indica en la ecuación 4.1. Por último, los conjuntos de validación y de prueba se normalizaron con los valores Mín y Máx obtenidos a partir de la red de entrenamiento.

$$Features(i)' = \frac{Features(i) - \min(Features)}{\max(Features) - \min(Features)} \quad (4.1)$$

4.2.4.3 Configuración de la clasificación

Las 21 características extraídas de los registros EEG.O1 y EEG.O2, obteniendo 42 columnas de características que se convirtieron en los datos de entrada de los algoritmos de clasificación: Máquinas de Vectores de Soporte (SVM), Red Neuronal Perceptrón Multicapa (MLP), Bosque Aleatorio (RF), K-Vecinos más Cercanos (KNN) y Aumento del Gradiente Xtreme (XGBoost) [49].

4.2.5 Análisis de resultados

Una matriz de confusión [49] nos entrega información que nos permite evaluar los algoritmos de clasificación, algunos de los parámetros son: Verdadero-Positivo (TP), que es la probabilidad de que el clasificador indique que un valor es positivo, siendo este positivo. Verdadero-Negativo (TN), que es la probabilidad de que el clasificador indique que un valor es negativo. Falso-Positivo (FP), que es la probabilidad

de que el clasificador indique que un valor es negativo, siendo este positivo. Y finalmente, Falso-Negativo (FN), que es la probabilidad de que el clasificador indique que un valor es negativo, siendo este negativo.

De todos estos casos, lo ideal es maximizar la posibilidad de los valores TP y FN [49]. En esta sección se muestra la matriz de confusión, de la configuración propuesta y analizamos los siguientes parámetros de los algoritmos de clasificación:

- Los parámetros Verdadero-Positivo (TP) y Falso-Negativo (FN) se utilizan para el cálculo, como se muestra en la ecuación 4.2 [49]:

$$Recall(\%) = \frac{TP}{TP + FN} \quad (4.2)$$

- Especificidad: Probabilidad de clasificar los verdaderos negativos. Para su cálculo se utilizan los parámetros Verdadero-Negativo (TN) y Falso positivo (FP), según la ecuación 4.3 [49]:

$$Specificity(\%) = \frac{TN}{TN + FP} \quad (4.3)$$

- Los parámetros Verdadero-Negativo (TN), Falso-Positivo (FP), Falso-Negativo (FN), Verdadero-Positivo (TP) se utilizan para su cálculo, como se muestra en la ecuación 4.4 [49]:

$$Accuracy(\%) = \frac{TN + TP}{TN + FP + FN + TP} \quad (4.4)$$

- Precisión: Dispersión del conjunto de valores obtenidos. Para su cálculo se utilizan los parámetros Verdadero-Positivo (TP) y Falso-Positivo (FP), según la ecuación 4.5 [49]:

$$Precision(\%) = \frac{TP}{FP + TP} \quad (4.5)$$

Las combinaciones de clases binarias son las siguientes: (0) 7Hz y 9Hz; (1) 7Hz y 11Hz; (2) 7Hz y 13Hz; (3) 9Hz y 11Hz; (4) 9Hz y 13Hz; (5) 11Hz y 13Hz. Con las configuraciones

propuestas, los resultados obtenidos con todos los algoritmos de clasificación se muestran en la tabla 4.2.5.1.

Tabla 4.2.5.1 Resultados medios de clasificación obtenidos con el conjunto de pruebas. [autoría propia]

Sin aumento de datos				
Algorithm	Accuracy%	Recall%	Precisión%	Specificity%
SVM	0.51	0.52	0.34	0.51
MLP	0.52	0.52	0.51	0.52
RF	0.54	0.48	0.54	0.59
KNN	0.51	0.51	0.56	0.51
XGBoost	0.49	0.49	0.52	0.50
Con aumento de datos				
SVM	0.55	0.55	0.57	0.55
MLP	0.51	0.51	0.55	0.52
RF	0.58	0.59	0.58	0.56
KNN	0.54	0.54	0.53	0.54
XGBoost	0.57	0.56	0.58	0.57

En la tabla 4.2.5.2, se muestran los resultados de la comparación de los tiempos de entrenamiento y clasificación entre los algoritmos SVM, MLP, RF, KNN, XGBoost, utilizando el Rasp-berryPi4B con todos los algoritmos de clasificación. Estos resultados sugieren que pese a que MLP no es uno de los algoritmos más rápidos al momento de entrenar, si lo es al momento de clasificar.

Tabla 4.2.5.2 Tiempo medio de entrenamiento y clasificación con la Raspberry Pi4 B. [autoría propia]

Algoritmo	Entrenamiento (Seg)	Clasificación (Seg)
SVM	9.47	16.58
MLP	32.1	1.8
RF	719.68	20
KNN	0.78	12.16
XGBoost	19.33	7.12

4.3 Etapas del procesamiento de señales EEG

En esta sección se presenta el análisis de algoritmos de aprendizaje no supervisado en la detección de Señales Potenciales Visuales Evocados de Estado Estable (SSVEP). Además, se propone un análisis estadístico de la distribución de las señales normales de EEG para determinar la necesidad de un preprocesamiento que elimine los componentes de ruido de las redes eléctricas u otras posibles fuentes. Este preprocesamiento incluye el diseño y uso de un filtro que elimine cualquier componente de la señal que no esté en el rango de frecuencias de funcionamiento de la zona occipital del cerebro del EEG. Por último, se procede a utilizar el algoritmo K-means para agrupar las señales según sus características frecuenciales y temporales.

4.3.1 Introducción

Las señales biomédicas, como la EEG se utilizan para medir la actividad eléctrica del cerebro con la ayuda de electrodos que entran en contacto con el cuero cabelludo. Estas señales representan las actividades neuronales corticales de diferentes lóbulos del cerebro como el frontal, el temporal, el central, el parietal y occipital [50]. Estos electrodos que se encuentran en el lóbulo occipital del cerebro permiten detectar los estímulos visuales. La actividad eléctrica de esta zona del cerebro refleja el mismo comportamiento de la frecuencia que el estímulo visual [51]. Existen muchos métodos invasivos y no invasivos para adquirir estas señales de EEG. Las mediciones invasivas requieren el uso de agujas o incluso complicadas cirugías; sin embargo, el método no invasivo es más accesible y fácil de realizar. El método no invasivo es, el método de medición más común porque es superficial y se puede realizar con un riesgo mínimo para la persona. En este método los electrodos miden generalmente la activación eléctrica cortical [52].

El método no invasivo, también conocido como método de superficie a pesar de ser el más común, tiene problemas de interferencia causados por los electrodos utilizados en el cuero cabelludo; sin embargo, es importante que estos electrodos se humedezcan con un gel conductor con componentes de Cloruro de Sodio para reducir la impedancia del cuero cabelludo y se debe evitar el movimiento relativo entre los electrodos y la cabeza del sujeto [53]. La amplitud de las señales del EEG oscila entre los microvoltios y el rango inferior de milivoltios - mV (menos de 10mV). La amplitud y las propiedades de las señales de EEG tanto en el dominio del tiempo como en el de la frecuencia, dependen de factores como la

intensidad del estímulo, la calidad de los contactos de los electrodos utilizados como referencia, las propiedades de la piel del cuero cabelludo (por ejemplo, el grosor de la piel, el tejido adiposo, entre otros), las propiedades de los electrodos y el amplificador, así como la calidad del gel conductor [53,54].

El desarrollo de tecnologías para la rehabilitación de pacientes con deficiencias motoras, en particular para los que tienen dificultades para controlar sus movimientos, por efectos de enfermedades como el Parkinson, o lesiones en la columna vertebral o espasticidad muscular, es posible mediante la medición de las señales bioeléctricas que generan los pacientes y, por lo tanto, es posible determinar la intención de movimiento del paciente. Sin embargo, dada la susceptibilidad al ruido de estas señales, se han propuesto algunas metodologías de preprocesamiento y agrupación de las señales de EEG [55].

En este trabajo utilizamos el algoritmo K-means para agrupar señales de EEG preprocesadas, utilizando características temporales y frecuencia para detectar cuándo una persona está observando estímulos visuales en dos rangos de frecuencia.

4.3.2 Metodología

El proceso de adquisición de datos comenzó con la captura de señales de EEG de 5 voluntarios sanos y capacitados, los que dieron su consentimiento por escrito antes de realizar los experimentos. A cada voluntario se le pidió que repitiera un experimento 10 veces a diferentes frecuencias; cada experimento fue desencadenado por un estímulo visual.

El experimento se diseñó para registrar las señales de EEG generadas por dos electrodos: Occipital Izquierdo (LO) y Occipital Derecho (OR). Estos electrodos se colocaron en la superficie de la zona occipital del cuero cabelludo. Para realizar el experimento los voluntarios estaban sentados en una silla cómoda y de frente a una pantalla, que generaba estímulos visibles a través de Diodos Emisores de Luz (LEDs) blancos, en las siguientes frecuencias: 5, 6, 7, 8, 9, 24, 26, 27, 28 y 29 Hz.

La frecuencia de estos estímulos fue creada aleatoriamente por un generador de frecuencia digital. Durante el proceso de elicitación, los voluntarios deben estar relajados para que el experimento tenga éxito. La figura 4.3.2.1 muestra a un voluntario en el proceso de adquisición de señales EEG de superficie utilizando un equipo comercial no invasivo

[56]. Cada uno de estos estímulos tenía una duración de 19,5 segundos, un tiempo que se estableció mediante pruebas de laboratorio previas, considerando el suficiente tiempo como para que el voluntario se adaptara a los estímulos visuales.

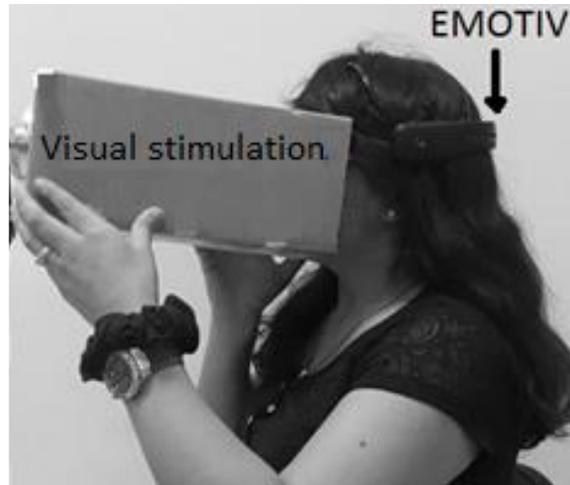


Figura 4.3.2.1 Estímulos visuales generados por una pantalla con LEDs utilizados para adquirir las señales de EEG occipital. [autoría propia]

Cada voluntario realizó un experimento para cada una de las 10 frecuencias de estímulos visuales (5, 6, 7, 8, 9, 24, 26, 27, 28 y 29 Hz.). En cada experimento, las señales de EEG generadas en los 2 electrodos (LO, RO) de la zona occipital, se registraron simultáneamente. Además, los datos EEG registrados fueron separados según la frecuencia de estímulo utilizada, teniendo de esta forma la etiqueta de los datos. Es importante señalar que el equipo de adquisición de datos tiene una tasa de muestreo de 128 Hz. o muestras por segundo, permitiendo adquirir 2.500 muestras, considerando que cada tarea tiene una duración de 19,5 segundos.

Los electrodos utilizados para medir las señales de EEG fueron de las dos áreas occipitales, como se muestra en la figura 4.3.2.2. Estos electrodos captan los estímulos visuales generados por los globos oculares.

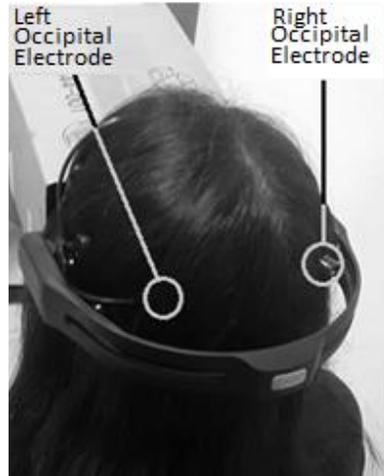


Figura 4.3.2.2 Distribución de los 2 electrodos occipitales Equipo Emotiv. [autoría propia]

La figura 4.3.2.3 muestra el comportamiento de las señales de EEG adquiridas, las que contienen 2500 muestras capturadas a través de dos electrodos simultáneamente alrededor de la zona occipital. Las líneas horizontales de la figura representan el promedio mínimo y máximo del desplazamiento (offset) de las señales adquiridas. Esto se debe a la presencia de la DC, también conocida como artefactos DC [53,57].

Para simplificar el análisis, las señales de EEG de todos los experimentos se agruparon en una única matriz: EEG (2500 filas que contienen las muestras x 20 columnas que contienen las frecuencias).

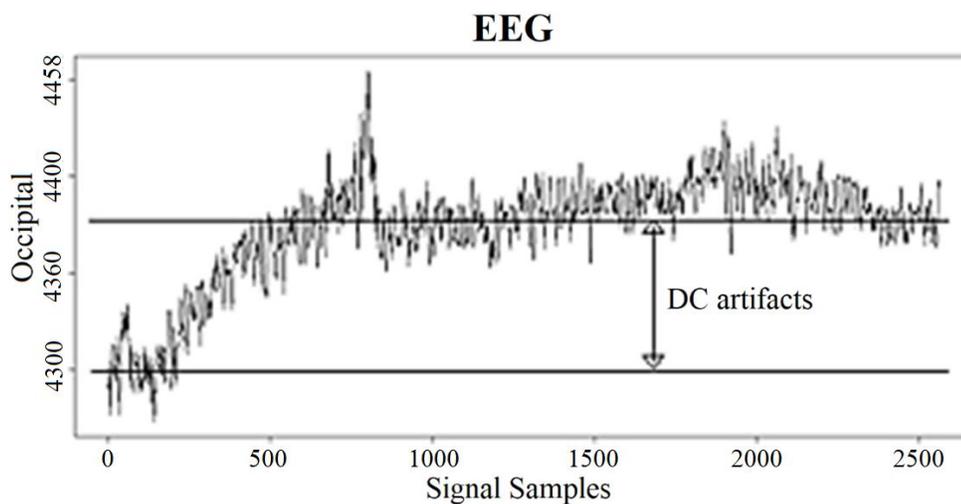


Figura 4.3.2.3 Artefactos de corriente continua presentes en las señales del EEG occipital estímulo visual de 5 Hz. [autoría propia]

Una vez identificados los artefactos de DC, la hipótesis de normalidad de los datos adquiridos es rechazada, y se determina la necesidad de filtrar los datos. Como se demostró en [58], cuando los datos contienen ruido debido a artefactos de DC no se comportan como una distribución normal. En la prueba con un nivel de significación del 5% para una hipótesis nula H_0 , las señales de EEG capturadas no se distribuyeron normalmente con media cero y valor de varianza 1, mientras que para la hipótesis alternativa H_1 , las señales de EEG se modelaron como una distribución normal con media cero y valor de varianza 1. Por lo tanto, no hay pruebas suficientes para rechazar la hipótesis nula H_0 , porque las señales capturadas son muy susceptibles a la interferencia del ruido procedente de los artefactos de DC y de la red eléctrica. La presencia de artefactos de DC altera las características de las estadísticas descriptivas en el dominio del tiempo, y los valores de la media y la varianza. La figura 4.3.2.4 muestra: a) el histograma de las señales del EEG occipital con un visual de 5 Hz, que no se comporta como una distribución normal; y, b) la comparación entre la distribución de las señales del EEG frente a los datos de una distribución normal teórica. En la figura 4.3.2.4 se muestra una distribución normal de las muestras.

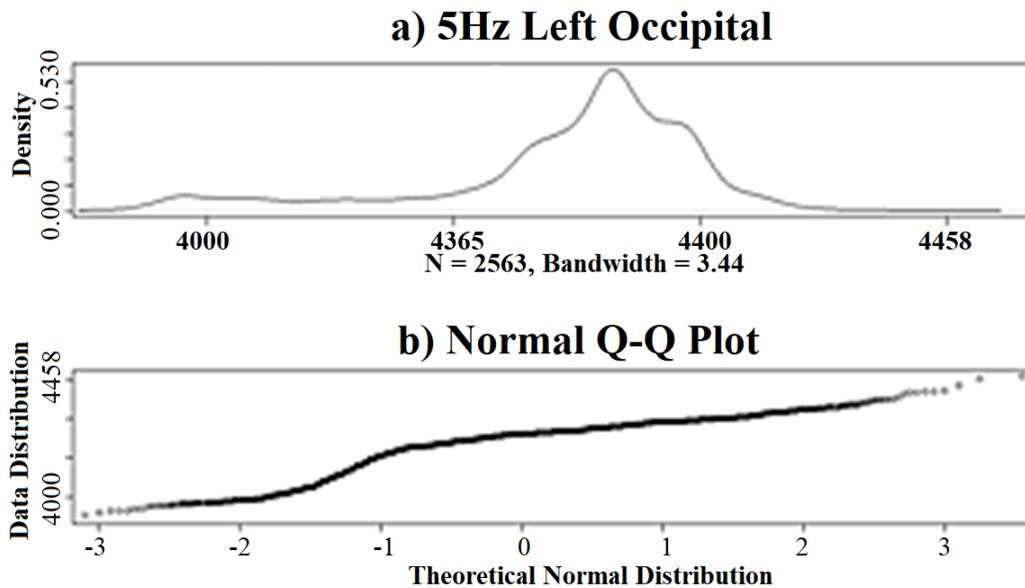


Figura 4.3.2.4 a) Histograma de la señal de EEG sin preprocesamiento para el área occipital con un estímulo visual de 5 Hz. b) Comparación entre la distribución de los datos adquiridos del EEG frente a los datos de una distribución normal. [autoría propia]

Los resultados del histograma para los estímulos visuales del EEG, en las frecuencias 6, 7, 8, 9, 24, 26, 27, 28 y 29 Hz, muestran un comportamiento similar al que se observa en

la figura 4.3.2.4, incluso la comparación entre la distribución de los datos del EEG frente a una distribución normal teórica.

También se realizó el análisis en el dominio de la frecuencia y se detectó la presencia de ruido con sus efectos. Para este análisis se aplicó la Transformada Rápida de Fourier (FFT) y se aplicó a las 2.500 muestras, por electrodo por estímulo visual y por voluntario. La figura 4.3.2.5 muestra la señal con una fuerte actividad cerca de la frecuencia de 0 Hz, en presencia de artefactos de DC.

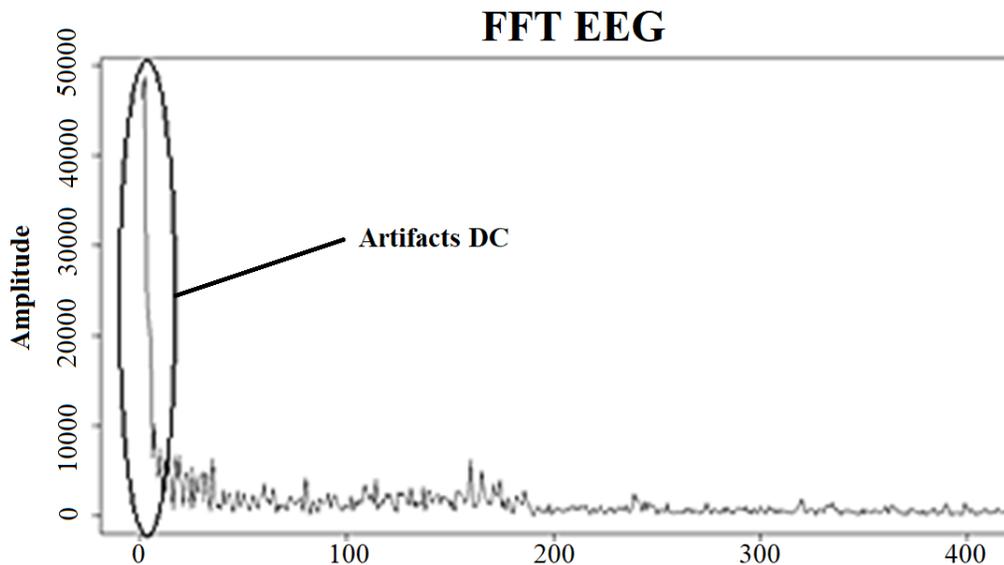


Figura 4.3.2.5 Un análisis de la frecuencia FFT de la señal de EEG. [autoría propia]

Una vez identificada la presencia de ruido producido por los artefactos DC en las señales de EEG, se diseñó un filtro Butterworth de tercer orden para obtener un gráfico de respuesta en frecuencia lo más plano posible, y evitar la distorsión de la señal original en el dominio de la frecuencia [58,59]. El filtro se diseñó para el rango de frecuencias entre 5 y 30 Hz, que es el rango en el que se generaron los estímulos del EEG generados.

4.3.3 Resultados

Tras identificar las características del ruido, se procedió a utilizar el filtro paso banda diseñado. La figura 4.3.3.1 muestra 2.500 registros de señales de todos los electrodos EEG. En ella puede verse la eliminación completa del ruido de los artefactos de DC. También se puede observar una señal sin desviaciones ni tendencias para realizar el

análisis y extracción de las características temporales y frecuenciales sin distorsiones importantes.

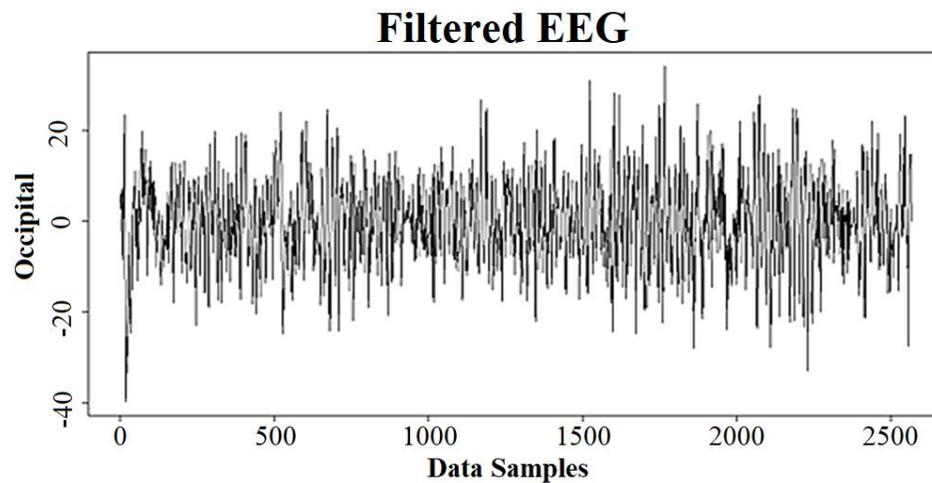


Figura 4.3.3.1 Señal de EEG sin artefactos de DC en los 2 electrodos del área occipital occipital. [autoría propia]

La figura 4.3.3.2 muestra la señal sin artefactos de DC. Esta señal permite evaluar la actividad cortical en el área occipital de voluntarios y posteriormente extraer estadísticas descriptivas de las características.

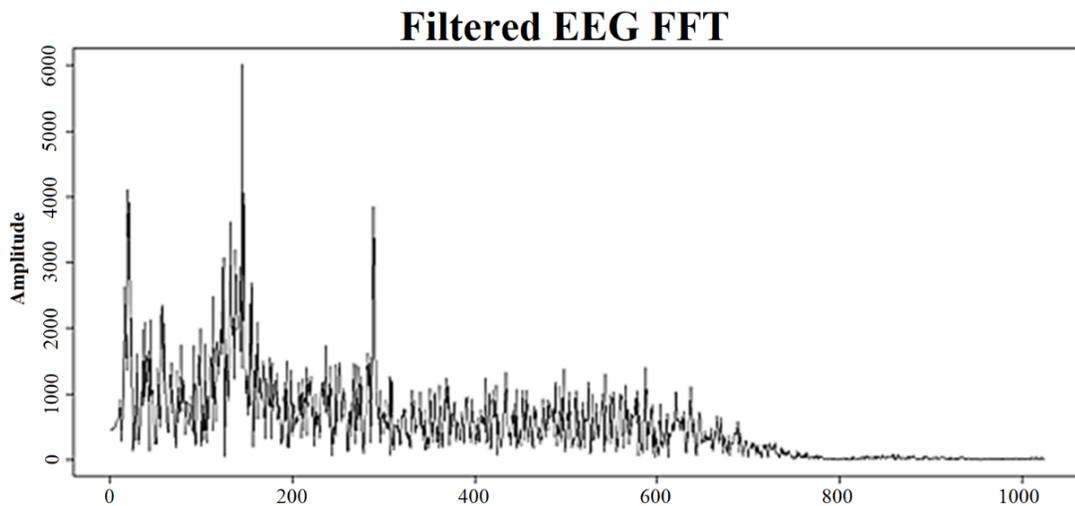


Figura 4.3.3.2 Análisis de la frecuencia filtrada con la FFT de las señales de EEG. [autoría propia]

Tras el preprocesamiento de las señales de EEG, la prueba de normalidad de la hipótesis se realizó a un nivel de significación del 5%, siendo la H_0 la hipótesis nula. Los datos de EEG no se distribuyen normalmente con un valor medio de 0 y una varianza de 1 frente a la hipótesis alternativa H_1 : Los datos del EEG se distribuyen normalmente con valores de

media y varianza de 0 y 1 respectivamente. La prueba indica que hay pruebas suficientes para rechazar la hipótesis nula H_0 , por lo que aceptamos la hipótesis alternativa H_1 . La figura 4.3.3.3 muestra: a) el histograma de las señales de EEG que filtran el área occipital con el mismo estímulo visual de 5 Hz, que muestra una distribución normal; b) muestra la comparación entre la distribución de las señales de EEG frente a los datos de una distribución normal teórica. El gráfico muestra también un comportamiento de distribución normal y debido a la pendiente perfecta del gráfico, es comprensible inferir una distribución teórica.

Los resultados del histograma de las señales EEG filtradas con las frecuencias de los estímulos visuales: 6, 7, 8, 9, 24, 26, 27, 28 y 29 Hz, es similar a lo que se representa en la figura 4.3.3.3, incluso para los datos de EEG distribuidos adquiridos frente a la distribución normal teórica.

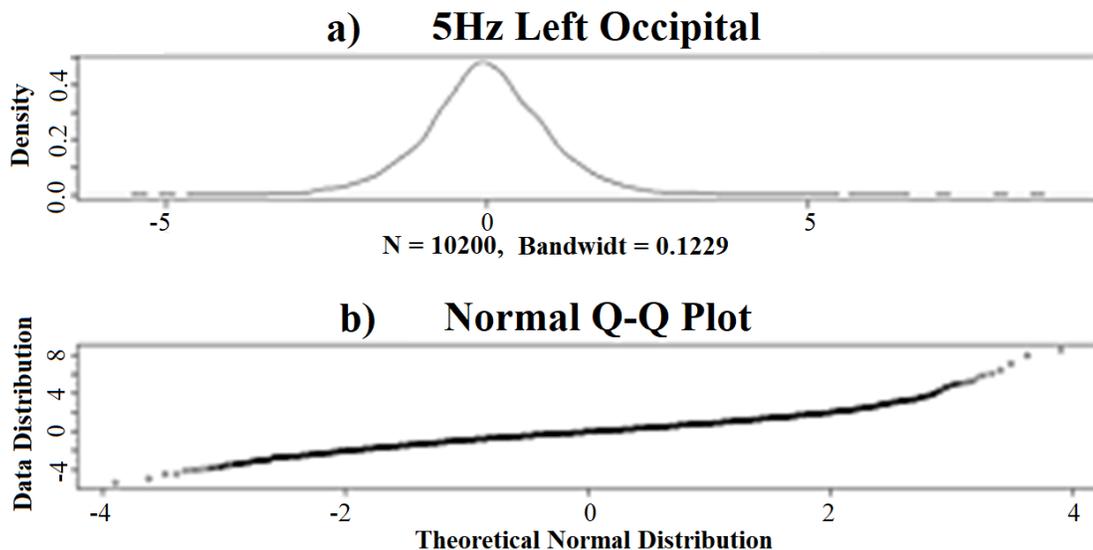


Figura 4.3.3.3 a) Histograma de la señal de EEG con preprocesamiento al área occipital con estímulo visual de 5Hz. b) Comparación entre la distribución de los datos adquiridos del EEG frente a los datos de una distribución normal. [autoría propia]

Una vez preprocesadas las señales adquiridas de los electrodos Occipital Izquierdo (LO) y Occipital Derecho (RO). Se procedió a extraer las características estadísticas temporales, tales como: el mínimo, máximo, mediana, media aritmética, varianza (LO, RO) covarianza (LO, RO), correlación (LO, RO) y el valor máximo de la tasa de frecuencia de la señal FFT. Además, se extrajeron algunas características de las señales en el dominio de la frecuencia, tales como: WhichMax (LO, RO), Varianza (LO, RO) Covarianza (LO, RO) y Correlación (LO, RO).

Para facilitar el análisis se elaboró una matriz en la que las filas representan la frecuencia de los estímulos visuales y las columnas las características temporales y la frecuencia de ambos electrodos de las áreas occipitales izquierda y derecha (LO, RO). A continuación, se describe el algoritmo utilizado para determinar el número adecuado de clusters [60]:

- 1. Seleccionar K centroides (K filas elegidas al azar).
- 2. Asignar a cada punto de datos el centroide más cercano.
- 3. Recalcular el centroide como la media de todos los puntos de datos de un cluster (es decir, los centroides son vectores medios de longitud p , donde p es el número de variables).
- 4. Asignar los puntos de datos a sus centroides más cercanos.
- 5. Repetir los pasos 3 y 4 hasta que las observaciones no se reasignen o se alcance el número máximo de iteraciones (R utiliza 10 por defecto).

El algoritmo, utiliza el algoritmo mejorado de R. Hartigan y Wong [61]. Esto significa que en los pasos 2 y 4, cada observación se asigna al cluster con el menor valor de la Suma del Error Cuadrático (SS). La figura 4.3.3.4 muestra el gráfico de la SS frente al número de clusters. Esto sugiere que el número óptimo de conglomerados es dos ($k = 2$).

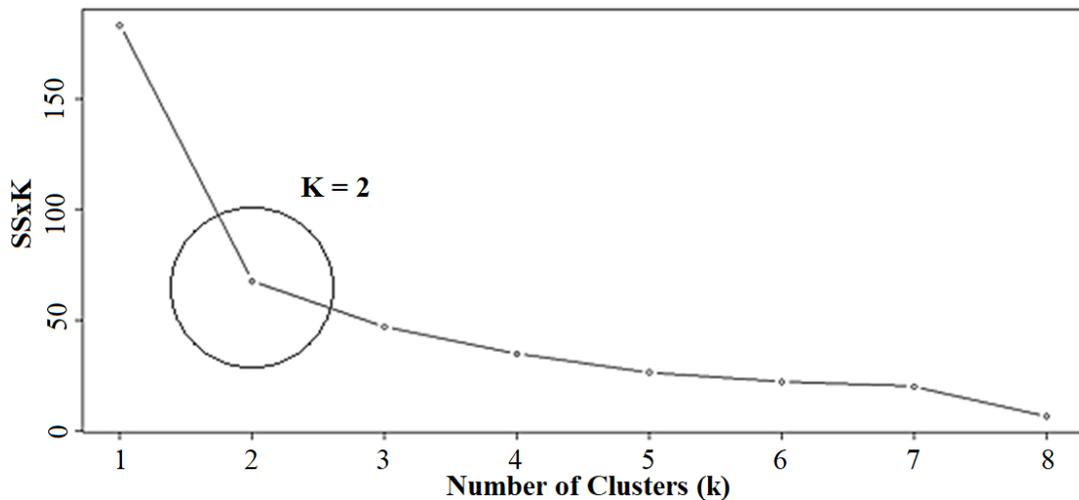


Figura 4.3.3.4 SS vs k clusters. [autoría propia]

Una vez conocido el valor de k sugerido para nuestro conjunto de datos, los 2 clusters representan las señales pertenecientes al grupo de 5 a 9 Hz y el otro grupo de 24 a 29 Hz. A continuación, procedemos a aplicar el algoritmo K-means a un grupo de datos con las siguientes características: a) datos con las características de varianza (tiempo y

frecuencia), covarianza (tiempo y frecuencia) y correlación (tiempo y frecuencia). b) Los mismos datos, pero ahora con el índice de frecuencia máxima. c) Los datos ahora sin varianza (tiempo y frecuencia), covarianza (tiempo y frecuencia) y correlación (tiempo y frecuencia). Los resultados que se obtuvieron con los grupos de datos se muestran en la tabla 4.3.3.1. El acierto de la detección se midió comprobando la agrupación de los datos; este procedimiento se realizó con las siguientes frecuencias de estímulo: 6, 7, 8, 9, 24, 26, 27, 28 y 29 Hz.

Tabla 4.3.3.1 Resultados de aciertos utilizando k-means a diferentes grupos de características. [autoría propia]

Caso	Características	% Acierto
A	Var(t,f), Cov(t,f), Corr(t,f)	36%
B	WhichMax(f), Var(t,f), Cov(t,f), Corr(t,f)	80%
C	WhichMax(f)	80%

La figura 4.3.3.5 muestra el cluster con las variables índice de frecuencia máxima “WhichMax”, tanto para el electrodo occipital izquierdo WhichMax(f01), como para el electrodo occipital derecho WhichMax(f02). Esto nos da un porcentaje entre SS / SS total = 74,3%.

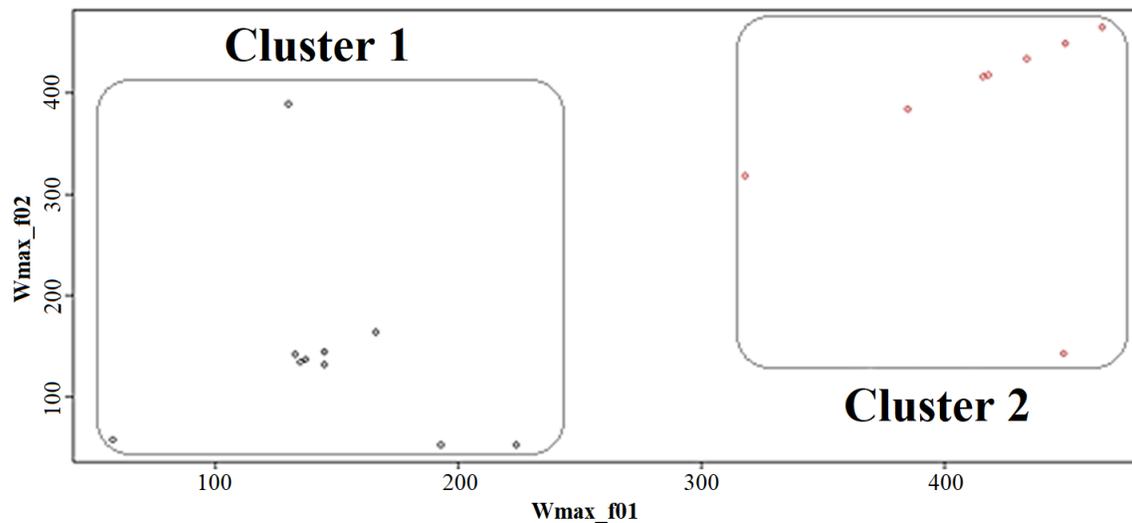


Figura 4.3.3.5 Señales de EEG en el rango de frecuencia de 5 a 9 Hz (cluster 1) y en el rango de 24 a 29 Hz (cluster 2). [autoría propia]

4.4 Control de una mano robótica empleando características temporales

Hoy en día, con el uso de las impresoras 3D, las prótesis de un miembro superior están más disponibles, principalmente los dispositivos mioeléctricos controlados; sin embargo, hay algunos casos en los que la señal mioeléctrica es difícil de detectar debido a la lesión del paciente, como en el caso de prótesis controlada con señales EEG. En este trabajo, informamos de un caso de 64 años que recibió una descarga eléctrica de 13,2 kV. en su mano derecha, registrando una baja señal Electromiográfica (EMG). El brazo protésico se diseñó utilizando el software Blender. Se tomaron las dimensiones y se realizaron ajustes utilizando la mano izquierda como referencia. Todos los componentes de la prótesis se imprimieron en 3D: las bisagras con material flexible y el resto con Polilactida Ácida (PLA). Se utilizaron tres actuadores colocados en el antebrazo, que se conectaban a los dedos: un motor para el pulgar y los otros dos motores conectados a dos dedos para cada uno. Utilizamos el Neurosky Mindwave 2 equipado con un sensor frontal y transmisión inalámbrica de datos y una unidad de control para obtener los datos del EEG. Los datos del dispositivo de EEG se filtraron y se ajustaron a las capacidades del paciente para encontrar un valor de umbral que se ha utilizado como parámetro de control. Como resultado, la prótesis impresa en 3D se ajustó al muñón del paciente. El paciente fue capaz de realizar movimientos de apertura y cierre de la mano con una fuerza de 11,0 N, capaz de agarrar objetos de la vida cotidiana. Los resultados demostraron la viabilidad de un control sencillo de las prótesis mediante el registro de datos de EEG, especialmente para aquellas cuyas señales de electromiografía son difíciles de leer.

4.4.1 Introducción

La tecnología de impresión 3D ha influido significativamente en el desarrollo de las prótesis de miembro superior. Así, se diseñan e imprimen nuevos dispositivos que pueden adaptarse fácilmente a un brazo humano, que sea ligero, fácilmente reemplazable y de bajo coste. La mayoría de los desarrollos de prótesis impresas en 3D están diseñadas para niños [62,63]. Hay tres tipos de prótesis que se pueden comercializar o imprimir en 3D: las prótesis cosméticas pasivas y las activas en las que el movimiento de las articulaciones puede conseguirse de dos formas: la accionada por el cuerpo y la accionada eléctricamente. El codo controla el antebrazo accionado por el cuerpo en la mayoría de los

casos. Sin embargo, para otros niveles de amputación, los diseñadores se centran en acomodar las necesidades del paciente a los dispositivos según el nivel de amputación. En cambio, los dispositivos de accionamiento eléctrico se accionan detectando la actividad mioeléctrica [64,65], siendo el desafío el sensado, la identificación de la señal y la clasificación [66], y el sistema de control [67]. En la actualidad, dos empresas venden prótesis comerciales de bajo coste: Youbionic con un precio de \$ 1.000 y Open Bionics con un precio de \$ 3.000 aproximadamente. Estas prótesis son dispositivos mioeléctricos. Por otro lado, las prótesis mioeléctricas disponibles en el mercado tienen un precio de entre \$ 25.000 y \$ 75.000 dólares [68]. Aunque los esfuerzos se han centrado en el desarrollo de dispositivos mioeléctricos, hay algunas situaciones en las que los datos electromiográficos son de registrar y analizar, porque las terminaciones nerviosas pueden perder eficacia debido a la amputación o, en algunos casos, no existen.

La mayoría de las prótesis existentes en el mercado, tanto comerciales como las presentadas en algunos trabajos de investigación, controladas en base a señales mioeléctricas, tienen funcionalidades muy diversas; sin embargo, algunas de ellas necesitan descifrar señales para su posterior interpretación y encontrar patrones de control para el movimiento de la mano [69,70]. Además, otras prótesis requieren la colocación de diversos sensores musculares superficiales sobre la piel o implantados internamente en el músculo, lo que podría incomodar al usuario en el momento de la colocación y podría producir pequeñas descargas eléctricas que causaran daños al sistema nervioso [71,72]. Además, debido a la cantidad de datos de la Electromiografía (EMG) y la decodificación mediante hardware programable, el algoritmo utilizado para el funcionamiento de los servomotores tiende a ser complicado [73,74], lo que produce tiempos de respuesta lentos.

Como alternativa, algunos autores utilizaron las señales de EEG para controlar los movimientos de la prótesis de dedo utilizando el dispositivo de bajo coste "Emotiv" que consta de 14 canales. Independientemente del hecho del excelente rendimiento y la compatibilidad con el hardware de desarrollo programable (Arduino, Raspberry Pi, etc.) y software como Labview [75], podría ser un gran problema para que el paciente realice sus actividades diarias. Llevar todos los elementos externos de medición y control (14 canales de EEG y placas de circuitos), esto restringe drásticamente la libertad del paciente [76,77].

En este contexto, las prótesis eléctricas controladas por señales Electroencefalográficas (EEG) podrían ser una excelente alternativa a los dispositivos mioeléctricos, proporcionando un nuevo canal de control a los individuos con graves deficiencias motoras [78]. Pocos estudios demuestran un buen rendimiento y precisión en el accionamiento de cada articulación del dispositivo. En la mayoría de los trabajos publicados, los sistemas complejos basados principalmente en Brain-Computer Interfaces (BCI), consisten en un sensor EEG que capta las señales cerebrales procesadas a través de un ordenador utilizando MATLAB [79,80]. Estos sistemas dependen de un ordenador, por lo tanto no son adecuados para los pacientes que utilizan el dispositivo para la vida diaria debido a la dependencia de un ordenador. Este trabajo tuvo como objetivo diseñar y construir una prótesis autónoma (brazo protésico autónomo), que utilice las señales EEG generadas al mostrar las señales de imágenes motoras, de manera que permitió al usuario controlar los movimientos del dispositivo y sirvió como banco de pruebas de los algoritmos de caracterización utilizados en EEG-BCI, que permitieron extraer las características adecuadas de las intenciones motoras, y responder nuestra pregunta de investigación.

4.4.2 Metodología

A continuación, los detalles más relevantes que fueron contemplados para realizar la metodología experimental.

4.4.2.1 Paciente:

La prótesis fue diseñada para un paciente que perdió su brazo por una amputación quirúrgica. El sujeto de prueba es de 62 años y sufrió una descarga eléctrica de 13,2 kV en su mano derecha. Dos meses después de la operación, el muñón medido está a 10 cm del codo; sin embargo, no se registró correctamente una señal EMG perceptible.

4.4.2.2 Diseño mecánico y fabricación

Para el diseño de todos los componentes, utilizamos software de código abierto “Blender” [80]. La prótesis completa consta de dos partes principales: la mano y el antebrazo, con 32 piezas individuales. Cada articulación de los dedos comprende una bisagra de flexión impresa en 3D que proporciona la unión de ambos elementos, permitiendo la rotación y retorno a la posición inicial. Para el diseño de las bisagras, hemos utilizado el

procedimiento descrito en [81]. Los dedos y la mano tienen conductos internos que permiten el paso de hilos de nylon conectados a los correspondientes servomotores. El antebrazo es una carcasa con soportes internos para atornillar tres servomotores y la unidad de control electrónico. Utilizamos dos imágenes del muñón del antebrazo sobre el fondo de la rejilla milimétrica para ajustar el tamaño y la forma de la prótesis a la anatomía del paciente. Posteriormente, se realizó el modelado en 3D con las fotos utilizando el software Blender.

Finalmente, todos los componentes fueron exportados en formato STL, y luego se imprimieron en 3D utilizando la impresora Rostock Max V3 delta (véase la figura 4.4.2.2.1). Para las bisagras, utilizamos Ninjatek Cheetah [81], con los parámetros principales: altura de capa de 0,2 mm, densidad de relleno del 20% tipo rejilla, y temperatura del extrusor de 235 °C. Se utilizó PLA con los siguientes parámetros para el resto de los componentes: altura de la capa 0,2 mm, densidad de llenado 10% tipo rejilla y temperatura del extrusor de 210 °C.

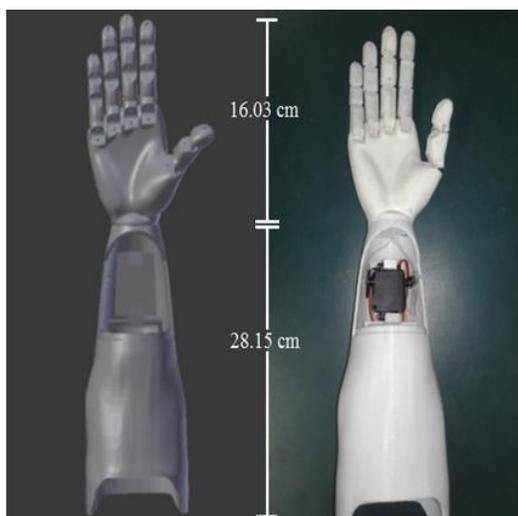


Figura 4.4.2.2.1 La parte izquierda muestra el diseño de la prótesis realizado con Blender. La derecha muestra el dispositivo impreso en 3D, incluidos los servomotores. [autoría propia]

4.4.2.3 Auricular EEG y señales neuronales

Se utilizó el dispositivo de auriculares EEG (Neurosky Mindwave Mobile 2), que lee los datos a través de un sensor en la región frontopolar (véase la figura 4.4.2.3.1). Los datos de EEG obtenidos se leen en tiempo real y proporcionan niveles de atención entre 0 y 130 donde el valor máximo denota la concentración total, y el valor mínimo denota la

desconcentración total. Todos los datos registrados se envían en tiempo real a través de una conexión Bluetooth.

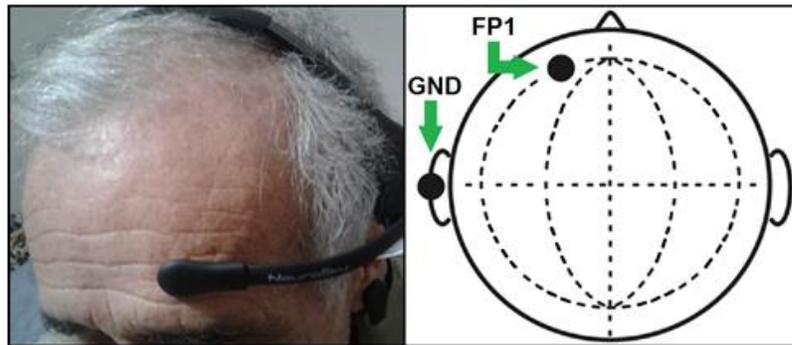


Figura 4.4.2.3.1 Ubicación del sensor Neurosky en la región Frontopolar uno y virtual en el oído izquierdo en el Sistema 10-20 EEG. [autoría propia]

4.4.2.4 Interfaz Arduino y algoritmo de control

El antebrazo de la prótesis 3D fue diseñado con una cavidad para albergar los elementos electrónicos y mecánicos. Estos elementos fueron: La tarjeta microcontroladora Arduino, el módulo Bluetooth HC-05, y los servomotores MG995. A través de un emparejamiento inalámbrico, se estableció la conexión del Neurosky con la tarjeta Arduino. Por lo tanto, los datos obtenidos en tiempo real de los auriculares Neurosky pueden ser leídos y procesados por el microcontrolador Arduino. Para la activación de los servomotores, el algoritmo se calibró con la actividad del paciente para detectar un rango de valores de atención con un umbral de 60 (equivalente a 1.17 V DC). Cuando se supera este valor, el paciente puede cerrar los dedos. En caso contrario, los abre (ver figura 4.4.2.4.1).

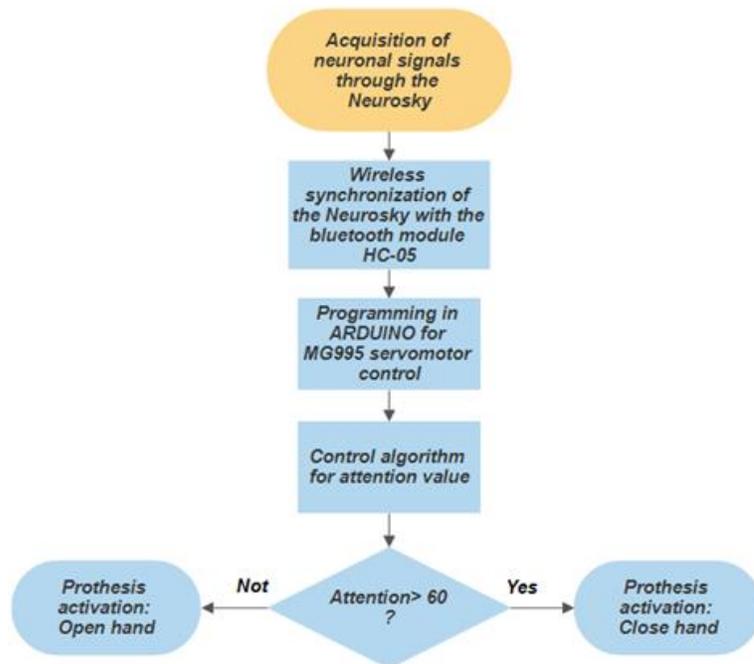


Figura 4.4.2.4.1 Diagrama de flujo general del algoritmo de programación. [autoría propia]

4.4.2.5 Implementación y conexión del cableado

Por último, se colocaron y ajustaron los elementos electrónicos en el interior del antebrazo de la prótesis 3D. Los servomotores se fijaron en el interior del antebrazo protésico. Se utilizaron hilos de nylon que conectan la bocina del servomotor con los extremos de los dedos a través de los conductos internos, que se ajustaron normalmente abiertos. Las conexiones generales de los elementos se muestran en la figura 4.4.2.5.1; además, todo el sistema interno es alimentado por baterías recargables de 5 V. DC.

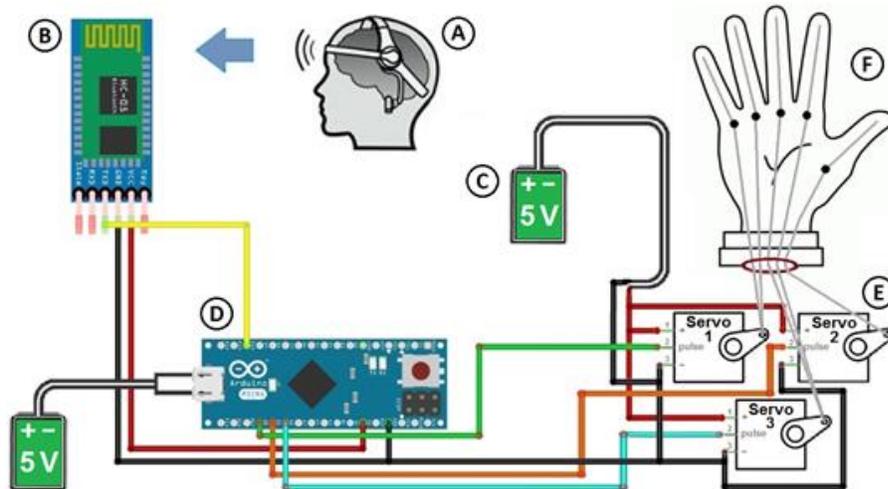


Figura 4.4.2.5.1 Esquema general de conexión. A. Dispositivo Neurosky sobre la cabeza. B. Módulo Bluetooth HC-05. C. Baterías de 5 [V]. D. Arduino Micro. E. Servomotores. F. Borrador de mano. [autoría propia]

4.4.3 Resultados

Las pruebas se realizaron para determinar los niveles de concentración del paciente que ha sufrido una amputación reciente del brazo y determinar si se puede realizar el control de la prótesis utilizando un dispositivo Neurosky; y, permitió probar el algoritmo de extracción de características de la señal EEG, y determinar las intenciones motoras de las extremidades superiores.

4.4.3.1 Análisis de los valores de atención

La siguiente tabla muestra una comparativa de cinco conjuntos de datos de niveles de atención obtenidos en sujetos con y sin amputación. Esta comparación nos permite determinar si un sujeto puede realizar una acción de apertura y cierre de la mano de la prótesis, en función de su nivel de concentración. Adquirimos 100 muestras por cada dato de algunos sujetos de control, y los valores medios se muestran en la Tabla 4.4.3.1.1.

Tabla 4.4.3.1.1 Comparación del conjunto de datos de atención entre sujetos con y sin amputación. [autoría propia]

Sujeto de control sano				
Dato	Edad	Genero	Valor de la atención Concentración	Valor de la atención Desconcentración
1	44	Mujer	100	11
2	50	Hombre	100	20
3	64	Hombre	100	15

4	74	Hombre	97	12
5	55	Mujer	97	23
Sujeto amputado				
Dato	Edad	Genero	Valor de la atención Concentración	Valor de la atención Desconcentración
1	62	Hombre	97	41
2			100	41
3			93	44
4			90	44
5			83	47

Como se muestra en la Tabla 4.4.3.1.1, la media de la columna de concentración de valores de atención, de los sujetos de control, no difirió significativamente con la media de los pacientes, según la prueba F realizada: $F(4) = 0,062$, $p = 0,019$. Sin embargo, la columna de desconcentración del valor de atención difiere significativamente entre el paciente y los sujetos de control: $F(4) = 4,238$, $p = 0,190$. Las respuestas neurales fueron similares al grado de concentración que tienen, que se consiguió con un pequeño entrenamiento mental antes de la prueba. A pesar de las diferencias entre el paciente y los sujetos de control, el paciente pudo realizar correctamente el control de la prótesis tal y como lo haría una persona normal basándose en su respuesta mental. Entonces, cuando el nivel de concentración supera el límite del umbral, los servomotores se activaron, y la mano procedía a cerrarse. A la inversa, cuando el nivel de concentración cae por debajo del umbral, la mano procedía a abrirse. El valor del umbral se determinó experimentalmente con el paciente, tomando los datos medios de las muestras cuando la mano comienza a cerrarse. El umbral obtenido para el paciente fue de 60. Gracias al muestreo instantáneo de datos en tiempo real del Neurosky, se logró obtener un control del tiempo de respuesta corto. Los experimentos realizados en el banco de pruebas, con el sujeto amputado, permitieron determinar la funcionalidad y eficacia de la prótesis y los algoritmos. A continuación, se evaluó si el paciente podía realizar actividades de la vida diaria, como coger un objeto. Por lo tanto, además de la operación esencial de apertura y cierre de la mano (véase la figura 4.4.3.1.1), se procedió a realizar pruebas de agarre de pequeños objetos ordinarios, llevadas a cabo con éxito.



Figura 4.4.3.1.1 Paciente con la prótesis y el dispositivo Neurosky. [autoría propia]

4.4.3.2 Par, fuerza de agarre y pérdidas en las articulaciones de los dedos

El par del servomotor MG995 es de 8,5 Kgf por cm, con tensión de funcionamiento de 5 V DC. Las pérdidas generadas por el hilo de nylon, el elemento flexible y la fricción del hilo con los conductos internos de la mano impresa, sirvieron para estimar el par del servomotor. Para ello, se utilizó un dinamómetro colocado en el extremo del dedo, y así medir el par del servomotor necesario. El valor medido en cada dedo fue de 2,22 N. de media por dedo. Finalmente, para determinar la fuerza total de la mano se multiplica por los cinco dedos, como se indica en la ecuación 4.6.

$$F_T = 2.22N \times 5 \sim 11.0N \quad (4.6)$$

Esto significa que la fuerza de agarre total de la prótesis impresa en 3D fue de aproximadamente 11,0 N. Como se muestra en la figura 4.4.3.2.1.

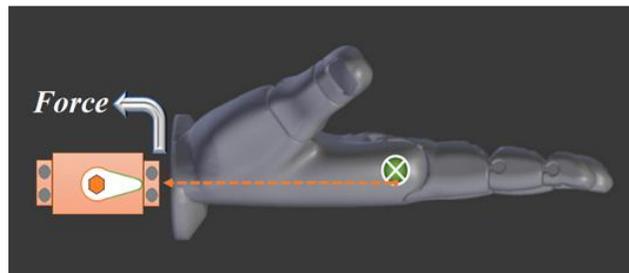


Figura 4.4.3.2.1 Fuerza de transmisión a los dedos a través del hilo de nylon, el servomotor emite un par específico de 8,5 Kgf por cm. [autoría propia]

4.5 Detección de intenciones motoras en extremidades superiores basados en señales EMG

En esta sección se comprueban los algoritmos de aprendizaje no supervisado, que fueron evaluados con señales EEG en la sección anterior, con las señales bioeléctricas de Electromiografía (EMG). El propósito de evaluar los métodos de preprocesamiento, extracción de características y clustering, con otra señal bioeléctrica, fue para verificar si estas técnicas pueden ser generalizadas en procesamiento de señales bioeléctricas.

Para validar la eficacia del preprocesamiento, analizamos los componentes de frecuencia y la distribución de las señales EMG filtradas. Posteriormente, los datos filtrados se procesaron con los algoritmos K-means, DBSCAN y Clustering Jerárquico para determinar la intención de un sujeto al realizar una tarea. Los resultados muestran que el algoritmo K-means agrupa los nueve gestos realizados por los sujetos, en comparación con los algoritmos DBSCAN y Clustering Jerárquico, que no fueron capaces de realizar el clustering como se esperaba. Sin embargo, coinciden en el rendimiento de la agrupación de los grupos de gestos combinados.

4.5.1 Introducción

Las señales biomédicas de la EMG permiten medir la diferencia de potencial generada en los músculos durante la contracción y la relajación. Estas señales representan actividades neuromusculares controladas por la corteza motora del cerebro [6]. En la corteza motora se genera un tren de impulsos eléctricos; luego los nervios cerebrales llevan esta señal a través del cerebro medio. Estas señales descienden por la médula espinal; a través de la sinapsis, el receptor excita el músculo, provocando su acortamiento [82].

Existen dos métodos para medir las señales de EMG: Intramuscular y Superficial. La medición intramuscular se realiza con una aguja hipodérmica que se introduce a través de la piel hasta el tejido muscular; este método se considera invasivo e innecesario en algunos casos. En cambio, el método superficial no es invasivo y representa menos riesgo para el paciente, por lo que es el más popular. En este método un electrodo mide la activación muscular dentro de unas pocas fibras musculares [83].

El método superficial tiene interferencias debido a los sensores utilizados en la piel para recoger las señales eléctricas procedentes de los músculos. Mientras viajan a través de

diferentes tejidos, la amplitud de las señales EMG se encuentra en el rango de microvoltios (μV) a milivoltios (mV); sin embargo, el nivel eléctrico suele ser inferior a 10mV. Las propiedades de la piel (por ejemplo, el grosor de la piel, el tejido adiposo, entre otras), la duración y la intensidad de la contracción muscular definen las características de las señales EMG en los dominios del tiempo y la frecuencia; así como, las propiedades del amplificador, el tipo de electrodos y el contacto piel-electrodo [84,85].

La susceptibilidad al ruido de las señales EMG ha motivado varias metodologías para analizar y preprocesar las señales EMG. Nuestra contribución es utilizar señales EMG preprocesadas con algoritmos de clustering para detectar la intención durante el desarrollo de tareas motoras [86].

En esta sección, utilizamos el análisis estadístico de las señales EMG para detectar la presencia de ruido. Luego, las señales EMG para eliminar los componentes de ruido. Por último, las señales preprocesadas se procesaron utilizando algoritmos de agrupación.

4.5.2 Metodología

El conjunto de datos utilizado en este trabajo fue recogido por colegas, investigadores del Parque Tecnológico de San Sebastián – España [58]. Las señales EMG se midieron en seis sujetos sanos, diestros y sin trastornos musculares. Los sujetos dieron su consentimiento por escrito antes de realizar los experimentos.

Los experimentos consistieron en el registro de señales eléctricas de EMG obtenidas de los antebrazos de los sujetos, a través de treinta electrodos superficiales (10 mm de diámetro), mientras los sujetos respondían a un estímulo visual. El estímulo está relacionado con el lenguaje de signos, y un programa informático genera aleatoriamente los gestos. La tarea de los sujetos consistía en reproducir los gestos aleatorios que aparecían en el monitor del ordenador [84].

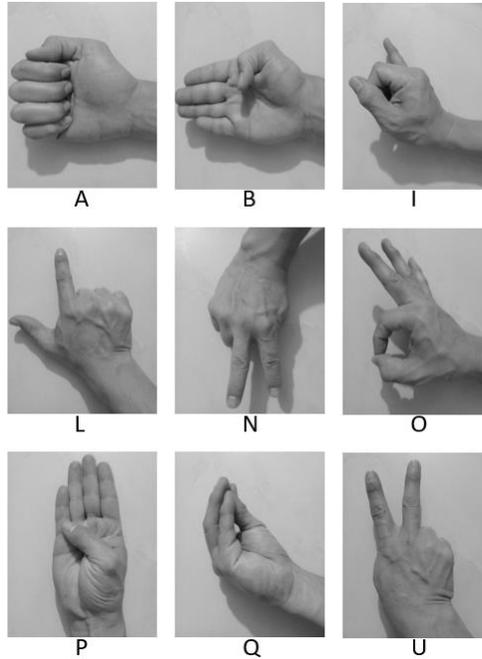


Figura 4.5.2.1 Reproducción del gesto de la mano a los estímulos visuales utilizados para adquirir las señales EMG. Procedimiento también descrito en [84].

La figura 4.5.2.1 muestra el conjunto de gestos, de los que se seleccionó un conjunto de nueve letras en lenguaje de signos. El tiempo de proyección de cada estímulo visual, correspondiente a nueve tareas, fue de 6,6 segundos. Este tiempo se estableció teniendo en cuenta las pruebas anteriores, así como para dar tiempo suficiente al sujeto para reproducir la tarea y capturar las señales EMG [84].

Los treinta electrodos de superficie se distribuyeron uniformemente en el antebrazo del sujeto como se muestra en la figura 4.5.2.2. Esta distribución uniforme en el antebrazo derecho permitió registrar completamente la actividad muscular en cada experimento.

Cada sujeto realizó nueve repeticiones presentadas de forma pseudo-aleatoria de cada uno de los nueve gestos (A, B, I, L, N, O, P, Q y U). Las señales EMG (32 electrodos: dos como referencia terrestre) se registraron en paralelo (todos los sensores a la vez). La frecuencia de muestreo fue de 1.000Hz, y cada evento duró 6,6 segundos [84].

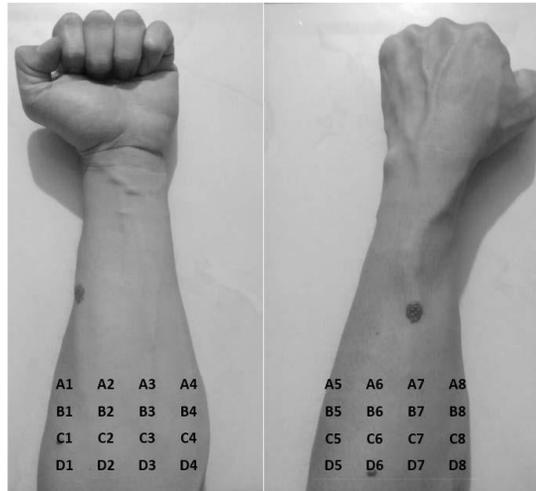


Figura 4.5.2.2 Distribución de treinta y dos electrodos de superficie alrededor del músculo digitorum communis. Los electrodos denominados A6 y D6 se utilizaron como referencia a tierra [84].

Para garantizar la estabilidad del registro de las señales EMG, se utilizaron las últimas 3.600 muestras, de las 6.600 adquiridas para cada tareas o letras realizadas, teniendo en cuenta que el sujeto en ese tiempo ya había mantenido el antebrazo y el gesto [85].

La figura 4.5.2.3 muestra un gráfico de las señales eléctricas en el dominio del tiempo, que representa la actividad muscular del antebrazo derecho del sujeto. La tarea realizada fue la imitación de la letra A en la primera repetición. La señal eléctrica contiene 3.600 muestras de treinta electrodos, registrados simultáneamente; las señales contienen componentes de Corriente Directa (DC) o artefactos de baja frecuencia (cerca de 0 Hz), principalmente debido a la sudoración en la piel o al movimiento relativo entre la piel y los electrodos. Otras fuentes de ruido tienen componentes de frecuencia, como la frecuencia cardíaca (1Hz a 2Hz) y la frecuencia de la red eléctrica (50Hz) [84].

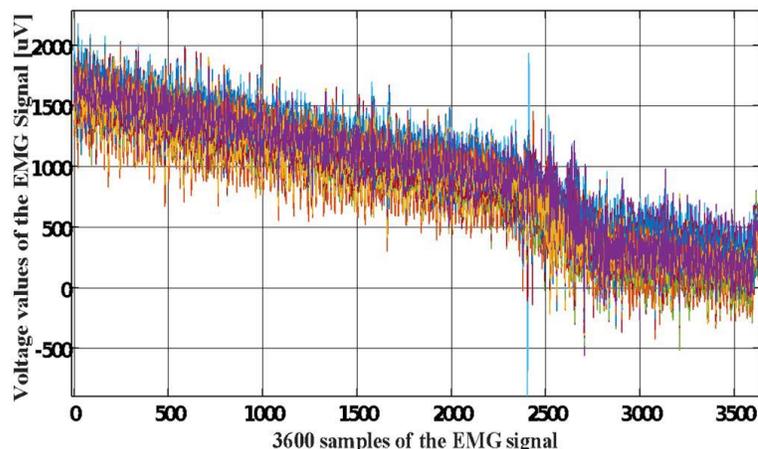


Figura 4.5.2.3 Artefactos de DC presentes en los treinta electrodos de la señal EMG para la letra A. [autoría propia]

El análisis de los datos de preprocesamiento se realizó utilizando Matlab 2017b (The MathWorks, Natick, MA) y la caja de herramientas de Processing Toolbox. Los algoritmos de agrupación se realizaron en RStudio V1.0.143 [58]. Los registros de las señales EMG se agruparon y almacenaron en un archivo de Matlab “DEMG” conteniendo 3.600 muestras de los 30 electrodos, para cada uno de los 9 gestos, con 9 repeticiones realizadas por los 6 sujetos ($3600 \times 30 \times 9 \times 9 \times 6$).

Debido a la presencia de ruido y artefactos de DC, los datos no presentaron una distribución normal. Una vez identificada la presencia de artefactos de DC el siguiente paso, fue realizar la prueba de hipótesis de normalidad de las señales. La prueba realizada con un nivel de significación del 5% mostró que, para la hipótesis nula H_0 de las señales EMG capturadas, no presentaban una distribución normal con media cero media y varianza con valor 1.

Mientras que para la hipótesis H_1 , las señales EMG mostraron una distribución normal con media cero y varianza con valor 1. Por lo tanto, no hay pruebas suficientes para rechazar la hipótesis nula, H_0 , dado que las señales capturadas eran muy susceptibles a la interferencia inducida por el ruido de los artefactos de DC, así como de la red eléctrica (50Hz). La presencia de artefactos de DC modifica las características de las estadísticas descriptivas en el dominio del tiempo, como los valores medios y la varianza. La figura 4.5.2.4 muestra el histograma de todas las señales EMG de los treinta electrodos superficiales, con ruido de baja frecuencia cerca a 0Hz, y el ruido con frecuencias superiores a 20Hz.

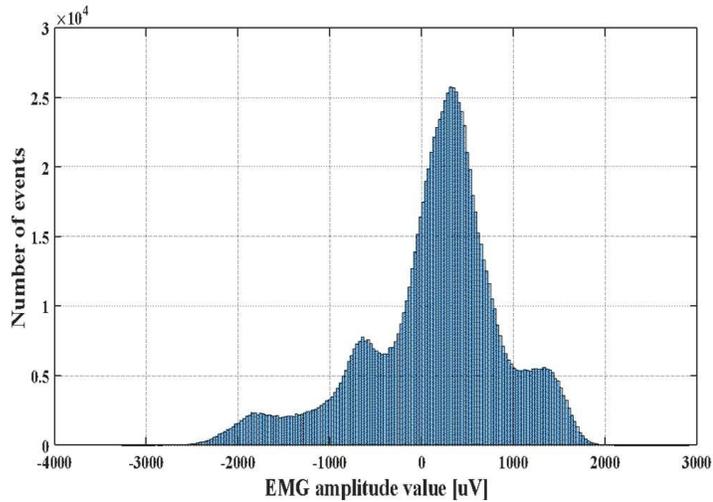


Figura 4.5.2.4 Histograma de las señales EMG sin procesamiento. [autoría propia]

La metodología propuesta también consideró el análisis en el dominio de la frecuencia, para determinar la presencia de ruido generado por la red de distribución eléctrica. Este análisis se realizó utilizando la Transformada Rápida de Fourier (FFT) al archivo Matlab de datos “DEMG”.

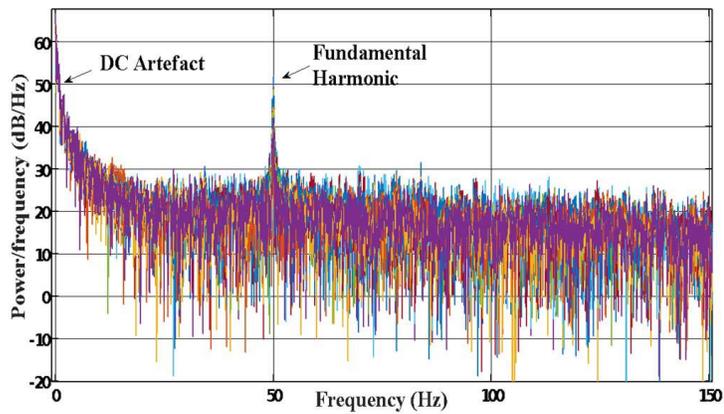


Figura 4.5.2.5 Análisis de frecuencias utilizando la FFT de señales EMG con ruido componentes de ruido. [autoría propia]

La figura 4.5.2.5 muestra que todos los electrodos tenían una fuerte actividad debido a la presencia de valores de artefactos de DC cercanos a 0 Hz de frecuencia. Además, se pudo observar una pronunciada actividad en la frecuencia de 50Hz; que se conoce como armónico fundamental generado por la red eléctrica.

La actividad muscular medida por los electrodos de superficie EMG, registró la actividad muscular en el rango de frecuencia de 7Hz a 20Hz. La figura 4.5.2.6 muestra el filtro de

paso de banda Butterworth-IIR, el coeficiente constante fue diseñado para la banda de frecuencia de 7Hz a 20Hz. Para producir una respuesta en frecuencia lo más estable posible, manteniendo la señal de interés eliminando el ruido de los datos EMG adquiridos [87].

Una vez preprocesados los datos adquiridos de los treinta electrodos EMG, se extrajeron algunas características temporales, por ejemplo: el valor máximo, el valor mínimo, la media aritmética y la mediana durante 3.600 muestras (4 características para cada electrodo). Además, se extrajeron la varianza, la covarianza y la correlación entre los treinta electrodos (90 características para cada electrodo). Además, se extrajeron características de las señales en el dominio de la frecuencia como: el valor máximo, el valor mínimo, la media aritmética, la mediana y el valor máximo, índice (que-Max) en el periodograma (5 características para cada electrodo). También hemos considerado el valor de la varianza, la covarianza y los valores de correlación entre los treinta electrodos (90 características para cada electrodo).

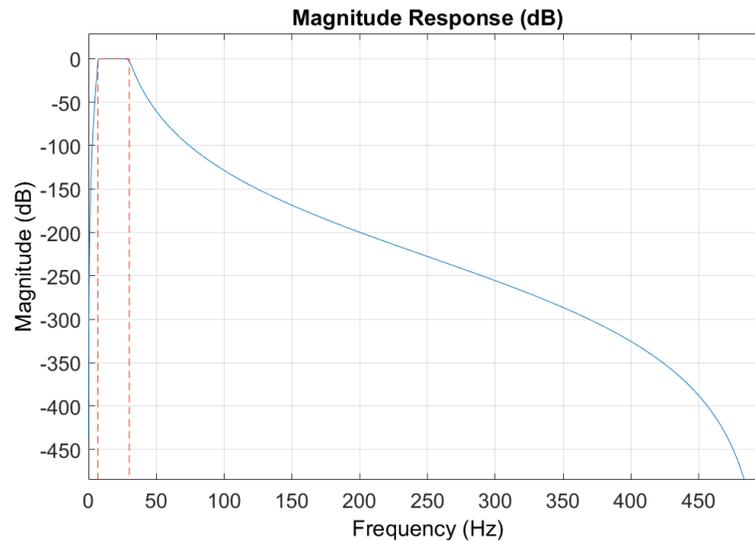


Figura 4.5.2.6 Ganancia del filtro Butterworth para la frecuencia de la rabi de 7Hz a 20Hz. [autoría propia]

Estas 189 características extraídas de cada uno de los 30 electrodos EMG (5.670 características en total), fueron creadas y almacenadas en un nuevo archivo Matlab bidimensional "FEMG", donde sus filas representan los nueve gestos o tareas realizadas por los seis sujetos durante nueve repeticiones (486 filas), y las columnas contienen las características de tiempo y frecuencia (5.670 columnas). Además, se añadió una primera

columna con la etiqueta de la letra reproducida por los sujetos, esta etiqueta nos permitió evaluar la tasa de éxito de los algoritmos de clustering utilizados.

El primer algoritmo de clustering utilizado con el archivo FEMG (486x5671) fue K-means. Siguiendo a Hartigan y Wong [87,88] determinamos el número adecuado de clusters ($k = 9$). Utilizando una configuración de tipo convexo, este algoritmo obtuvo nueve clusters, cada uno correspondiente a los nueve gestos. Los resultados corresponden a: Clúster 1 - la tarea realizada para el gesto letra A, Cluster 2 - letra B, Cluster 3 - letra I, Cluster 4 - letra L, Grupo 5 - letra N, Grupo 6 - letra O, Grupo 7 - letra P, Cluster 8 - letra Q, y Cluster 2 - letra U.

El algoritmo de Clustering basado en la Densidad (DBSCAN) con el archivo FEMG (486x5671). Los puntos mínimos son cuántos vecinos debe tener un punto para ser considerado en un clúster; pero, antes de utilizar este algoritmo, calculamos el valor de la Distancia Epsilon (EPS) entre los puntos para ser considerado parte del mismo cluster aplicar con un minpoints = 7 y un valor de distancia EPS = 65 [89,90]. El algoritmo DBSCAN obtuvo: Cluster 1 correspondiente a los gestos A, B, I, L y N. El cluster 2 corresponde a la letra O, P, Q y letra W.

El tercer algoritmo utilizado fue el Jerárquico, luego del análisis del archivo FEMG (486x5671), este algoritmo determinó dos árboles de clusters: Clúster 1 conformado por las letras A, I y L. Cluster 2 correspondiente a las tareas realizadas a la letra B, O, P, Q, W y la letra N.

4.5.3 Resultados

El filtro diseñado para preprocesar las señales EMG fue capaz de reducir el ruido identificado. La figura 4.5.3.1 muestra la reducción del ruido en el dominio del tiempo, correspondiente a la letra A, realizado por el sujeto uno, durante la primera repetición. Las señales EMG mostraron un pico de respuesta durante las 500 muestras, luego la señal se estabiliza cerca de cero voltios, que es una respuesta típica del filtro Butterworth-IIR Bandpass de Butterworth-IIR.

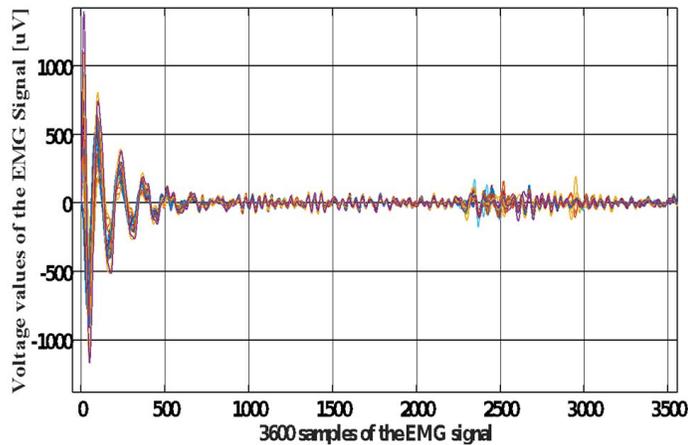


Figura 4.5.3.1 Señal EMG sin artefactos de DC presentes en los treinta electrodos de una letra A. [autoría propia]

El filtro de paso banda diseñado redujo la frecuencia de 50 Hz de los armónicos fundamentales, generados por la red eléctrica y los artefactos de DC de baja frecuencia cercanos a cerca de 0Hz, el preprocesamiento del archivo DEMG (3600 x 30 x 9 x 6) en Matlab, nos permite evaluar la actividad muscular durante la ejecución de las tareas por parte de los sujetos. La figura 4.5.3.2 muestra la actividad de las señales EMG en el rango de frecuencia de 7Hz a 20Hz, durante el gesto realizado correspondiente a la letra A, por el sujeto uno, durante la primera repetición.

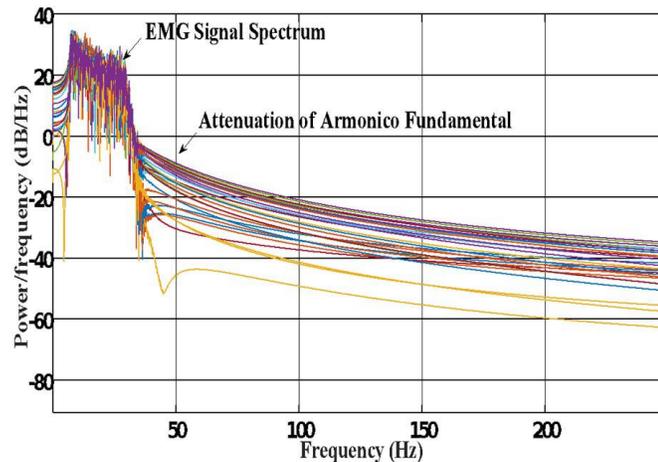


Figura 4.5.3.2 Frequency analysis of the filtered EMG signals using FFT. [autoría propia]

Tras el preprocesamiento de las señales de EMG, se realizó la prueba de hipótesis de normalidad, también con un nivel de significación del 5%. La hipótesis nula H_0 : Los datos de EMG no muestran una distribución normal (media cero y varianza 1) frente a H_1 : Los

datos de EMG muestran una normal (media cero y varianza 1). La prueba muestra que hay pruebas suficientes para rechazar la hipótesis nula H_0 . Por lo tanto, se acepta la hipótesis H_1 , que indica que las señales EMG tienen una distribución normal.

La figura 4.5.3.3 muestra el histograma de todas las señales EMG filtradas de los treinta electrodos, donde se observa la distribución normal con media cero y varianza 1, lo que es consistente ya que todos los electrodos tienen actividad en la banda de 7Hz a 20Hz, sin artefactos DC. A diferencia del histograma mostrado en la figura 4.5.2.4, con desviación de la media, producto del ruido de baja frecuencia cerca de 0Hz, y una varianza muy amplia producto del ruido de las frecuencias superiores a 20Hz.

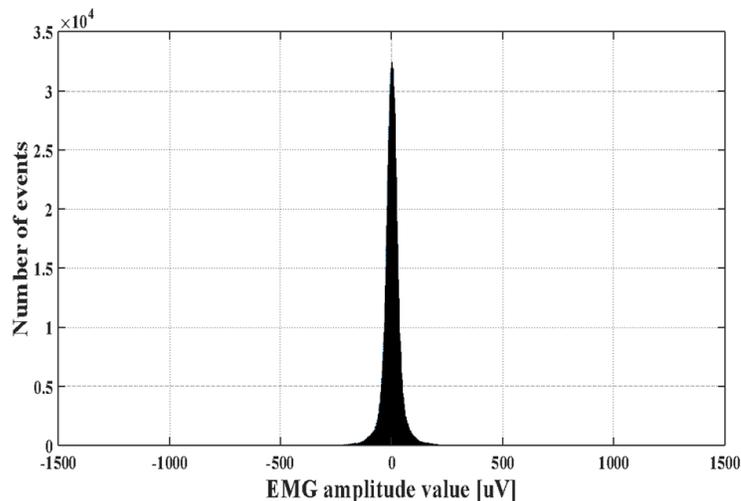


Figura 4.5.3.3 Histograma de las señales EMG filtradas con distribución normal. [autoría propia]

La figura 4.5.3.4 muestra la Suma del Error Cuadrático (SSE) frente al número de conglomerados; de donde se deduce que el número apropiado de conglomerados es $k = 8$. Esto da un porcentaje entre entre_SSE y total_SSE de 74,3%. Sin embargo, dado que el número de conglomerados debe ser nueve, dado el número de gestos, el valor entre_SSE y total_SSE es el mismo porcentaje. En la detección de los nueve gestos, el algoritmo K-means fue capaz de agrupar cada una de las nueve letras realizadas por los sujetos, y obtuvo una media de éxito cercana al 50% con los nueve clusters.

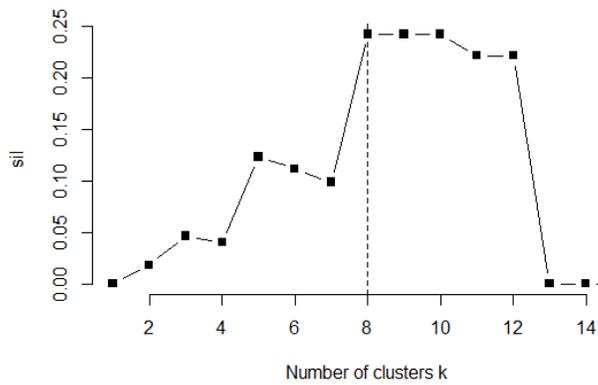


Figura 4.5.3.4 Evaluación del algoritmo K-means con nueve centroides. [autoría propia]

La evaluación del algoritmo DBSCAN se muestra en figura 4.5.3.5, donde el mejor número de clusters fue de dos grupos, y tiene una capacidad muy baja para detectar las letras realizadas por los sujetos. En este caso el algoritmo DBSCAN tiene un éxito cercano a cero porque no fue capaz de agrupar las nueve letras y no fue capaz de diferenciar las letras A, B, I, L o la letra N. Asimismo, este algoritmo no fue capaz de diferenciar las letras O, P, Q ni la letra U.

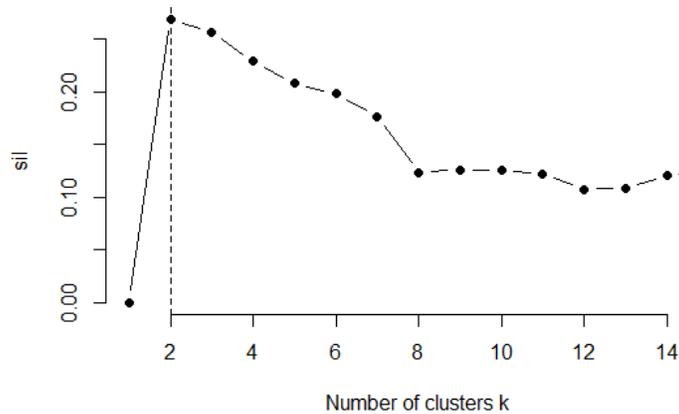


Figura 4.5.3.5 Evaluación del algoritmo DBSCAN. [autoría propia]

La figura 4.5.3.6 muestra el resultado de la evaluación de la cantidad de clusters del algoritmo de Aglomeración Jerárquica, donde el mejor número de clusters son dos grupos, este algoritmo no fue capaz de detectar las nueve letras realizadas por los sujetos. El algoritmo de Aglomeración Jerárquica obtuvo una tasa de éxito cercano a cero y no fue

capaz de diferenciar las letras A, I o la letra L. Además, este algoritmo no fue capaz de diferenciar las letras B, O, P, Q, U o la letra N.

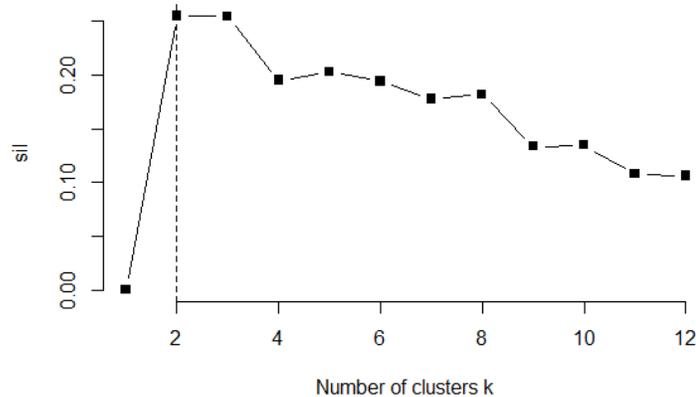


Figura 4.5.3.6 Evaluación del algoritmo de clustering jerárquico. [autoría propia]

4.6 Conclusiones

A continuación, se presentan las conclusiones que buscan responder a la pregunta ¿Cómo podrían adaptarse los actuales algoritmos de caracterización utilizados en el EEG-BCI para extraer características adecuadas de las intenciones motoras de las extremidades inferiores?, para cada una de las secciones arriba detalladas.

4.6.1 Extracción de características basadas en densidad espectral en la detección de tareas motoras e imagenético motoras de señales EEG

En la comparación de los algoritmos de clustering con señales EEG para detectar diferentes tareas que incluyen la actividad motora e imaginaria, fue necesario utilizar la FFT de las señales de EEG, para eliminar la fuerte actividad de densidad espectral cerca de 0Hz. El uso del filtro Butterworth nos permitió definir el comportamiento de la densidad espectral de potencia en el rango de frecuencia de 7-30 Hz de las señales adquiridas del cerebro, que corresponden a la corteza motora.

El análisis de la agrupación obtenida, de cada uno de los diferentes algoritmos evaluados, nos permitió determinar que los K-means, K-medoids y los algoritmos de Clustering Jerárquico tienen un mejor rendimiento en la detección de la actividad motora, concretamente son mejores con las tareas motoras de ambas manos (T3), con un éxito

superior al 80%. Los resultados también muestran que el algoritmo de Clustering Espectral es el que tiene un mejor porcentaje de éxito en la detección de las tareas motoras de ambos pies (T4). En nuestros experimentos, ninguno de los algoritmos evaluados pudo realizar una detección de tareas motoras imaginarias de ambos pies (T2).

4.6.2 Clasificación de señales SSVEP-EEG de la región occipital del cerebro

Los resultados mostraron que la utilización de las 21 características de cada uno de los electrodos EEG de la región occipital (O1 y O2) era adecuada, permitiendo alcanzar unos valores de precisión del 58%. Al utilizar la red de entrenamiento sin calibración de datos, entre los 5 algoritmos que se utilizaron están el RF y el MLP, cuyos valores de precisión fueron del 54% y el 52%, respectivamente. Por este motivo, fue necesario considerar la posibilidad de aumentar las señales de EEG con alta resolución temporal añadiendo blancos con amplitudes pequeñas y altas, los algoritmos que han registrado un menor tiempo de clasificación son MLP y XGBoost fueron MLP y XGBoost con tiempos de 1,8 y 7,12 milisegundos, respectivamente.

4.6.3 Etapas del procesamiento de señales EEG

El análisis de la distribución normal en las señales de EEG, y en el de frecuencia sin preprocesamiento, nos permite detectar la presencia de parámetros de ruido mediante estadísticas descriptivas. Esta detección nos permitió determinar la necesidad de filtrar las señales adquiridas. Además, tuvimos que utilizar la FFT de la señal de EEG sin preprocesamiento para apreciar los datos con fuerte actividad cerca de 0 Hz. Esto nos llevó a la conclusión de ser un efecto de artefactos de DC. Es interesante señalar que esto también era visible en el dominio del tiempo mediante la detección de tendencias de estos artefactos de DC de la corriente continua. Por lo tanto, la prueba de hipótesis es una herramienta valiosa que nos ayuda a detectar la presencia de ruido debido a los efectos temporales de los artefactos de DC de baja frecuencia como el promedio de la variación de la señal durante el experimento, así como su varianza.

En base a las características de tiempo y frecuencia extraídas, se detectaron dos clusters en cada una de las señales de EEG: Uno en el rango de frecuencia de 5 a 9 Hz (cluster 1) y otro en el rango de 24 a 29 Hz (cluster 2). Los resultados demuestran que se obtiene un

mejor cluster al medir los valores del índice de frecuencia máxima. Esto ocurre porque las señales de EEG occipital muestran el mismo comportamiento de frecuencia ante los estímulos visuales. Además, el uso de la correlación de Pearson, entre los electrodos de la zona occipital no mejora la agrupación porque los estímulos visuales están en ambos ojos, en todos los experimentos para todas las frecuencias.

Los resultados con estímulos visuales en las siguientes frecuencias 6,0, 7,0, 8,0 26,0, 27,0, 28,0 y 29,0 Hz fue de aproximadamente el 90%, porque la frecuencia de 5 Hz es muy baja para los experimentos de estimulación visual; y, las frecuencias de 24 y 9 Hz conforman la señal del grupo más cercano que se utilizó en el experimento.

4.6.4 Control de una mano robótica empleando características temporales

Este trabajo presenta el diseño y desarrollo de una plataforma de pruebas, basado en un antebrazo protésico impreso en 3D de bajo coste, accionado por señales de EEG y accionado por tres servomotores. Junto con el diseño personalizado y la buena apariencia antropomórfica de la prótesis, el principal hallazgo fue encontrar los datos de EEG adecuados y transferirlos de forma inalámbrica a los dispositivos de control electrónico que envían las señales de control a los servomotores, según la intención de movimiento del paciente. Nuestro diseño tuvo una apariencia anatómica que se ajustó al muñón del paciente y se dimensionó al contralateral utilizando una serie de imágenes como referencia en el software Blender. Además, este prototipo permitió probar los algoritmos de extracción de características de las señales EEG, y determinar las intenciones motoras de las extremidades superiores.

Por otro lado, la prótesis también permitió demostrar la fabricación, como el PLA, utilizando un material de bajo coste y materiales biodegradables en su fabricación. También, se ha evitado el uso de conexiones quirúrgicas e innumerables sensores en la piel. La solución propuesta es sencilla, la colocación correcta de la prótesis en el muñón, y un único sensor colocado en la frente [91,92]. Por lo tanto, se ha evitado el requisito de complicados algoritmos de la señal EEG para generar el movimiento de la prótesis. Un prototipo sencillo con un algoritmo de control basado en un rango de atención, que permite al paciente abrir o cerrar la mano en función del nivel de concentración. Además, la prótesis fabricada no requiere múltiples líneas de código para activar los servomotores para agarrar un objeto.

Este algoritmo permite una respuesta rápida y ágil para operar la mano. Por lo tanto, esta prótesis podría ser útil para las personas que necesitan una prótesis ligera, de bajo coste, y de funcionamiento binario para agarrar y soltar objetos de la vida cotidiana. Además, esta prótesis incorpora internamente todos los elementos que permiten el movimiento de los dedos, por lo que se diferencia de muchas prótesis 3D actuales [93,94]. No es necesaria una base externa con componentes electrónicos y componentes mecánicos; y, se optimiza el espacio en la parte superior del antebrazo para albergar los componentes electrónicos incluida la batería, proporcionando comodidad al amputado.

4.6.5 Detección de intensiones motoras en extremidades superiores basados en señales EMG

El análisis de la distribución de los datos permitió detectar la presencia de ruido en las señales de EMG; basándonos en parámetros estadísticos descriptivos como la media y la varianza. Esta detección nos permitió determinar la necesidad de preprocesamiento, porque el ruido de baja frecuencia varió la distribución media, la distribución del conjunto de datos y el ruido con frecuencia superior a 20Hz; rango en el que aumentaba la varianza en mayor medida. Además, el uso de la misma prueba de normalidad después del preprocesamiento con el filtro de paso banda, nos permitió evaluar la eficacia del filtro en el rango de frecuencia de 7Hz a 20Hz.

La utilización de la FFT en la señal EMG sin preprocesamiento nos permitió saber que hay una fuerte actividad a 50Hz y cerca de 0Hz, que es un efecto del armónico fundamental de la red eléctrica y de los artefactos DC respectivamente. Además, las señales EMG se analizaron sin procesamiento en el dominio del tiempo, para detectar las tendencias producidas por los artefactos DC. Sin embargo, con el uso de la prueba de normalidad, se pudo detectar la presencia de ruido sin necesidad de realizar la representación en el dominio del tiempo y la FFT.

Las hipótesis probadas nos ayudaron a detectar la presencia de ruido. Los artefactos de CC de baja frecuencia afectaron a las características temporales, como: la media y la varianza. Las señales sin preprocesamiento se analizaron en el dominio de la frecuencia; estas señales mostraron una mayor actividad cerca de 50Hz, que corresponde al artefacto de la red eléctrica. Este ruido afectó a las características en el dominio de la frecuencia de la señal.

De los algoritmos evaluados, podemos concluir que el algoritmo K-means fue capaz de detectar cada una de las nueve tareas realizadas con un porcentaje de éxito aceptable. Este algoritmo se basa en la Distancia Euclidiana al centroide del clúster; por lo tanto, tiene una mejor respuesta en la agrupación de las características auto-correlacionadas en el dominio del tiempo [95]. Los algoritmos basados en densidad DBSCAN y Clustering Jerárquico presentaron una baja tasa de éxito. Agrupan todas las letras en dos clusters porque las características basadas en la frecuencia no tienen suficiente información sobre las resoluciones temporales [96].

4.7 Publicaciones

Los algoritmos de aprendizaje no supervisado fueron utilizados en la detección de intenciones motoras de manos y pies, empleando señales EEG. Estos resultados fueron publicados en el artículo titulado “EEG signal clustering for motor and imaginary motor tasks on hands and feet”, que fue presentado en el 2017 en el Congreso “IEEE Second Ecuador Technical Chapters Meeting” (ETCM) [1].

Se desarrolló una metodología para el registro de señales EEG de la región occipital del cerebro. Con los datos registrados se evaluaron algoritmos de aprendizaje supervisado implementados en un sistema embebido. Los resultados fueron publicados en el artículo científico titulado: “SSVEP-EEG Signal Classification 162atlab162162 Emotiv EPOC BCI and Raspberry Pi”, el mismo que fue presentado el 2021 en el “International Federation of Automatic Control (IFAC) Symposium on Biological and Medical Systems (BMS)” en la universidad de Ghent en Bélgica [2].

Otro trabajo relacionado al procesamiento de señales cerebrales EEG, pero de la región occipital, basado en algoritmos de aprendizaje no supervisado dio como resultado la publicación titulada: “Clustering of EEG occipital signals using K-means” presentado el 2016 en el Congreso “IEEE Ecuador Technical Chapters Meeting” (ETCM) [3].

Además, los trabajos realizados en los datos adquiridos del dispositivo EEG se filtraron y ajustaron a las capacidades del paciente para encontrar un valor de umbral que se utilizó como parámetro de control. Los resultados fueron publicados en el artículo científico titulado: “A 3D-Printed EEG based Prosthetic Arm” presentado el 2021, en el “International Conference on E-health Networking, Application & Services” (HEALTHCOM) [4].

Finalmente, los métodos de preprocesamiento, caracterización y detección de tareas, fue replicado empleando esta vez señales EMG. Los resultados fueron publicados en el artículo “EMG Signal Processing with Clustering Algorithms for motor gesture Tasks”, presentado en el 2018 en el Congreso “IEEE Third Ecuador Technical Chapters Meeting” (ETCM) [5].

4.8 Bibliografía

- [1] Asanza, V., Pelaez, E., & Loayza, F. (2017, October). EEG signal clustering for motor and imaginary motor tasks on hands and feet. In Ecuador Technical Chapters Meeting (ETCM), 2017 IEEE (pp. 1-5). IEEE.
- [2] Asanza, V., Avilés-Mendoza, K., Trivino-Gonzalez, H., Rosales-Uribe, F., Torres-Brunes, J., Loayza, F. R., ... & Tinoco-Egas, R. (2021). SSVEP-EEG Signal Classification based on Emotiv EPOC BCI and Raspberry Pi. IFAC-PapersOnLine, 54(15), 388-393.
- [3] Asanza, V., Ochoa, K., Sacarelo, C., Salazar, C., Loayza, F., Vaca, C., & Peláez, E. (2016, October). Clustering of EEG occipital signals using k-means. In Ecuador Technical Chapters Meeting (ETCM), IEEE (pp. 1-5). IEEE.
- [4] Fuentes-Gonzalez, J., Infante-Alarcón, A., Asanza, V., & Loayza, F. R. (2021, March). A 3d-printed eeg based prosthetic arm. In 2020 IEEE International Conference on E-health Networking, Application & Services (HEALTHCOM) (pp. 1-5). IEEE.
- [5] Asanza, V., Peláez, E., Loayza, F., Mesa, I., Díaz, J., & Valarezo, E. (2018, October). EMG Signal Processing with Clustering Algorithms for motor gesture Tasks. In 2018 IEEE Third Ecuador Technical Chapters Meeting (ETCM) (pp. 1-6). IEEE.
- [6] Reaz, M. B., Hussain, M. S., & Mohd-Yasin, F. (2006). Techniques of EMG signal analysis: detection, processing, classification and applications. Biological procedures online, 8(1), 11-35.
- [7] Pfurtscheller, G., Neuper, C., Guger, C., Harkam, W. A. H. W., Ramoser, H., Schlogl, A., ... & Pregenzer, M. A. P. M. (2000). Current trends in Graz brain-computer interface (BCI) research. IEEE Transactions on Rehabilitation Engineering, 8(2), 216-219.
- [8] Mulroy, S., Gronley, J., Weiss, W., Newsam, C., and Perry, J. Use of cluster analysis for gait pattern classification of subjects in the early and late recovery phases following stroke. Gait & posture 18, 1(2003), 114-125.
- [9] G. Schalk and E. C. Leuthardt, “Brain-computer interfaces using electrocorticographic signals,” IEEE reviews in biomedical engineering, vol. 4, pp. 140–154, 2011.
- [10] Wolpaw, J. R. (2007). Brain-computer interfaces as new brain output pathways. The Journal of physiology, 579(3), 613-619.
- [11] Minguillon, J., Lopez-Gordo, M. A., & Pelayo, F. (2017). Trends in EEGBCI for daily-life: Requirements for artifact removal. Biomedical Signal Processing and Control, 31, 407-418.
- [12] Guger, C., Schlogl, A., Neuper, C., Walterspacher, D., Strein, T., & Pfurtscheller, G. (2001). Rapid prototyping of an EEG-based braincomputer interface (BCI). IEEE Transactions on Neural Systems and Rehabilitation Engineering, 9(1), 49-58.

- [13] Lee, J. J., Lee, D. R., Kyum Shin, Y., Lee, N. G., Han, B. S., & You, S. J. H. (2013). Comparative neuroimaging in children with cerebral palsy using fMRI and a novel EEG-based brain mapping during a motor task—a preliminary investigation. *NeuroRehabilitation*, 32(2), 279-285.
- [14] Shin, Y. K., Lee, D. R., Hwang, H. J., You, S. J. H., & Im, C. H. (2012). A novel EEG-based brain mapping to determine cortical activation patterns in normal children and children with cerebral palsy during motor imagery tasks. *NeuroRehabilitation*, 31(4), 349-355.
- [15] Müller-Putz, G. R., Scherer, R., Pfurtscheller, G., & Rupp, R. (2005). EEG-based neuroprosthesis control: a step towards clinical practice. *Neuroscience letters*, 382(1), 169-174.
- [16] Gao, L., Wang, J., & Chen, L. (2013). Event-related desynchronization and synchronization quantification in motor-related EEG by Kolmogorov entropy. *Journal of neural engineering*, 10(3), 036023.
- [17] Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering* 51(6):1034-1043, 2004. [In 2008, this paper received the Best Paper Award from IEEE TBME.]
- [18] Bascil, M. S., Tesneli, A. Y., & Temurtas, F. (2016). Spectral feature extraction of EEG signals and pattern recognition during mental tasks of 2-D cursor movements for BCI using SVM and ANN. *Australasian physical & engineering sciences in medicine*, 39(3), 665-676.
- [19] Bascil, M. S., Tesneli, A. Y., & Temurtas, F. (2015). Multi-channel EEG signal feature extraction and pattern recognition on horizontal mental imagination task of 1-D cursor movement for brain computer interface. *Australasian Physical & Engineering Sciences in Medicine*, 38(2), 229-239.
- [20] Rambabu, C., & Murthy, B. R. (2014). EEG signal with feature extraction using SVM and ICA classifiers. *International Journal of Computer Applications*, 85(3).
- [21] Chai, R., Naik, G., Nguyen, T. N., Ling, S., Tran, Y., Craig, A., & Nguyen, H. (2016). Driver fatigue classification with independent component by entropy rate bound minimization analysis in an EEG-based system. *IEEE journal of biomedical and health informatics*.
- [22] Hazrati, M. K., & Erfanian, A. (2010). An online EEG-based brain-computer interface for controlling hand grasp using an adaptive probabilistic neural network. *Medical engineering & physics*, 32(7), 730-739.
- [23] Gunn, S. R. (1998). Support vector machines for classification and regression. *ISIS technical report*, 14, 85-86.
- [24] Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9(3), 293-300.
- [25] Singla, R., & Haseena, B. A. (2014). Comparison of ssvp signal classification techniques using svm and ann models for bci applications. *International Journal of Information and Electronics Engineering*, 4(1), 6.
- [26] Özgen, C. (2011). Classification of motor imagery tasks in EEG signal and its application to a brain-computer interface for controlling assistive environmental devices (Doctoral dissertation, Middle East Technical University).
- [27] Stoica, P., & Moses, R. L. (2005). *Spectral Analysis of Signals*: Prentice Hall. Upper Saddle River, NJ.
- [28] Hartigan, J. A., and Wong, M. A. Algorithm as 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)* 28, 1 (1979), 100-108.

- [29] Alcivar-Molina, E., Hurel, J., Ter´an, E., Zamora-Olea, G., Ponguillo, R., and Loayza, F.R. (2018). Six-axis lower-limb exoskeleton control system based on neural networks. In 2018 IEEE Third Ecuador Technical Chapters Meeting (ETCM), 1–5. IEEE.
- [30] Han, X., Lin, K., Gao, S., and Gao, X. (2018). A novel system of SSVEP-based human–robot coordination. *Journal of neural engineering*, 16(1), 016006.
- [31] Chen, X., Zhao, B., Wang, Y., and Gao, X. (2019). Combination of high-frequency SSVEP-based BCI and computer vision for controlling a robotic arm. *Journal of neural engineering*, 16(2), 026012.
- [32] Erkan, E. and Akbaba, M. (2018). A study on performance increasing in SSVEP based BCI application. *Engineering Science and Technology, an International Journal*, 21(3), 421–427.
- [33] Huang, D., Qian, K., Fei, D.Y., Jia, W., Chen, X., and Bai, O. (2012). Electroencephalography (EEG)-based brain–computer interface (BCI): A 2-d virtual wheelchair control based on event-related desynchronization/synchronization and state control. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20(3), 379–388.
- [34] Chouhan, T., Robinson, N., Vinod, A., Ang, K.K., and Guan, C. (2018). Wavlet phase-locking based binary classification of hand movement directions from EEG. *Journal of neural engineering*, 15(6), 066008.
- [35] Ghaemi, A., Rashedi, E., Pourrahimi, A.M., Kamandar, M., and Rahdari, F. (2017). Automatic channel selection in EEG signals for classification of left or right hand movement in brain computer interfaces using improved binary gravitation search algorithm. *Biomedical Signal Processing and Control*, 33, 109–118.
- [36] Fuentes-Gonzalez, J., Infante-Alarc´on, A., Asanza, V., and Loayza, F.R. (2021). A 3d-printed eeg based prosthetic arm. In 2020 IEEE International Conference on Ehealth Networking, Application & Services (HEALTHCOM), 1–5. IEEE.
- [37] Asanza, V., Pelaez, E., and Loayza, F. (2017). Supervised pattern recognition techniques for detecting motor intention of lower limbs in subjects with cerebral palsy. In 2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM), 1–5. IEEE.
- [38] Artoni, F., Delorme, A., and Makeig, S. (2018). Applying dimension reduction to EEG data by principal component analysis reduces the quality of its subsequent independent component decomposition. *NeuroImage*, 175, 176–187.
- [39] V. Asanza, A. Constantine, S. Valarezo and E. Pel´aez, "Implementation of a Classification System of EEG Signals Based on FPGA," 2020 Seventh International Conference on eDemocracy & eGovernment (ICEDEG), 2020, pp. 87-92, doi: 10.1109/ICEDEG48599.2020.9096752.
- [40] Al-Saegh, A., Dawwd, S.A., and Abdul-Jabbar, J.M. (2021). Deep learning for motor imagery EEG-based classification: A review. *Biomedical Signal Processing and Control*, 63, 102172.
- [41] Fischer, N.L., Peres, R., and Fiorani, M. (2018). Frontal alpha asymmetry and theta oscillations associated with information sharing intention. *Frontiers in behavioral neuroscience*, 12, 166.
- [42] Shao, L., Zhang, L., Belkacem, A.N., Zhang, Y., Chen, X., Li, J., and Liu, H. (2020). EEG-controlled wall-crawling cleaning robot using ssvp-based brain-computer interface. *Journal of healthcare engineering*, 2020.
- [43] Khosla, A., Khandnor, P., and Chand, T. (2020). A comparative analysis of signal processing and classification methods for different applications based on EEG signals. *Biocybernetics and Biomedical Engineering*, 40(2), 649–690.

- [44] Zhang, D., Huang, B., Wu, W., and Li, S. (2015). An idle-state detection algorithm for SSVEP-based brain-computer interfaces using a maximum evoked response spatial filter. *International journal of neural systems*, 25(07), 1550030.
- [45] Chen, X., Zhao, B., Wang, Y., Xu, S., and Gao, X. (2018). Control of a 7-DOF robotic arm system with an SSVEP based BCI. *International journal of neural systems*, 28(08), 1850018.
- [46] Waytowich, N., Lawhern, V.J., Garcia, J.O., Cummings, J., Faller, J., Sajda, P., and Vettel, J.M. (2018). Compact convolutional neural networks for classification of asynchronous steady-state visual evoked potentials. *Journal of neural engineering*, 15(6), 066031.
- [47] Chen, X., Wang, Y., Gao, S., Jung, T.P., and Gao, X. (2015). Filter bank canonical correlation analysis for implementing a high-speed SSVEP-based brain-computer interface. *Journal of neural engineering*, 12(4), 046008.
- [48] Tinoco-Egas, R., Aviles, K., Torres-Brunes, J., Trivino-Gonzalez, H., Asanza, V., Rosales-Uribe, F., Loayza, F.R., and Pel'aez, E. (2021). SSVEP-EEG data collection using emotiv EPOC. doi:10.21227/0j42-qd38. URL <https://dx.doi.org/10.21227/0j42-qd38>.
- [49] Yindong, D., Fuji, R., and Chunbin, L. (2021). Eeg emotion recognition based on linear kernel pca and xgboost. *Opto-Electronic Engineering*, 48(2), 200013–1.
- [50] J. R. Garcell, "Aportes del electroencefalograma convencional y el análisis de frecuencias para el estudio del trastorno por déficit de atención. Primera parte," *Salud Mental*, vol. 27, no. 1, p. 23, 2004.
- [51] L. A. Riggs and P. Whittle, "Human occipital and retinal potentials evoked by subjectively faded visual stimuli," *Vision Research*, vol. 7, no. 5-6, pp. 441–451, 1967.
- [52] G. Schalk and E. C. Leuthardt, "Brain-computer interfaces using electrocorticographic signals," *IEEE reviews in biomedical engineering*, vol. 4, pp. 140–154, 2011.
- [53] I. Iturrate, C. Escolano, J. Antelis, and J. Minguez, "Dispositivos robóticos de rehabilitación basados en interfaces cerebro-ordenador: silla de ruedas y robot para teleoperación," in *III International 166atlab166166son Domotics, Robotics and Remote-Assistance for All*, Barcelona, Spain, 2009, pp. 124–134.
- [54] G. R. Bermúdez, P. J. G. Laencina, D. Brizion, and J. R. Dorda, "Adquisición, procesamiento y clasificación de señales eeg para el diseño de sistemas bci basados en imaginación de movimiento," *Jornadas de introducción a la investigación de la UPCT*, no. 6, pp. 10–12, 2013.
- [55] J. V. Pinzón, R. P. Mayorga, and G. C. Hurtado, "Brazo robótico controlado por electromiografía," *Scientia Et Technica*, vol. 1, no. 52, pp. 165–173, 2012.
- [56] K. Jerbi, J. Vidal, J. Mattout, E. Maby, F. Lecaigard, T. Ossandon, C. Hamam'ee, S. Dalal, R. Bouet, J.-P. Lachaux et al., "Inferring hand movement kinematics from meg, eeg and intracranial eeg: From brainmachine interfaces to motor rehabilitation," *IRBM*, vol. 32, no. 1, pp. 8–18, 2011.
- [57] N. A. Badcock, P. Mousikou, Y. Mahajan, P. de Lissa, J. Thie, and G. McArthur, "Validation of the 166atlab166 eeg gaming system for measuring research quality auditory erps," *PeerJ*, vol. 1, p. e38, 2013.
- [58] I. Mesa, A. Rubio, I. Tubia, J. De No, and J. Diaz, "Channel and feature selection for a surface electromyographic pattern recognition task," *Expert Systems with Applications*, vol. 41, no. 11, pp. 5190–5200, 2014.
- [59] R. Kabacoff, *R in action: data analysis and graphics with R*. Manning Publications Co., 2015.
- [60] R. Kabacoff, *R in action: data analysis and graphics with R*. Manning Publications Co., 2015.

- [61] J. A. Hartigan and M. A. Wong, "Algorithm as 136: A k-means clustering algorithm," *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, vol. 28, no. 1, pp. 100–108, 1979.
- [62] Zuniga J, Katsavelis D, Peck J, Stollberg J, Petrykowski M, Carson A, et al. Cyborg beast: a low-cost 3d-printed prosthetic hand for children with upper-limb differences. *BMC Res Notes*. 2015;8: 10.
- [63] Burn MB, Ta A, Gogola GR. Three-Dimensional Printing of Prosthetic Hands for Children. *J Hand Surg Am*. 2016;41: e103–9.
- [64] Putzi R. Myoelectric Partial-Hand Prosthesis [Internet]. *JPO Journal of Prosthetics and Orthotics*. 1992. p. 103–108. doi:10.1097/00008526-199212000-00005.
- [65] Gretsch KF, Lather HD, Peddada KV, Deeken CR, Wall LB, Goldfarb CA. Development of novel 3D-printed robotic prosthetic for transradial amputees. *Prosthet Orthot Int*. 2016;40: 400–403.
- [66] Li C, Ren J, Huang H, Wang B, Zhu Y, Hu H. PCA and deep learning based myoelectric grasping control of a prosthetic hand. *Biomed Eng Online*. 2018;17: 107.
- [67] Muzumdar A. *Powered Upper Limb Prosthesis: Control, Implementation and Clinical Application*; 11 Tables. Springer Science Business Media; 2004.
- [68] Ten Kate J, Smit G, Breedveld P. 3D-printed upper limb prosthesis: a review. *Disabil Rehabil Assist Technol*. 2017;12: 300–314.
- [69] Controzzi M, Clemente F, Barone D, Ghionzoli A, Cipriani C. The SSSA-MyHand: A Dexterous Lightweight Myoelectric Hand Prosthesis. *IEEE Trans Neural Syst Rehabil Eng*. 2017;25: 459–468.
- [70] Geethanjali P. Myoelectric control of prosthetic hands: state-of-the-art review. *Med Devices*. 2016;9: 247–255.
- [71] Pasquina PF, Evangelista M, Carvalho AJ, Lockhart J, Griffin S, Nanos G, et al. First-in-man demonstration of a fully implanted myoelectric sensors system to control an advanced electromechanical prosthetic hand. *J Neurosci Methods*. 2015;244: 85–93.
- [72] Schiefer M, Tan D, Sidek SM, Tyler DJ. Sensory feedback by peripheral nerve stimulation improves task performance in individuals with upper limb loss using a myoelectric prosthesis. *J Neural Eng*. 2016;13: 016001.
- [73] Calderon-Cordova C, Ramirez C, Barros V, Quezada-Sarmiento PA, Barba-Guaman L. EMG signal patterns recognition based on feedforward Artificial Neural Network applied to robotic prosthesis myoelectric control [Internet]. 2016 Future Technologies Conference (FTC). 2016. doi:10.1109/ftc.2016.7821705.
- [74] Koprnický J, Najman P, Safka J. 3D printed bionic prosthetic hands [Internet]. 2017 IEEE International Workshop of Electronics, Control, Measurement, Signals and their Application to Mechatronics (ECMSM). 2017. doi:10.1109/ecmsm.2017.7945898.
- [75] Kasim MAA, Low CY, Ayub MA, Zakaria NAC, Salleh MHM, Johar K, et al. User-Friendly LabVIEW GUI for Prosthetic Hand Control Using Emotiv EEG Headset [Internet]. *Procedia Computer Science*. 2017. pp. 276–281. doi:10.1016/j.procs.2017.01.222.
- [76] Beyrouthy T, Al Kork S, Korbane JA, Abouelela M. EEG Mind Controlled Smart Prosthetic Arm – A Comprehensive Study [Internet]. *Advances in Science, Technology and Engineering Systems Journal*. 2017. pp. 891–899. doi:10.25046/aj0203111.
- [77] Chinbat O, Lin J-S. Prosthetic Arm Control by Human Brain [Internet]. 2018 International Symposium on Computer, Consumer and Control (IS3C). 2018. doi:10.1109/is3c.2018.00022.

- [78] Bright D, Nair A, Salvekar D, Bhisikar S. EEG-based brain controlled prosthetic arm [Internet]. 2016 Conference on Advances in Signal Processing (CASP). 2016. doi:10.1109/casp.2016.7746219.
- [79] Beyrouthy T, Al Kork SK, Korbane JA, Abdulmonem A. EEG Mind controlled Smart Prosthetic Arm [Internet]. 2016 IEEE International Conference on Emerging Technologies and Innovative Business Practices for the Transformation of Societies (EmergiTech). 2016. doi:10.1109/emergitech.2016.7737375.
- [80] Elstob D, Secco EL. A Low Cost Eeg Based Bci Prosthetic Using Motor Imagery [Internet]. International Journal of Information Technology Convergence and Services. 2016. pp. 23–36. doi:10.5121/ijitcs.2016.6103.
- [81] Mutlu R, Alici G, Panhuis M in H, Spinks GM. 3D Printed Flexure Hinges for Soft Monolithic Prosthetic Fingers [Internet]. Soft Robotics. 2016. pp. 120–133. doi:10.1089/soro.2016.0026.
- [82] Pantoja, W. C. Neuroprotesis: Hacia un futuro de cuerpos cibernéticos. *Ingeniería Industrial*, 26 (2008),251-266.
- [83] Forero, A., Gonzalez, B., Reyes, C., Arango, D., and Avila, E. Diseño y construcción de un electro-miógrafo con su interfaz de visualización en 168atlab.
- [84] Mesa, I., Rubio, A., Tubia, I., De No, J., and Diaz, J. Channel and feature selection for a surface electromyographic pattern recognition task. *Expert Systems with Applications* 41, 11 (2014), 5190-5200.
- [85] Pinzon, J. V., Mayorga, R. P., and Hurtado, G. C. Brazo robótico controlado por electromiografía. *Scientia Et Technica* 1, 52 (2012), 165-173.
- [86] Jerbi, K., Vidal, J., Mattout, J., Maby, E., Lecaigard, F., Ossandon, T., Hamamé, C., Dalal, S., Bouet, R., Lachaux, J.-P., et al. Inferring hand movement kinematics from meg, eeg and intracranial eeg: From brain-machine interfaces to motor rehabilitation. *IRBM* 32, 1 (2011), 8-18.
- [87] Kabacoff, R. *R in action: data analysis and graphics with R*. Manning Publications Co., 2015.
- [88] Hartigan, J. A., and Wong, M. A. Algorithm as 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)* 28, 1 (1979), 100-108.
- [89] Bhargav, S., and Pawar, M. A review of clustering methods forming non-convex clusters with, missing and noisy data.
- [90] Mulroy, S., Gronley, J., Weiss, W., Newsam, C., and Perry, J. Use of cluster analysis for gait pattern classification of patients in the early and late recovery phases following stroke. *Gait & posture* 18, 1(2003), 114-125.
- [91] Lange G, Low CY, Johar K, Hanapiah FA, Kamaruzaman F. Classification of Electroencephalogram Data from Hand Grasp and Release Movements for BCI Controlled Prosthesis [Internet]. *Procedia Technology*. 2016. pp. 374–381. doi:10.1016/j.protcy.2016.08.048.
- [92] Slade P, Akhtar A, Nguyen M, Bretl T. Tact: Design and performance of an open-source, affordable, myoelectric prosthetic hand [Internet]. 2015 IEEE International Conference on Robotics and Automation (ICRA). 2015. doi:10.1109/icra.2015.7140105.
- [93] Russo RE, Fernández JG, Rivera RR. Algorithm of Myoelectric Signals Processing for the Control of Prosthetic Robotic Hands [Internet]. *Journal of Computer Science and Technology*. 2018. p. e04. doi:10.24215/16666038.18.e04.

- [94] Canizares A, Pazos J, Benitez D. On the use of 3D printing technology towards the development of a low-cost robotic prosthetic arm [Internet]. 2017 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC). 2017. doi:10.1109/ropec.2017.8261579.
- [95] Hartigan, J. A., and Wong, M. A. Algorithm as 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)* 28, 1 (1979), 100-108.
- [96] Liu, Y. H., Lin, L. F., Chou, C. W., Chang, Y., Hsiao, Y. T., & Hsu, W. C. (2018). Analysis of Electroencephalography Event-Related Desynchronisation and Synchronisation Induced by Lower-Limb Stepping Motor Imagery. *Journal of Medical and Biological Engineering*, 1-16.

5 Capítulo 5 RQ3: ¿Qué algoritmo de aprendizaje automático será eficaz para el análisis EEG-BCI en la detección de las intenciones motoras de las extremidades inferiores?

En este capítulo se presenta una comparación entre los algoritmos de aprendizaje supervisado y no supervisados utilizados. Este trabajo implica no sólo la clasificación de tareas motoras de las extremidades inferiores sino también de las superiores. Una de las implementaciones presentadas en este capítulo, es capaz de operar en tiempo real para el control de una prótesis de mano empleando tecnología FPGA.

En la sección 5.1 se presenta los algoritmos de clasificación de una tarea motora imaginaria y una tarea motora en extremidades inferiores, empleando señales EEG. El algoritmo de aprendizaje supervisado utilizado fue una red NN feed-forward y fue implementado en una FPGA.

En la sección 5.2 se presenta una versión que combina lo realizado en la sección 5.1 con algoritmos de aprendizaje no supervisado. Los algoritmos de clustering fueron utilizados para seleccionar los electrodos EEG que presentaban actividad en el dominio del tiempo mientras se realizaban las tareas imagenético motoras. Por otro lado, los algoritmos de aprendizaje supervisado fueron utilizados para detectar si las señales EEG representaban una actividad imagenético motora de ambas manos o ambos pies.

Por otro lado, los algoritmos de aprendizaje supervisado también fueron utilizados en la detección de tareas motoras empelando, esta vez señales EMG. En la sección 5.3 se describe el uso del algoritmo K-NN en la detección de 9 gestos realizados con mano, empelando datos medidos empelando 8 electrodos EMG superficiales.

En la sección 5.4 se presente una aplicación del uso de los algoritmos de aprendizaje supervisado en la detección de sujetos que padecen Parkinson. Los resultados demuestran que el monitoreo de los tiempos de teclear con el dedo puede ser utilizados en la detección de sujetos con Parkinson con un 98.08% de acierto.

En la sección 5.5 se da respuesta a la pregunta de investigación que se analiza en este capítulo. Además, se discuten los resultados obtenidos como respuesta a esta pregunta de investigación.

Finalmente, en la sección 5.6 se presentan los trabajos ya publicados que reportan los hallazgos de ésta pregunta de investigación: a) “Implementation of a Classification System of EEG Signals Based on FPGA” [1]; b) “BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control” [2]; c) “K-NN-Based EMG Recognition for Gestures Communication with Limited Hardware Resources” [3]; y d) “Classification of Subjects with Parkinson’s Disease using Finger Tapping Dataset” [4].

5.1 Clasificación de una tarea motora imaginaria y una tarea motora en extremidades inferiores

En esta sección presentamos un primer enfoque que utiliza algoritmos de aprendizaje supervisado en la clasificación de tareas motoras de las extremidades inferiores. En el campo de las prótesis, en los últimos años se han incorporado diferentes tecnologías para mejorar su desarrollo y control, y el uso de los Arreglos de Compuertas Programables en Campo (FPGA) [5]; y en la Biomedicina ha aumentado debido a su flexibilidad para realizar múltiples tareas en un tiempo reducido [6]. En esta sección se presenta la implementación de un sistema basado en FPGA capaz de clasificar datos caracterizados, a través de la representación de una tarea motora imaginaria en extremidades inferiores.

Además, se diseñó e implementó una red neuronal feed-forward de tres capas en Matlab, lo que permitió probar diferentes arquitecturas para evaluar el rendimiento del clasificador; para dicha evaluación se definió algunas métricas, tales como la Matriz de Confusión y la curva ROC.

5.1.1 Introducción

Los FPGA son dispositivos electrónicos contruidos como una matriz de Elementos Lógicos (LE) configurables. Cada LE puede configurarse para realizar funciones combinatoriales o secuenciales. Como se muestra en la figura 5.1.1.1, las tarjetas FPGA modernas integran otras características útiles, como multiplicadores incorporados, Entradas/Salidas (I/O) de alta velocidad, convertidores de datos que incluyen Convertidores Analógico-Digitales (ADC), grandes matrices de Memorias de Acceso Aleatorio (RAM) y procesadores. Todas estas características permiten crear hardware complejo en un Sistema en Chip (SoC), lo que da la opción de crear Unidades Centrales

de Procesamiento (CPU) personalizadas para fines específicos, con el fin de realizar múltiples instrucciones [6].

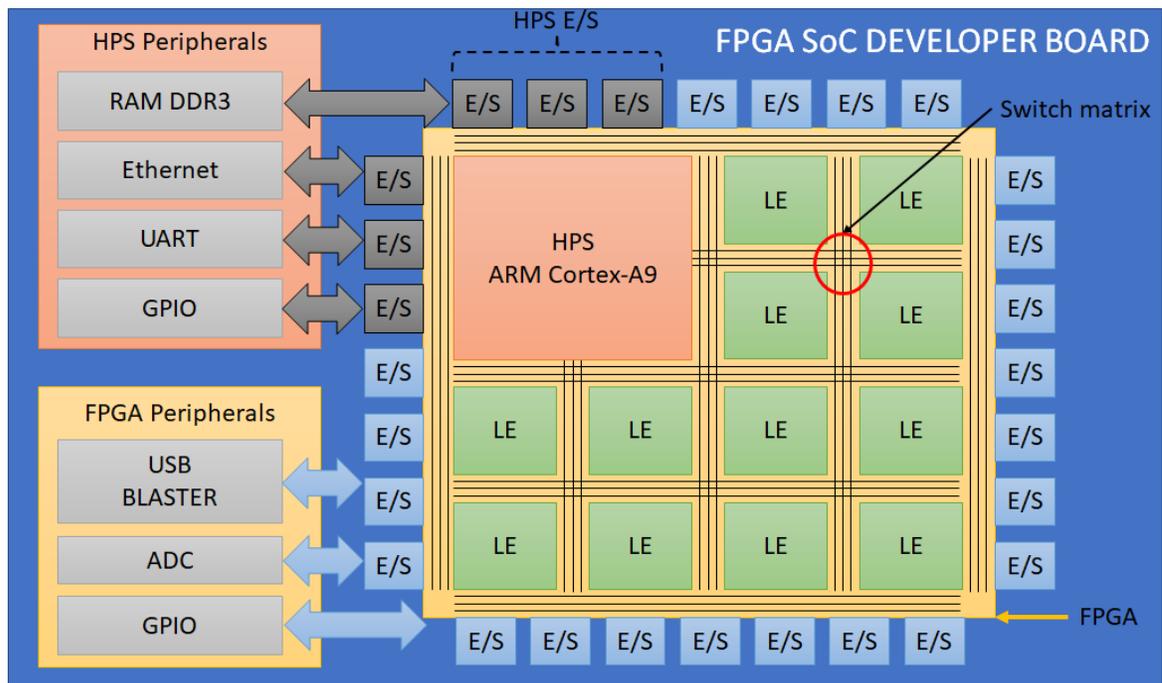


Figura 5.1.1.1 Gráfico de los componentes que integran las tarjetas de desarrollo genéricas basadas en FPGA SoC. [autoría propia]

Como se muestra en la figura 5.1.1.1, las Placas de Circuito Impreso (PCB) o tarjetas de desarrollo existentes, como la DE10 Standard, incorporan chips SoC y Sistema de Procesamiento Duro (HPS), por lo que pueden crear e implementar dos sistemas embebidos en tiempo real, cada uno de los cuales puede trabajar de forma independiente o conjunta con su propio CPU. Una de las ventajas de la comunicación entre estos dos sistemas es que no sólo pueden compartir recursos físicos, sino que también pueden verificar los tiempos de respuesta y la ejecución de las aplicaciones [6].

En la actualidad, el uso de FPGA ha aumentado porque es sencillo y barato comprado con las implementaciones de CPU / GPU. Se puede reprogramar en cualquier momento para realizar una tarea diferente a la que se estaba ejecutando inicialmente. Además, esto permite modificar el mismo algoritmo para hacerlo más robusto y complejo, con el fin de obtener mejores resultados [7].

La tendencia actual sobre el uso de SoC basados en FPGA es programar un microcontrolador sencillo y potente utilizando el lenguaje C/C++, debido a su flexibilidad y

con la opción de aumentar la capacidad del microcontrolador según la aplicación [6]. Las FPGAs reducen el tiempo de comercialización de los productos y facilitan el proceso de depuración o la adición de características durante la fase de diseño [8]. Los algoritmos en lenguaje C/C++ se han establecido en todos los sectores de la tecnología donde se utilizan los sistemas embebidos, y la tendencia es el uso de algoritmos de aprendizaje automático para aplicaciones como visión embebida, reconocimiento de voz, robótica industrial, Internet de las Cosas (IoT), Big Data y Redes Neuronales (NN), que han contribuido a fortalecer la Inteligencia Artificial (IA) y el procesamiento de señales biomédicas [8].

Los datos biomédicos como la Electroencefalografía (EEG), una técnica electrofisiológica para registrar la actividad eléctrica que surge del cerebro humano [3], pueden ser utilizados, junto con las Interfaces Cerebro Computadora (BCI), para controlar dispositivos de rehabilitación electrónicos, robóticos o protésicos [9]. Esta metodología de procesamiento consiste en el pre-procesamiento de los datos, la extracción de características y la clasificación de los patrones de EEG para su uso en BCI. La actividad cortical motora medida con los sistemas EEG-BCI se encuentra en la banda de frecuencia Mu (μ) de 8-13 Hz y en la banda de frecuencia Beta (β) de 13-30 Hz [10]. Es habitual utilizar la Densidad Espectral de Potencia (PSD) para medir las características para determinar la intención de las actividades motoras en los rangos de frecuencia μ y β [11]. Yong Zhang et al. utilizaron Wavelet Coeficientes, como características para clasificar las tareas mentales, contribuyendo a la precisión de la resolución temporal de estas características en el algoritmo [12].

La implementación de hardware utilizando FPGA para el procesamiento en tiempo real podría ayudar en el desarrollo de dispositivos BCI, especialmente para aquellos que requieren el análisis de grandes cantidades de datos.

5.1.2 Trabajos relacionados

Un sistema FPGA es un dispositivo que permite modelar un circuito digital utilizando un lenguaje específico, siendo el más común Lenguaje de Descripción de Hardware Verilog (VHDL), que es luego cargado en una matriz y creado físicamente en un chip con puertas y funciones y otras partes; tales como, la memoria y los puertos de entrada-salida. La tarjeta, conocida como FPGA puede hacer fácilmente multitareas, transmitir y recibir

paquetes en redes de alta velocidad, por lo que la comunicación de datos es muy eficiente, que puede utilizarse como núcleo de una gran variedad de proyectos [7-9].

Las NN son una arquitectura de algoritmos que contiene un grupo de parámetros que se procesan constantemente con el aprendizaje autónomo como objetivo. Esto se representa mediante un sistema de control con retroalimentación, donde la salida se calcula a partir de los datos de entrada como referencia en cada etapa. Las NN se han utilizado para aprender el conjunto de parámetros que definen la función que representa los datos de entrenamiento [10,11].

Las Redes Neuronales Profundas (DNN), como las Redes Neuronales Convolucionales (CNN), son NN centradas en problemas de clasificación de objetos y tienen múltiples capas conectadas que pueden lograr tasas de error más bajas [12]. Algunas arquitecturas CNN son factibles para implementaciones embebidas debido a su reducida demanda de recursos de procesamiento y almacenamiento, como el modelo SqueezeNet, que requiere 480 KB de almacenamiento para sus 1,2 millones de parámetros [13]. Son compatibles con los sistemas en la nube y su belleza se basa en su pequeño tamaño, que permite entrenarlos más rápidamente y tener un uso más eficiente de la energía [13].

En el aprendizaje autónomo, el conocimiento de un experto se considera necesario para ajustar las etapas de preprocesamiento y elegir los hiperparámetros, así como las funciones de activación. La clasificación de señales mediante NNs se realiza en 4 etapas: Preprocesamiento de las señales, extracción de características, selección de características y clasificación [14].

Antes de clasificar las señales, los datos necesitan una etapa de preprocesamiento, que en el caso de las señales EEG, comúnmente está basada en filtros paso-banda [14,15], y filtros espaciales utilizados para eliminar las señales promediadas en todos los canales, típicamente con un filtro de Referencia Media Común (CAR) [16-18]; luego, en la etapa de extracción de características, la NN busca las características que nos permitan obtener información en diferentes dominios que, dependiendo de la aplicación, nos permitan tener una mejor representación de las señales, tales como: morfológico [19], espectral [20], tiempo frecuencia [18,21,22], temporal [14,20], representación [23,24] y entropía [25]. Algunos de los algoritmos de aprendizaje automático utilizados para detectar intenciones motrices son Máquinas de Vectores de Soporte (SVM) [20], Redes Neuronales (NN)

[26,27], Análisis Discriminante Lineal (LDA) [14,26] y algoritmos de clustering [28]. En esta investigación hemos utilizado NN para la detección de actividades motoras.

5.1.3 Base de datos

El conjunto de datos utilizado se obtuvo de PhysioNet, que comparten los desarrolladores del sistema de instrumentación BCI2000 [27]. En nuestros experimentos, se utilizó el conjunto de datos de señales EEG, adquiridas de sujetos sanos, disponible en el sitio web: <http://www.physionet.org/physiobank/database/eegmmidb/> [27].

El conjunto de datos contiene señales de actividad cerebral cortical, registradas a partir de 8 sujetos, utilizando 64 electrodos superficiales distribuidos uniformemente siguiendo el sistema estándar internacional 10/10 (excluyendo los electrodos Nz, F9, F10, FT9, FT10, A1, A2, TP9, TP10, P9 y P10) como se muestra en la figura 5.1.3.1, con señales muestreadas a 160Hz para cada sujeto; es decir, se registraron 14 archivos en un Formato Europeo de Datos (EDF) [27], que corresponden a lo siguiente:

- Tarea 0: Posición de reposo con los ojos abiertos y cerrados, ambas con una duración de un minuto.
- Tarea 1: Abrir y cerrar la mano izquierda o derecha.
- Tarea 2: Imaginar la apertura y el cierre de mano izquierda o derecha.
- Tarea 3: Abrir y cerrar ambas manos, o la flexión dorsal y plantar de ambos pies.
- Tarea 4: Imaginar la apertura y el cierre de ambas manos o imaginar la flexión dorsal y plantar de ambos pies.

Las cuatro últimas tareas se repitieron tres veces para cada tema con una duración de dos minutos cada una. La tarea 0 representa la línea de base y se repitió dos veces: con los ojos abiertos y cerrados.

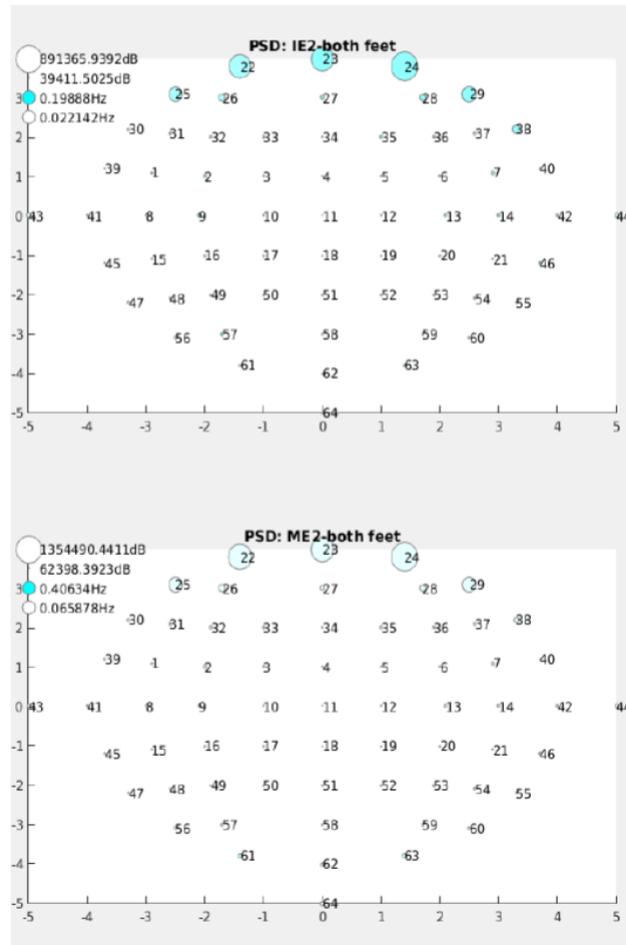


Figura 5.1.3.1 Distribución y análisis espectral de 64 electrodos de superficie vistos en el sistema internacional 10/10. [autoría propia]

Para este trabajo se utilizó la Tarea 3 y la Tarea 4 porque contenían datos que ayudaban a detectar la diferencia entre la actividad cerebral de las extremidades inferiores durante la ejecución de la tarea motora, así como a imaginar la actividad motora [27].

Durante la ejecución de la Tarea 3 y la Tarea 4, los sujetos fueron instruidos para realizar aleatoriamente 30 eventos de 4,1 segundos cada uno, como sigue: La Tarea 3 se componía de 7 repeticiones de la actividad motora de ambos pies (ME2), con un total de 4.599 muestras, como se muestra en la figura 5.1.3.2. Para cumplir con la Tarea 4, los sujetos fueron instruidos para realizar 9 repeticiones de la actividad motora imaginaria de ambos pies (IE2) con un total de 6.008 muestras. Cada evento se realizó después de una posición de reposo, etiquetada como evento E0 [27]. En total, cada tarea contenía 30 eventos pseudoaleatorios.

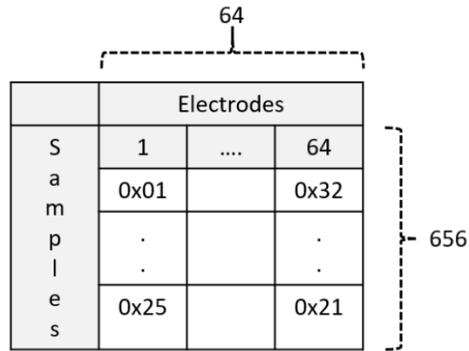


Figura 5.1.3.2 El archivo de actividad motora de ambos pies (ME2) contiene 4.599 filas o muestras x 64 columnas o electrodos EEG de superficie. [autoría propia]

5.1.4 Metodología

En esta sección se describe el análisis espectral de los datos que permitieron determinar su preprocesamiento. El preprocesamiento consiste en aplicar un filtrado paso banda en el rango de frecuencias de 8 a 30 Hz. También, se muestra la extracción de características basados en PSD que se utilizan en la NN implementada en una FPGA.

Para el análisis de datos se utilizó Matlab 2015, seleccionando los archivos correspondientes a la Tarea 3 y a la Tarea 4, y para cada uno de los 8 sujetos se almacenaron los datos de los eventos ME2 e IE2 de forma pseudo-aleatoria en 16 archivos Matlab, generando un total de 128 archivos Matlab con mediciones de EEG. La figura 5.1.4.1 muestra la señal de EEG en el dominio del tiempo sin preprocesamiento.

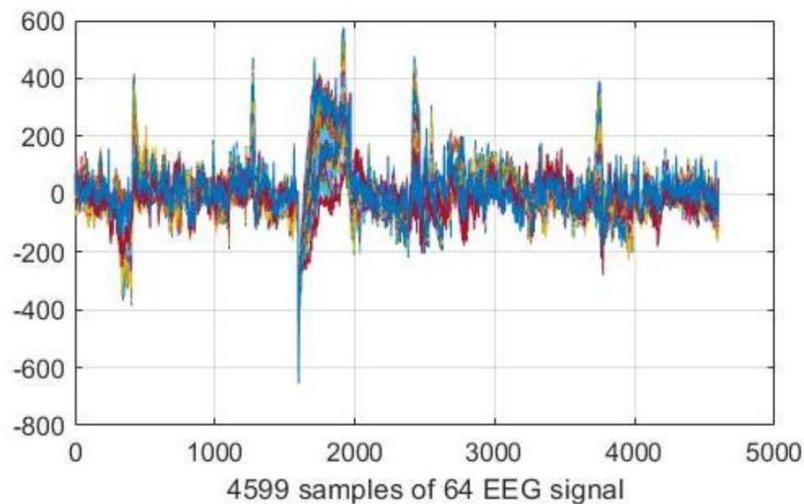


Figura 5.1.4.1 Representación en el dominio del tiempo de 4.599 muestras de la señal EEG de la actividad motora de ambos pies (ME2). [autoría propia]

La figura 5.1.4.2 muestra el espectro de las 64 señales de EEG donde hay una alta densidad espectral de potencia cerca de cero Hz, lo que indica que hay ruido o artefactos de baja frecuencia, por lo que se debe utilizar posteriormente un Filtro Pasa Banda que permita atenuar el ruido y permitir el paso de señales en el rango de frecuencias que nos interesa analizar, mejorando así la relación señal/ruido.

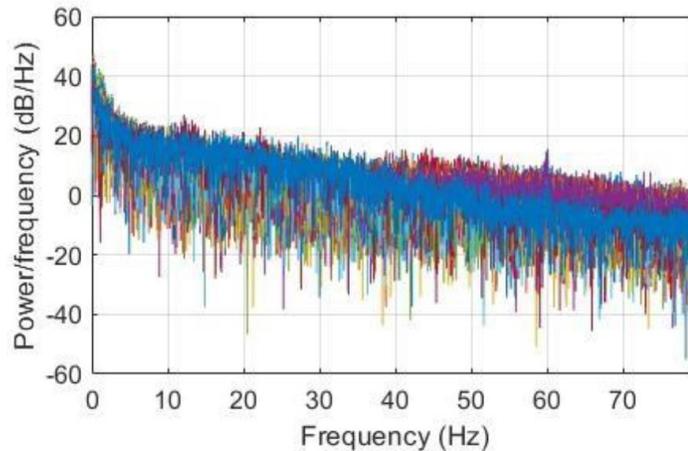


Figura 5.1.4.2 Estimación de la densidad espectral de potencia del periodograma de la señal EEG de la actividad motora de ambos pies (ME2). [autoría propia]

Inicialmente, los datos fueron preprocesados utilizando un filtro paso banda de 8Hz a 30 Hz (incluyendo las bandas μ y β), este filtro eliminó los componentes de ruido de alta frecuencia, como los armónicos de los sistemas eléctricos, y los componentes de ruido de baja frecuencia, como los movimientos relativos entre el electrodo y el cuero cabelludo. El filtro diseñado fue un Butterworth de respuesta a impulsos infinitos (IIR) de orden 200 y de doble paso para mantener una fase lineal. La figura 5.1.4.3 muestra el espectro de las 64 señales de EEG después de ser filtradas en el rango de 8Hz a 30Hz, donde ya no predomina la densidad espectral del ruido de baja frecuencia y el ruido de 60Hz producido por la red eléctrica.

Se extrajeron las características de cada electrodo (64 en total), utilizando PSD en ventanas temporales de 5 segundos, lo que dio como resultado un nuevo archivo que contenía 95.079 filas, correspondientes a los eventos, y 64 columnas, correspondientes a las frecuencias. Para validar los resultados, se añadieron dos columnas al final con el identificador del evento al que pertenece cada fila, es decir IE2 [1 0] o ME2 [0 1]; y, el análisis espectral de los electrodos EEG en el sistema 10/10, como se muestra en la figura

5.1.4.3, que representa la media de todos los sujetos disponibles que realizan la actividad IE2 y ME2.

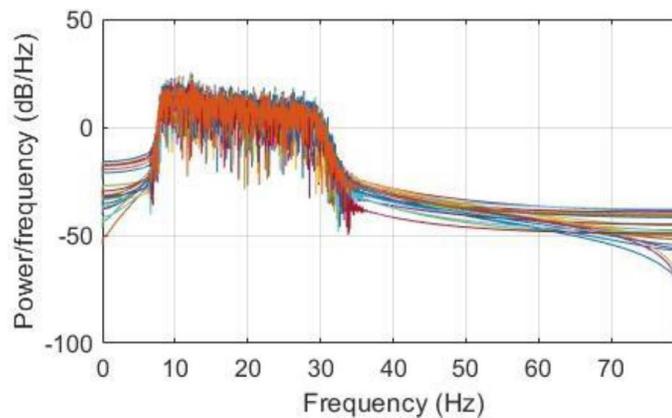


Figura 5.1.4.3 Estimación del periodograma de la densidad espectral de potencia, tras el filtro de paso de banda de la señal EEG correspondiente a la actividad motora de ambos pies (ME2). [autoría propia]

Dado que la tarjeta FPGA contiene recursos limitados de hardware, se decidió utilizar una Red Neuronal Perceptrón Multicapa (MLP) con tres capas; una capa de entrada con las características de los eventos a clasificar, una capa oculta con un número de neuronas que serán calibradas para analizar el comportamiento del clasificador, y una capa de salida que determina la clase a la que pertenece el evento que se está clasificando.

La capa de entrada de la NN tiene 64 neuronas que corresponden a las 64 características de la PSD. Cada una de estas 64 características, son calculados con 10 segundos de registros de datos de cada electrodo del EEG. La capa oculta tiene un número variable de neuronas que se ha modificado al alza desde 5 hasta 100 neuronas, en función de los efectos sobre la mayor diferencia en la precisión del clasificador. La capa de salida tiene el mismo número de neuronas según las clases a las que pertenecen los eventos (IE2, ME2), es decir, dos neuronas; el clasificador, a través de esta capa, indicará la probabilidad de pertenencia a las clases IE2 y ME2 para los eventos evaluados por el clasificador.

Para el entrenamiento de la red neuronal, se utilizó el 15% de los datos para la validación, el 15% para la prueba y el 70% para el entrenamiento, elegidos al azar. Para el entrenamiento se utilizó una técnica de retro-propagación del Gradiente Conjugado Escalado (CGB) y el rendimiento del modelo de clasificación se midió mediante la curva Característica Operativa del Receptor (ROC).

Como parte de la etapa de preprocesamiento, los datos de entrada fueron normalizados entre los valores mínimos y máximos de cada fila, para evitar que los electrodos que tiene valores con una mayor amplitud no sesguen la decisión de los algoritmos de inteligencia artificial, en este caso, $[-1,1]$. A continuación, a partir de la capa de entrada, se añaden los pesos y el sesgo a la capa oculta, como puede verse en la figura 5.1.4.4. Esta configuración fue implementada con el fin de ser ejecutada en un sistema embebido de características computacionales limitadas como lo es la FPGA. Para la capa oculta se utilizó una función de activación Tangente Hiperbólica, que calcula la salida de las neuronas a partir de su entrada neta. A continuación, se conecta la capa de salida donde dos neuronas que representan las clases motora e imagenético motora. En Matlab la capa de salida nos da el valor de probabilidad de pertenencia a cada clase, por ello se utilizó una función Smooth Maximum, donde la clase 1, corresponde a las salidas con mayor valor probabilístico; mientras que la clase 0, a las salidas con la menor probabilidad. Esto nos da como resultado un clasificador binario que nos indica si las características analizadas pertenecen a una actividad motora o imagenético motora.

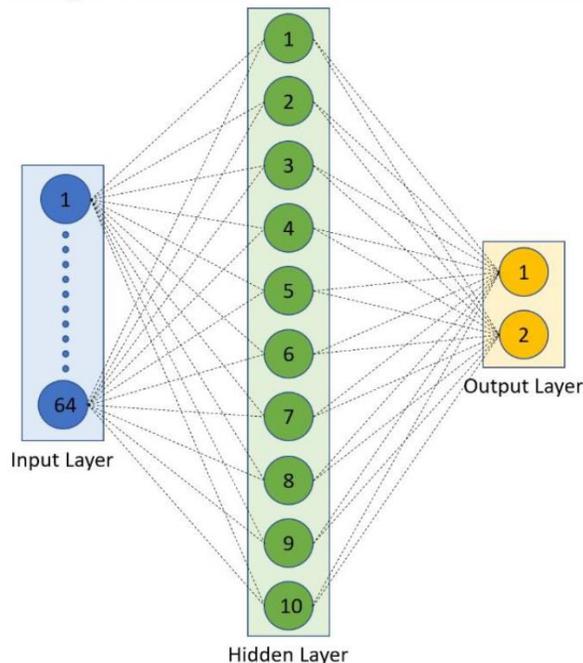


Figura 5.1.4.4 Diagrama de la función de reconocimiento de patrones de las NN en Simulink. [autoría propia]

El procesador NIOS II implementado en la FPGA puede ejecutar scripts en lenguaje C. Para probar el modelo de la NN creado en Matlab, se creó un código equivalente en C. El peso

y los sesgos para la Red Neural entrenada se obtuvieron de Matlab y se convirtieron en matrices en el programa C.

La FPGA utilizada en esta investigación es un procesador NIOS II/e implementado en la FPGA Cyclone V del kit de desarrollo Altera DE10 Standard [6]. El procesador funciona directamente desde el reloj de 50MHz del DE10, e incluye un temporizador de intervalos, un Receptor-Transmisor Asíncrono Universal (UART) JTAG y una interfaz de tarjeta SD. La memoria utilizada es el chip SDRAM de 64 MB del DE10, que funciona a 50 MHz, y es lo suficientemente grande como para almacenar la cantidad de parámetros o pesos generados y los vectores de sesgo necesarios para la NN, así como las librerías utilizadas en el código desarrollado. Todos los demás parámetros se dejaron por defecto.

Los datos EEG registrados de los 64 electrodos de superficie y su respectivo identificador fueron almacenados en una tarjeta SD de 2GB en formato FAT16, utilizando un archivo en formato Valores Separados por Comas (CSV), conectado a la FPGA a través de los pines Entrada/Salida de Propósito General (GPIO I/O), luego leído por el código desarrollado en C, como se detalla en la figura 5.1.4.5. Los valores de los electrodos fueron almacenados en un vector de 64 columnas, y luego procesados por la NN, después el resultado obtenido fue comparado con el identificador real de la intención motora realizada por el sujeto. Para evaluar la exactitud del resultado, este proceso fue ejecutado para cada uno de los datos guardados en la tarjeta SD. A través del temporizador de intervalos, se calculó el tiempo de ejecución de cada uno de los procesos. El proceso sigue tres pasos: Abrir el archivo de la tarjeta SD, leer los datos de la tarjeta SD (T1) y procesar los datos a través de la NN (T2).

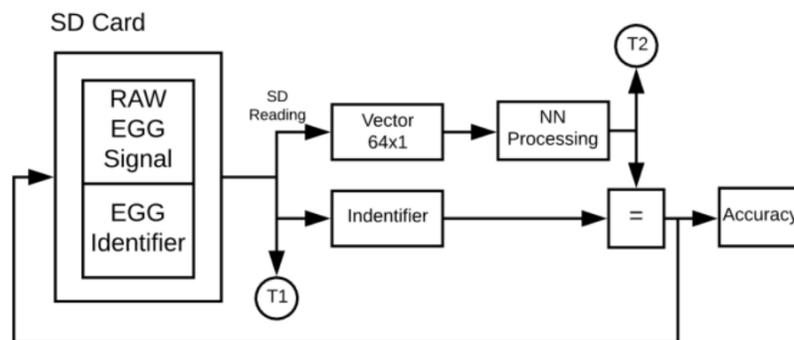


Figura 5.1.4.5 Diagrama de bloques del procesamiento de datos en la FPGA. [autoría propia]

5.1.5 Resultados y Discusiones

Como se observa en la matriz de confusión, figura 5.1.5.1 la NN fue capaz de realizar la clasificación entre la actividad motora imaginaria (1-IE2) frente a la actividad motora (2-ME2) de las extremidades inferiores, con 10 segundos de muestras de EEG (1600 muestras). La probabilidad de detectar un verdadero positivo, cuando el evento ME2 se clasifica como una actividad motora ME2, es del 92,1%; la probabilidad de detectar un falso positivo, cuando el evento ME2 se clasifica como una actividad motora imaginaria IE2, es del 7,9%. Asimismo, la probabilidad de detectar un verdadero negativo, cuando el evento IE2 se clasifica como una actividad motora imaginaria IE2, es del 93,8%; la probabilidad de detectar un falso negativo, cuando el evento IE2 se clasifica como una actividad motora ME2, es del 6,2%. Es decir, la red neuronal predice con alta probabilidad los eventos ME2 con una precisión del 92,1%, y los eventos IE2 con un 93,8%.

Output Class	1	47,5%	3,9%	92,4% 7,6%
	2	3,1%	45,5%	93,6% 6,4%
		93,8% 6,2%	92,1% 7,9%	93,0% 7,0%
		1	2	
		Target Class		

Figura 5.1.5.1 Matriz de confusión de la clasificación de todos los eventos. [autoría propia]

La figura 5.1.5.2 muestra la curva ROC de las clases IE2 y ME2 con 809 épocas; la red neuronal tiene una buena sensibilidad en la detección de verdaderos positivos y verdaderos negativos en ambas clases, en base a este criterio, se selecciona la NN con un tamaño de 30 neuronas para las capas ocultas.

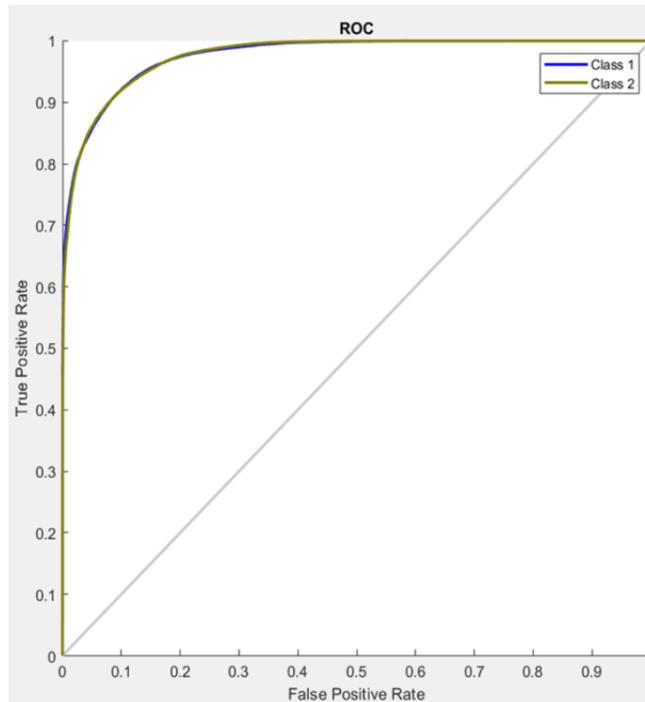


Figura 5.1.5.2 Características operativas del receptor de la clasificación de todos los eventos. [autoría propia]

Al probar la NN de 3 capas con el siguiente número de neuronas en la capa oculta (10, 30, 60 y 100) obtuvimos las siguientes precisiones 85,5%, 93%, 91,6% y 80,2% respectivamente. La red configurada con 30 neuronas en la capa oculta tuvo la mayor precisión en este sistema de clasificación basado en FPGA, y fue utilizada en esta investigación.

La tabla 5.1.5.1 muestra los recursos utilizados por la FPGA para la implementación de la red neuronal y la lectura de los datos de los electrodos a través de la tarjeta SD.

Tabla 5.1.5.1 Recursos utilizados por el FPGA. [autoría propia]

Logic utilization (in ALMS)	1,303 / 41,910 (4%)
Total block memory bits	47,360 / 5,662,720 (<1%)
Total pins	45/499 (9%)

Los tiempos de ejecución del proceso en la FPGA con las configuraciones mencionadas se detallan en la tabla 5.1.5.2.

Tabla 5.1.5.2 Tiempos de ejecución. [autoría propia]

Time to look for the file in the SD	21,26 [us]
Time to open the file in the SD	22,30 [us]
Processing time of the neural network	27,36 [us]

5.2 Detección de intensiones motoras de extremidades superiores e inferiores basado en combinación de algoritmos supervisados y no supervisados

Este trabajo propone una arquitectura de modelo de “extremo a extremo”, desde la extracción de características hasta la clasificación mediante una red neuronal artificial. El proceso de extracción de características parte de un conjunto inicial de señales adquiridas por los electrodos de una Interfaz Cerebro-Ordenador (BCI). La arquitectura propuesta incluye el diseño y la implementación de una mano protésica funcional de seis Grados de Libertad (DOF). Una FPGA traduce las señales de Electroencefalografía (EEG) en movimientos en la prótesis. También, proponemos una nueva técnica de selección y agrupación de electrodos, que está relacionada con las intenciones motoras del sujeto. Analizamos y predecimos dos tareas imaginarias de intención motora: abrir y cerrar ambas manos y flexionar y extender ambos pies. El modelo implementado con la arquitectura propuesta mostró una precisión del 93,7% y un tiempo de clasificación de 8,8 μ s para la FPGA. Estos resultados presentan la viabilidad de realizar BCI utilizando técnicas de aprendizaje automático implementadas en una tarjeta FPGA.

5.2.1 Introducción

La mano humana, como parte esencial del cuerpo, realiza operaciones precisas, pesadas y rápidas, utilizando 27 grados de libertad para todos sus movimientos. Hoy en día, millones de personas sufren la pérdida de sus extremidades debido a amputaciones, lo que provoca un efecto significativo en su vida [29].

La mano humana se controla mediante potenciales de acción neuronal que estimulan la contracción muscular para producir movimientos articulares. Los estímulos neuronales viajan desde el cerebro hasta los músculos a través de las neuronas motoras situadas en la médula espinal. Estos estímulos provienen de la conjunción de diferentes partes del

cerebro, como detallan el Homúnculo de Penfield y las áreas de Brodmann de la corteza cerebral [30]. La actividad neuronal generada en estas regiones cerebrales mientras se realiza una tarea puede ser detectada, medida, registrada y filtrada para controlar un mecanismo artificial.

El acceso a estos estímulos podría ser difícil, como se describe en [31]. La captura de estas señales directamente de los nervios requiere métodos invasivos. Sin embargo, se pueden registrar mediante procedimientos mínimamente invasivos, como propone [32]. Una de las técnicas no invasivas es el uso de la Electromiografía (EMG) [33] o el EEG [34] para registrar la actividad que acompaña naturalmente a los movimientos de la mano.

5.2.1.1 Trabajos relacionados

Hoy en día, el EEG tiene un gran impacto en el desarrollo de dispositivos de rehabilitación y prótesis. La integración de técnicas de Inteligencia Artificial (IA) en el análisis de las señales de EEG facilita la clasificación o interpretación autónoma de la intención de un sujeto [1,35]. Además, su bajo coste, su compatibilidad con otros dispositivos, su portabilidad y su alta resolución temporal, hacen de la captura de señales EEG uno de los enfoques más adecuados para analizar los potenciales de acción neuronal a través de BCIs [36].

Para el control activo de prótesis, Cedeño Z. et al. [3] utilizaron sensores EMG para detectar las intenciones motoras con un 95% de precisión. Sin embargo, estos sensores requieren una actividad motora residual del sujeto. Un trabajo reciente utiliza el electroencefalograma registrado de la corteza prefrontal para controlar activamente las prótesis de mano [37]. Este método requiere que el sujeto se concentre o se relaje para generar ondas cerebrales β o α .

En este trabajo, utilizamos datos de EEG registrados durante la ejecución de una actividad, en el área de la corteza motora [38]. Los datos se recogieron mientras se realizaban tareas motoras y tareas imaginarias. Los datos se preprocesaron para eliminar componentes de ruido. Para predecir la intención motora imaginaria de los sujetos, diseñamos un modelo de extremo a extremo. La extracción de características se realiza en las señales adquiridas a través de la grabación del EEG. Se utilizó una NN para la clasificación. La arquitectura propuesta incluyó el control basado en una FPGA, que traduce las intenciones en movimientos para la mano robótica [39].

5.2.2 Materiales y métodos

La metodología consta de seis etapas: Diseño de una mano impresa en 3D, adquisición de datos, preprocesamiento, extracción de características, clasificación y control del dispositivo 3D.

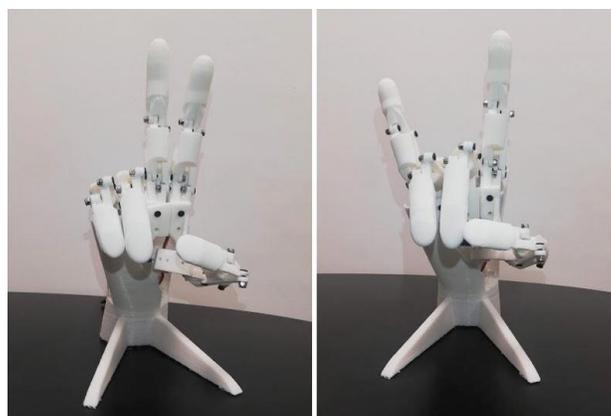
5.2.2.1 EEG Dataset

El conjunto de datos de EEG utilizado para el entrenamiento del modelo procede de la base de datos gratuita PhysioNet [38]. Los datos se adquirieron con un electroencefalograma de 64 canales con electrodos de superficie siguiendo el sistema internacional 10-20. Goldberger et al. [38] registraron las señales utilizando el sistema BCI2000 [40], con una frecuencia de muestreo de 160Hz.

Los sujetos realizaron cada movimiento de forma aleatoria durante 4,1 seg., con intervalos de un segundo para completar un total de 90 repeticiones. Durante la ejecución de la prueba, se mostró un objetivo en la parte superior o inferior de la pantalla. Si aparece en la parte superior, el sujeto imagina que abre y cierra ambas manos; si aparece en la inferior, el sujeto imagina que flexiona y extiende ambos pies. Estas acciones se denominaron Movimientos 1 y 2 (M1 y M2) respectivamente. El participante se concentró hasta que el objetivo desaparecía, y luego se relajaba.

5.2.2.2 Implementación del hardware

Se diseñó y creó una mano impresa en 3D, como un prototipo para el desarrollo de pruebas de los algoritmos de clasificación, siguiendo las directrices definidas por [37], con algunas modificaciones realizadas utilizando un suite de creación 3D de código abierto (Blender), que nos permitió incluir un DOF adicional al dedo pulgar; esta modificación incluyó la opción de utilizar servomotores lineales. La mano creada tiene 6 DOF en total, 2 para el pulgar y uno para el resto de los dedos. Para cada DOF se utilizó un micro servomotor modelo SG90 unido a un manguito en cada articulación de los dedos. El modelo final se muestra en la figura 5.2.2.2.1.



Peace Sign (PS)

Rock Sign (RS)

Figura 5.2.2.2.1 Mano robótica en 3D y movimientos programados en la mano robótica relacionados con las intenciones de los motores M1 y M2 descritas en la sección 2.3. [autoría propia]

Se utilizó un procesador NIOS II/e como controlador y se lo implementó en una FPGA Altera Cyclone® V en un DE0- Nano-SoC (Sistema en un chip). La figura 5.2.2.2.2 muestra la arquitectura del controlador. En esta configuración, los datos del EEG de cada electrodo se envían a través de un Receptor-Transmisor Asíncrono Universal (UART) al circuito de comunicación UART y al procesador ARM (Advanced RISC Machines) de la tarjeta, a través del bus Interfaz eXtensible Avanzada (AXI). Utilizamos el procesador ARM para calcular las predicciones de las intenciones del motor. El procesador ARM activa los pines Entrada/Salida de Propósito General (GPIO) correspondientes a cada servomotor de la mano robótica. El bus AXI se comunica con el bus AVALON utilizando las interfaces IIPS-FPGA. A través del bus AXI, los controladores de Modulación de Ancho de Pulso (PWM) se comunican con los GPIOs de la FPGA, disponibles en la tarjeta.

La mano se conecta con los pines GPIO de la FPGA a través de una tarjeta de control de servomotores. La tarjeta fue diseñada para tener una distribución ordenada plug-and-play de los servomotores que pueden seleccionarse mediante puentes. Esta característica permite seleccionar la alimentación de los servomotores ya sea desde la FPGA o desde una fuente externa de 5 VDC.

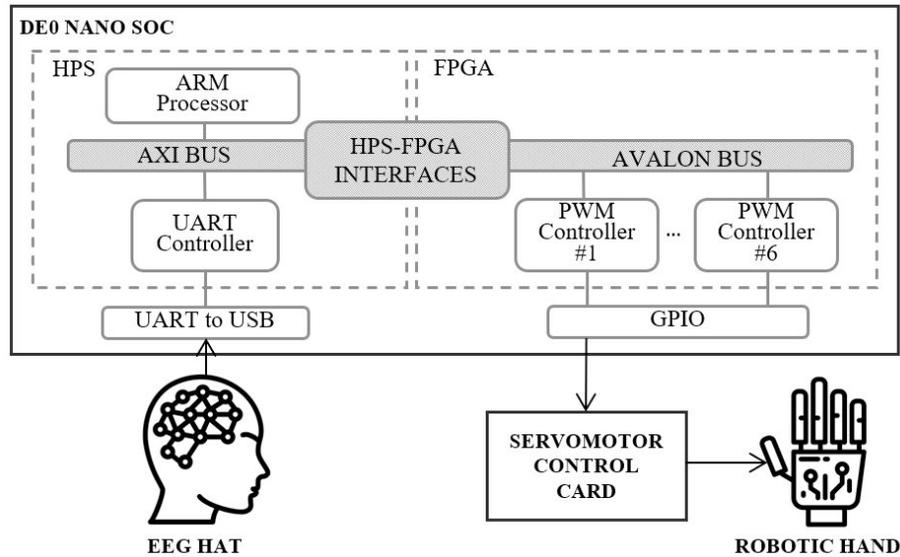


Figura 5.2.2.2.2 Descripción del SoC utilizado para la interconexión de los elementos de hardware. [autoría propia]

5.2.2.3 Estructura del sistema

Se diseñó un sistema no invasivo fuera de línea, utilizando una estrategia BCI, como se muestra en la figura 5.2.2.3.1. En esta configuración, se adquirieron datos de 10 voluntarios sanos, como se describe en la sección 5.2.2.1

De los movimientos utilizados para controlar la mano, M1 fue para realizar el signo de la paz (PS) y M2 para el Signo de Rock (RS), como se muestra en la figura 5.2.2.2.1. Después, cada movimiento se guardó siguiendo el formato europeo EDF. Cada tarea tenía un total de 656 muestras, y para cada sujeto había 46 archivos, 23 correspondientes a PS y 23 a RS.

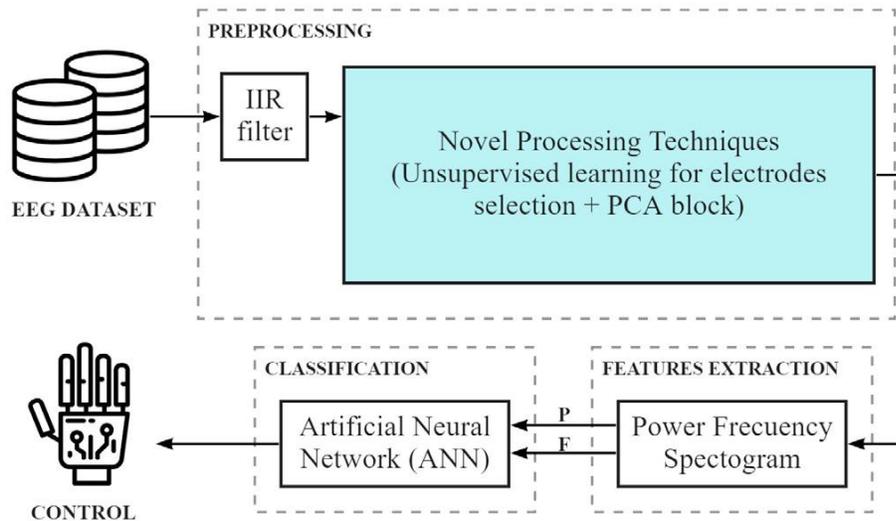


Figura 5.2.2.3.1 Estructura del sistema BCI de enfoque en línea. [autoría propia]

5.2.2.4 Preprocesamiento de datos

Una vez adquiridas las señales de EEG, fue necesario realizar un preprocesamiento para maximizar la información relevante contenida en las muestras de EEG. Además, el preprocesamiento aísla las señales asociadas a una actividad cerebral, durante un periodo específico dentro de un rango de frecuencia [41]. Para lograr esta extracción, y poder segmentar los datos de EEG continuos, luego seleccionar las señales significativas captadas en los electrodos, que se utilizaron en el entrenamiento del modelo, utilizamos la arquitectura que se muestra en la figura 5.2.2.4.1.

Filtro de Respuesta al Impulso Infinito (IIR). Tal como lo determinaron Bansal, D. y Mahajan, R. [41], cuando se trata de tareas motoras, las bandas relacionadas con los datos EEG de interés se reflejan en las bandas α , μ y β . Por lo tanto, diseñamos filtros temporales para seleccionar subfrecuencias específicas del EEG. Se implementó un filtro digital IIR de doble paso de orden Butterworth 162 con un paso de banda de 8 a 31 Hz, utilizando Matlab 2016.

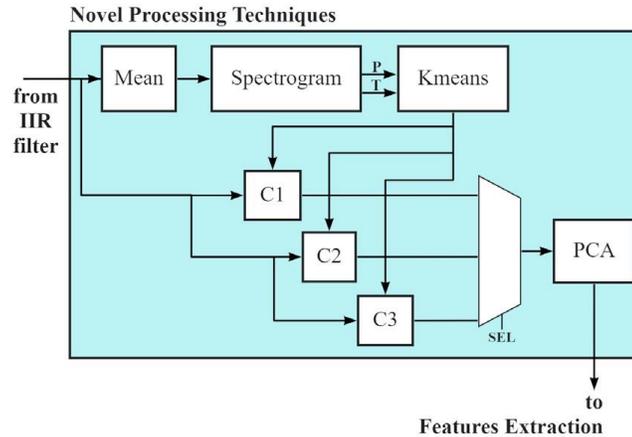


Figura 5.2.2.4.1 Arquitectura de aprendizaje no supervisado para la selección de los electrodos y señales significativas con PCA. [autoría propia]

- **Media estadística:** Para todos y cada uno de los movimientos evaluamos la media estadística, es decir, la media de todas las señales correlativas en los N archivos. Las señales se capturaron de cada electrodo en cada momento muestreado, generando un único archivo que contiene los valores RMS de todos los archivos del mismo movimiento.
- **Espectrograma:** Las señales del EGG tienen características particulares, como la no linealidad, la no gaussiana y la no estacionaria. Por lo tanto, para centrarse en su frecuencia con características no lineales, así como en sus características lineales temporales, aplicamos una Transformada de Fourier de Corto Plazo (STFT) a cada tarea ejecutada durante 4,1s (656 muestras). Como resultado se extrajeron tres características: Potencia, frecuencia y tiempo de la señal, como se muestra en la figura 5.2.2.4.2.

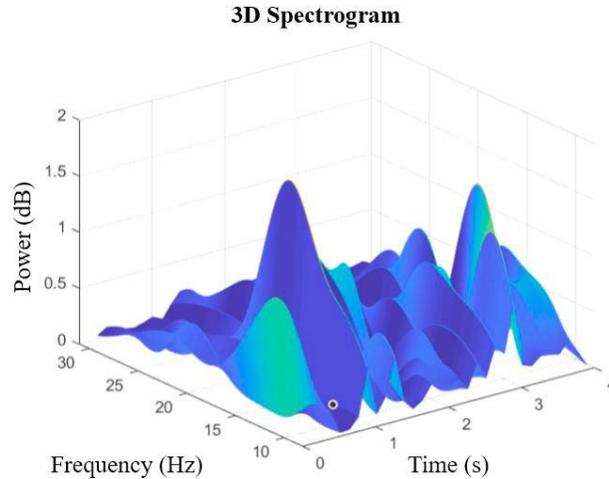


Figura 5.2.2.4.2 Espectrograma 3D de cada una de las tareas ejecutadas durante 4,1s (656 muestras). [autoría propia]

Con la combinación de estas señales, se creó una representación en tiempo potencia (PT) con los valores RMS de tiempo frente a la potencia, en cada instante de tiempo para cada uno de los 64 electrodos. Los electrodos están sincronizados en el tiempo y aportan información en el momento en que el sujeto realiza una actividad motora.

Agrupación híbrida de K-means. Como se ha descrito anteriormente, al adquirir señales de EEG, es necesario seleccionar los electrodos que mejor se comportan durante este proceso debido a la presencia de interferencias. Los datos capturados a través de estos electrodos se utilizaron posteriormente para analizar señales específicas relacionadas con la actividad neurofisiológica de interés. A continuación, estos datos se agruparon en K-grupos por su similitud dentro de los grupos, así como por su disimilitud entre elementos de diferentes grupos [42]. Para elegir el número adecuado de grupos en los que debe dividirse la señal, utilizamos el criterio de Calinski-Harabaz, que viene determinado por la ecuación 5.1:

$$CH(k) = \frac{B_c(k)}{k-1} / \frac{W_c(k)}{n-1} \quad (5.1)$$

Donde “n” representa el número de elementos de un cluster y “k” el número de clusters. “B_c” denota la suma cuadrática de la distancia entre los elementos de un clúster, y “W_c” la suma cuadrática de la distancia entre los elementos fuera de un clúster.

Los criterios determinados en la ecuación 5.1 nos permiten analizar cada posible solución de los clusters en función de su calidad. Esta característica determina cuán grandes son

las distancias entre-clústers y la proximidad a los datos intra-clústers [43]. En este caso, el número óptimo de clústeres determinado fue de tres.

Para la agrupación de los datos preprocesados, utilizamos un algoritmo K-means no supervisado. Una vez aplicado, fueron validados los electrodos de cada grupo mediante el coeficiente Silhouette [44]. Después de aplicar K-means, y validar los grupos, obtuvimos las señales guardadas tras aplicar el filtro temporal de los electrodos correspondientes a cada grupo guardados en diferentes archivos.

Análisis de Componentes Principales (PCA). Para centrarse en las características que mejor capturan las respuestas neurofisiológicas de los sujetos que ejecutaron una tarea, se utilizó una reducción de dimensionalidad usando PCA [45]. Para seleccionar el número de PCs a utilizar, se seleccionó el menor número de dimensiones para que el subespacio cubierto por esas dimensiones capture al menos el 99% de la varianza [43]. Sobre la base del análisis estadístico del conjunto de datos utilizado en esta investigación, cuatro PC para cada una de las tareas realizadas por los sujetos, permitió mantener el 99% de la información, y al mismo tiempo redujo la necesidad de costosos recursos computacionales necesarios para realizar la tarea de extracción de características, basándose sólo en esos PCs.

5.2.3 Extracción de características

Se realizó la extracción del espectro de potencia en frecuencia de las señales, así como los valores RMS de las componentes principales de cada evento perteneciente a cada grupo obtenido en K-means, utilizando el Espectrograma. Los valores extraídos se almacenaron en un vector indexado por columnas, resultando una matriz de 4.096 columnas y n filas para cada tarea, donde n es el número de electrodos seleccionados por K-means en función de la tarea.

5.2.4 Clasificación

Para la etapa de clasificación utilizamos una estrategia de aprendizaje supervisado, basada en una red neuronal MLP [46]. Realizamos el entrenamiento utilizando el Stochastic Gradient Descend (SGD) y la actualización de los parámetros mediante Backpropagation. La MLP se diseñó como una red neuronal completa de 3 capas; la capa

de entrada se configuró con 4.096 neuronas, correspondientes al tamaño del vector de entrada; la capa de salida, contiene 2 neuronas, basadas en el número de tareas a clasificar. La capa oculta contiene 10 neuronas para la mejor configuración. Cada neurona fue configurada para responder a las señales entrantes, basándose en la función de activación sigmoideal como se detalla en la ecuación 5.2:

$$\phi(z) = \frac{1}{1 + e^{-z}}. \quad (5.2)$$

El proceso de entrenamiento duró hasta que la precisión fue superior al 90%; por lo tanto, después de que la red fuera entrenada y validada, y alcanzado la precisión y la pérdida esperadas y su respectiva matriz de pesos aprendida, se implementó su arquitectura en C++. Los coeficientes de umbral, y otros parámetros también se integraron en el sistema basado en FPGA.

5.2.5 Control

Tal y como se ha definido, la arquitectura de nuestro modelo finaliza con un control, que interactúa con la BCI. La estructura del control se detalla en el Algoritmo 5.1.

Algoritmo 5.1. Algoritmo de movimiento de manos robóticas. [autoría propia]

Result: Movement of Robotic Hand
Init: Begin button is press;
while *Always* **do**
 Read pre-processed EEG data and send it to the Neural Network;
 if *M1 predicted* **then**
 | PS Sign;
 else
 | **if** *M2 predicted* **then**
 | | RS Sign;
 | **else**
 | | Initial Hand position;
 | **end**
 end
end

5.2.6 Resultados y Discusiones

Como se muestra en la figura 5.2.6.1, el algoritmo K-means identificó 3 clusters que representan el número de grupos de electrodos que mejor capturaban las respuestas neurofisiológicas. El número de electrodos pertenecientes a cada grupo depende del movimiento realizado por el sujeto. Se puede notar que, para el caso del electrodo 13, el algoritmo de K-means lo identificó como un grupo en sí mismo, que está alejado del resto de los clusters. Por lo tanto, este cluster no fue considerado en este análisis. La señal perteneciente a este grupo mostró mucho ruido durante su proceso de adquisición y podría haber varias razones por las que esto podría estar ocurriendo, desde un electrodo dañado hasta una conexión suelta que compromete el proceso de captura de datos en este electrodo. Los grupos utilizados en el análisis son C1 y C3 para PS y C1 y C2 para RS, como se muestra en la figura 5.2.6.1. Los grupos de electrodos para los movimientos PS y RS están bien identificados y diferenciados entre sí, y no hay puntos de datos ubicados en un clúster diferente. Los resultados obtenidos por el coeficiente de Silhouette confirmaron que los electrodos estaban bien agrupados y ninguno fue eliminado para la etapa de clasificación.

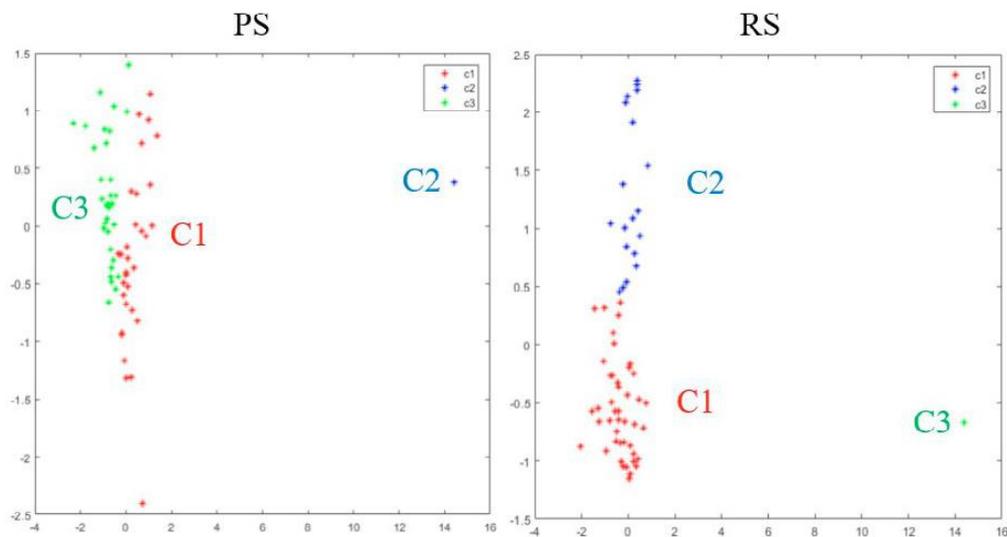


Figura 5.2.6.1 Asignación de clusters y centros para PS y Rs signos. [autoría propia]

Para el proceso de entrenamiento de la MLP el conjunto de datos se fragmentó de la siguiente manera: El 70% del conjunto de datos se eligió al azar para el entrenamiento; el

15% se utilizó para la validación durante el 15% restante del conjunto de datos se utilizó para las pruebas.

En la fase de clasificación, se obtuvieron mejores resultados para los grupos C3 de PS y C2 de RS. La MLP se entrenó utilizando diferentes configuraciones para la capa oculta. Se utilizó el siguiente número creciente de neuronas: 5, 10, 15, 20 y 30 neuronas, hasta que se obtuvo un rendimiento aceptable de la arquitectura MLP para la FPGA, sin afectar al tiempo de respuesta. Para estas configuraciones los resultados fueron: 94,8%, 96,4%, 94,3%, 92,4% y 90,5% respectivamente.

Después de obtener el mejor rendimiento con diez neuronas en la capa oculta, se realizaron pruebas con la MLP y con 63 nuevos puntos de datos, que constituyen el 15% restante del conjunto de datos no utilizados durante el entrenamiento ni la validación. La matriz de confusión de la Figura 5.2.6.2 muestra el mejor rendimiento en esta configuración.

10HL
Test Confusion Matrix

Output Class	30 47.6%	2 3.2%	93.8% 6.3%
	2 3.2%	29 46.0%	93.5% 6.5%
	93.8% 6.3%	93.5% 6.5%	93.7% 6.3%

Figura 5.2.6.2 Matriz de confusión de prueba. Matriz de confusión de prueba. [autoría propia]

En esta matriz de confusión, cada columna de la matriz representa el número de predicciones para cada clase, en nuestro caso, PS y RS. Mientras tanto, cada fila representa las instancias de la clase real, lo que permite detectar qué tipos de aciertos y errores tiene nuestro modelo durante el proceso de aprendizaje. En este caso, 30 de los 32 puntos de datos pertenecientes al evento PS fueron clasificados por el MLP como PS y 2 como RS; 29 de los 31 elementos pertenecientes a clase RS se clasificaron como RS y 2 como PS, lo que representa una precisión del 93,7%.

Una vez que esta red neuronal MLP ha cumplido con el rendimiento esperado, y antes de trasladar esta arquitectura a la FPGA, se verificaron y validaron los resultados de la matriz de confusión utilizando 60 nuevos puntos de datos. Como resultado, se obtuvo una precisión media del 95,1%, por lo que esta configuración de red fue empleada con el BCI.

La figura 5.2.6.3 muestra que para las señales PS y RS asociadas con los movimientos M1 y M2 se utilizaron 32 y 19 electrodos, respectivamente. La figura 5.2.6.3 representa los electrodos seleccionados que proporcionan información significativa en la clasificación de cada tarea imaginaria. La ubicación de estos electrodos permitió determinar las áreas de la corteza cerebral que estaban implicadas en la ejecución de estas tareas.

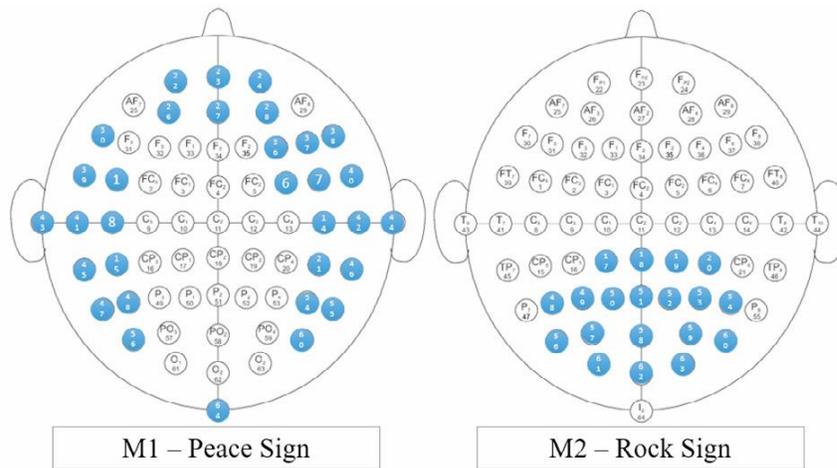


Figura 5.2.6.3 Electrodos utilizados en la intención motora M1 y M2. [autoría propia]

Para la implementación de la arquitectura mostrada en la figura 5.2.2.2.2, se utilizó la tarjeta de desarrollo “DE0-Nano-SoC” con una FPGA “Cyclone V” con 40K elementos lógicos que pueden ser controlados por software. La tabla 5.2.6.1 muestra un resumen de los recursos utilizados en esta implementación.

Se puede visualizar que se ha empleado el 52% de los elementos lógicos, así como el 73% del número total de pines. Por lo tanto, es posible seguir empleado más recursos, como los bloques PWM embebidos para controlar más servomotores y bloques de protocolo de comunicación embebidos, entre otros.

Tabla 5.2.6.1 Recursos utilizados por la FPGA. [autoría propia]

Recursos	Utilización
Elementos Logicos Utilizados ALMS	9328/15880 (52%)

Total de bits de memoria de bloque	2048/2764800 (<1%)
Total de pines	230/314 (73%)

5.3 Algoritmos de clustering en la detección de tareas motoras e imagenético motoras de señales EEG

El análisis de las señales de electromiografía (EMG) permite obtener información útil para desarrollar aplicaciones de reconocimiento de gestos. En este trabajo se propone un sistema de reconocimiento de gestos basado en FPGA, para apoyar la comunicación de frases personalizadas de personas con problemas de habla. Los algoritmos de aprendizaje autónomo pueden identificar con precisión los gestos, normalmente dependen de un gran número de características o de grandes conjuntos de datos de entrenamiento. En esta sección, se utiliza un pequeño número de características en el proceso de clasificación de gestos para reducir la necesidad de potencia computacional. En concreto, se propone utilizar una sola característica, el valor de la señal de la media cuadrática (RMS), y el algoritmo de clasificación supervisada KNN y el algoritmo de clasificación supervisada KNN. El sistema se evalúa en una FPGA DE10-Standard para demostrar su portabilidad a dispositivos portátiles con recursos de hardware limitados. Las pruebas muestran que los sujetos sólo necesitan tres segundos por gesto para entrenar el sistema, lo que evita el procesamiento de grandes cantidades de datos y mejora la experiencia del usuario durante la configuración del equipo. Además, la precisión del sistema alcanza el 95% utilizando 2 segundos de datos, con lo que se reducen los recursos humanos y de hardware.

5.3.1 Introducción

El progreso y la expansión de las Tecnologías de la Información y la Comunicación (TIC) han tenido un gran impacto en el funcionamiento de la sociedad, y los desarrolladores se han convertido en los principales contribuyentes de dicho impacto. Como se describe en [47], las mejoras y adiciones a la tecnología existente han hecho posible que las personas con discapacidades auditivas y del habla interactúen con un grupo más amplio de personas. La Organización Mundial de la Salud estima que el 15% de la población mundial, unos 900 millones de personas se han visto afectadas por alguna discapacidad física, psicológica o sensorial, y estas discapacidades dificultan el crecimiento personal y la integración social [48]. Con el aumento del acceso a la tecnología los dispositivos de bajo

coste que recogen datos de la actividad humana se han vuelto cada vez más accesibles para las personas. Hoy en día, muchos desarrollos de aplicaciones se centran en estos datos, y técnicas basadas en los datos, como el aprendizaje automático, es el estado del arte. Estos datos, junto con los modelos basados en Machine Learning (ML) pueden utilizarse para mejorar la experiencia del usuario, la calidad y la facilidad de uso de varios gadgets. La implementación propuesta en este trabajo abre la ventana para aumentar la oportunidad de acceder a las personas con discapacidad a dispositivos que puedan interpretar las intenciones de sus usuarios.

Entre las técnicas de ML disponibles, las redes NN están bien posicionadas en los procesos habituales de clasificación de imágenes y textos. Para otras aplicaciones, como las que implican dispositivos pequeños y portabilidad, la carga computacional de las NNs puede ser prohibitiva. Para este trabajo, consideramos el algoritmo K-Nearest Neighbors (KNN), un algoritmo potente pero fácil de implementar, con gran capacidad de interpretación y complejidad computacional adecuada para aplicaciones basadas en sistemas embebidos de pequeño tamaño que pretenden ser portátiles. Para la adquisición de datos, utilizamos el brazalete MYO [49], un dispositivo portátil de bajo coste capaz de interactuar con sistemas predefinidos y capturar datos. El MYO está equipado con varios sensores que proporcionan datos para su uso en el reconocimiento de los gestos de la mano y de los movimientos del brazo en general. Se caracteriza por utilizar un proceso llamado Electromiografía (EMG); identificando el gesto mediante el movimiento de los músculos del brazo. Basándose en los impulsos eléctricos generados por los músculos, 8 sensores EMG se encargan de caracterizar cada gesto objetivo [50]. El procesamiento se realiza mediante un arreglo de puertas configurables por campo (FPGA) Sistema en chip [51]. Específicamente, se emplea la FPGA Cyclone V implementada en la placa DE-10 Standard [52]. Los resultados muestran que el sistema propuesto puede alcanzar una alta precisión de reconocimiento, manteniendo una baja utilización del hardware y requiriendo cantidades relativamente pequeñas de datos de entrenamiento.

5.3.2 Trabajos relacionados

Existen algunos trabajos previos relacionados con la clasificación de datos EMG y la utilización de esos resultados en aplicaciones como punteros virtuales o cursores de movimientos. Fabrizio Eloy Ramirez et al. [53] desarrollaron un sistema para personas con

discapacidad auditiva utilizando un guante electrónico, y lograron una precisión de reconocimiento mínima del 90% mediante el empleo de sensores PowerFlex. El uso de un guante supone un gran dispositivo que debe llevar la persona para clasificar los gestos. El algoritmo DBSCAN utilizado en [54] adquirió datos de treinta y dos sensores superficiales en el antebrazo. Este algoritmo se probó en seis sujetos con el objetivo de clasificar 9 letras del lenguaje de signos americano. El procesamiento computacional se llevó a cabo en Matlab y la implementación del algoritmo de clustering fue realizado en RStudio. Este trabajo, implicó el procesamiento de las señales para reducir el ruido logrando una tasa de precisión cercana al 50% utilizando el algoritmo K-means. Una propuesta similar utilizó la combinación de k-NN y redes bayesianas para detectar 4 gestos diferentes [8]. Otro trabajo en reconocimiento de gestos empleó la detección de la actividad motora con el dispositivo MYO estableciendo un umbral para activar o desactivar un agarre [10]. Sin embargo, el sistema propuesto no diferencia los gestos realizados por el sujeto. Estos trabajos destacan la importancia de realizar una calibración inicial de los parámetros para cada entrenamiento y para cada sujeto o proporcionar un conjunto de datos de entrenamiento.

En este trabajo, se diseñó una configuración inicial que guía al usuario para obtener datos de entrenamiento personalizados. De este modo, se personaliza la clasificación y se logra una alta precisión de reconocimiento. Además, a diferencia de otros trabajos, sólo se usa un pequeño número de sensores EMG en el antebrazo, junto con un procesamiento de características y un algoritmo de clasificación, lo que reduce la carga computacional, logrando una precisión del 94%.

5.3.3 Diseño del sistema implementado

En esta sección, presentamos una visión general del sistema propuesto y describimos las diferentes etapas para su implementación: adquisición de datos, selección de características, configuración del hardware FPGA, calibración inicial y proceso de evaluación.

5.3.3.1 Visión general del sistema

En la actualidad, existen productos y aplicaciones que ofrecen traducir la voz a texto permitiendo a los no hablantes, pero a través de signos, comunicarse con las personas. Sin embargo, esta última comunidad necesita contar con mecanismos que ayuden a la

traducción en situaciones en las que la escritura no es tan rápida como la prioridad del mensaje. Este sistema debe satisfacer la necesidad real del proceso de traducción, pero también ser lo suficientemente pequeño, potente y portátil como para ser útil. Diseñar un dispositivo que sea sencillo de instalar, configurar los mensajes predefinidos que se van a comunicar (datos de entrenamiento) y operar permitiría una forma efectiva de satisfacer dicha necesidad. La figura 5.3.3.2.1 muestra la implementación propuesta de un sistema digital donde los datos de EMG son adquiridos por el dispositivo MYO y tiene conectado un dispositivo “wearable” que tiene la capacidad de recoger y procesar la información de los gestos del lenguaje de las señales de la mano.

5.3.3.2 Adquisición de datos

Los datos se adquirieron utilizando el dispositivo MYO, que tiene 8 sensores distribuidos simétricamente alrededor del antebrazo. Estos 8 sensores proporcionan datos electromiográficos capaces de transmitir datos EMG en una escala de milivoltios. Estos datos vienen ya filtrados por el dispositivo, lo que lo hace apto para ser utilizado directamente en aplicaciones sin necesidad de pre-procesar la señal.



Figura 5.3.3.2.1 Sistema digital propuesto, utilizando MYO y un dispositivo portátil. [autoría propia]

Los datos de EMG se transmiten a una frecuencia de 200 Hz. MYO realiza el proceso de comunicación por Bluetooth 4.0 BLE con un alcance máximo de 15 mts [55]. Las muestras de datos adquiridas se recogen en el sistema embebido de destino para su caracterización y su posterior procesamiento. En el momento de la adquisición de datos la persona no debe hacer los gestos con fuerza o aplicando fuerza excesiva, esto puede afectar al proceso de clasificación porque los gestos pueden parecer poses naturales.

En la figura 5.3.3.2.2 se muestra la representación real de la letra L donde cada línea simboliza los datos de un solo sensor a lo largo de tiempo. Como se puede observar en la figura, los datos obtenidos directamente de los sensores no muestran características distinguibles que puedan ser identificadas como representantes únicos de la letra L. Sin embargo, al inspeccionar de cerca estos datos "en bruto", puede que los sensores 6, 7 y 8 muestren picos de actividad relativa. Esto supone que hay ciertas características que pueden ser explotadas a partir de los datos de los sensores para caracterizar la letra L, mediante los sensores que captan la mayor parte de la activación muscular al realizar un gesto de interés.

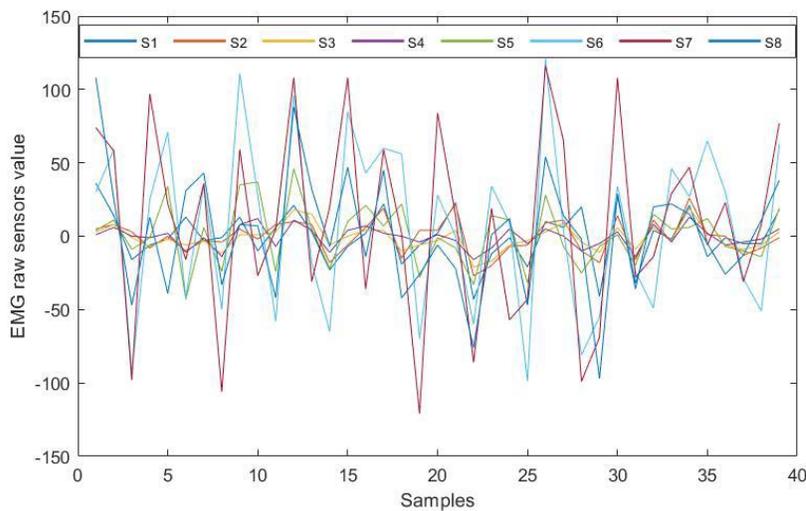


Figura 5.3.3.2.2 Datos de EMG de la señal de mano de la letra "L". [autoría propia]

5.3.3.3 Selección de características

Para obtener una representación correcta de la señal y tener suficientes características para trabajar en el proceso de clasificación de gestos, se realizaron varias pruebas con el objetivo de utilizar características de muy baja complejidad computacional como los valores máximos, la media, la varianza, la mediana y la raíz cuadrada. Con el objetivo de proporcionar características más "limpias" para el proceso de clasificación, se añadieron más características, obtenidas de los datos de los sensores, lo que supuso una degradación de la precisión.

Aunque las características adicionales consideradas eran baratas de calcular, su contribución a la información de caracterización no fue significativa. En su lugar,

contribuyen con redundancia o ruido a los datos en bruto. En su lugar, entonces se considera seleccionar sólo el valor de la raíz cuadrada principal, como se muestra en la ecuación 5.3.

$$X_j^{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (5.3)$$

Donde, para cada sensor “j”, esta característica calcula una escala normal sobre las “n” muestras que constituyen un gesto, en lugar de procesar cada muestra de tiempo “i” de forma independiente.

La representación de los datos con las características XRMS seleccionadas se visualiza en la figura 5.3.3.3.1 para la letra B para un valor de n = 400. Para esta muestra de gesto, la figura muestra que la actividad de las características RMS de los sensores 5 y 7 serían útiles a la hora de tomar la decisión de clasificar esta letra. Utilizando la representación basada en RMS cada gesto de interés pudo ser caracterizado por los sensores que llevan la mayor parte de la actividad muscular.

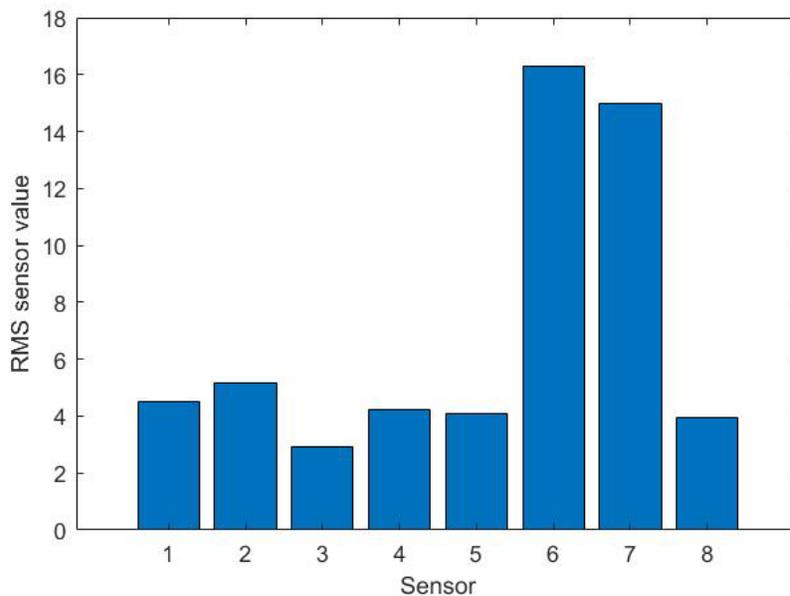


Figura 5.3.3.3.1 Valores del sensor de señal de mano de la letra "B". [autoría propia]

En la figura 5.3.3.3.2 se observa la representación durante un periodo de 216 segundos de la misma letra. La característica RMS de cada sensor muestra sistemáticamente que

los sensores 5 y 7 caracterizaban el gesto. Por lo tanto, proporcionaron una representación útil, aunque sencilla, del gesto para fines de clasificación, ya que sus características más importantes (RMS de los sensores 5 y 7), como se puede observar son estables en el tiempo.

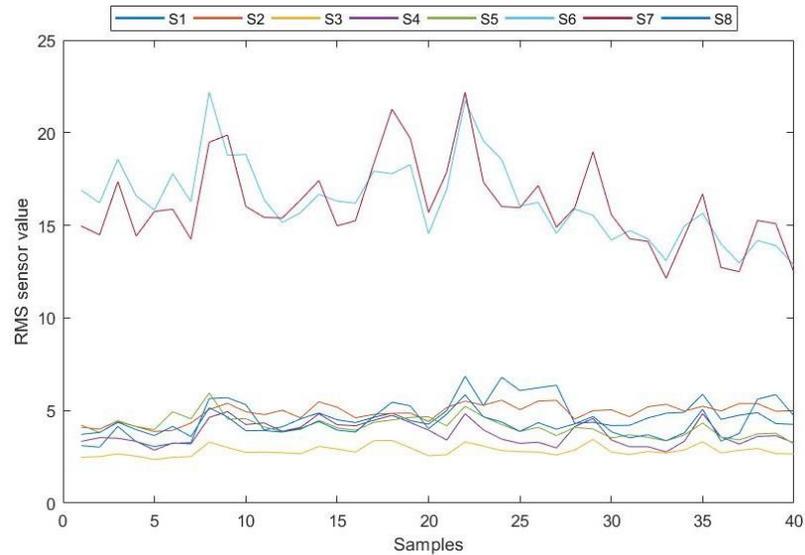


Figura 5.3.3.3.2 Forma de onda de múltiples puntos de la letra "B". [autoría propia]

5.3.3.4 Implementación de FPGA

La característica seleccionada es barata de calcular y adecuada para los pequeños sistemas empotrados portátiles. En este trabajo se utilizó el estándar FPGA De-10 Standard [52], para evaluar la demanda de recursos de hardware del sistema propuesto y obtener una referencia que establece los requisitos de hardware para la implementación real. El QSys (herramienta de diseño de Altera) evaluado tiene los siguientes elementos:

- Fuente de reloj.
- Bucle de Bloqueo de Fase (PLL).
- Procesador Nios II.
- Temporizador de intervalos.
- Periférico de identificación del sistema.
- Grupo de Acción de Prueba Conjunta (JTAG).
- Receptor-Transmisor Universal Asíncrono (UART).
- Memoria Dinámica de Acceso Aleatorio Síncrona (SDRAM).
- Receptor-Transmisor Asíncrono Universal (UART) (Puerto serie RS-232.)

El núcleo UART tuvo que ser configurado para recibir los datos EMG del host MYO, en particular este núcleo fue un mecanismo sencillo para sincronizar cada muestra de datos entrante.

5.3.3.5 Configuración del sistema

Como se describió anteriormente y se muestra en la figura 5.3.3.2.1, el sistema cuenta con una pantalla de Matriz de Gráficos de Vídeo (VGA) en la que se muestran las instrucciones de configuración. El mensaje de bienvenida y las instrucciones permiten que el sistema capture un conjunto inicial de 60 caracteres que indican que la FPGA está lista para recibir datos. En el diseño propuesto el número de gestos que el usuario puede introducir para ser reconocidos y mostrar, se personaliza durante la etapa de inicialización.

Siguiendo la motivación de crear un sistema que entregue mensajes predefinidos rápidamente, en lugar de una traducción en línea del lenguaje de signos, la configuración por defecto es tomar $N = 9$ muestras de gestos, cada uno de 400 puntos o 2 segundos, omitiendo la primera, ya que puede considerarse una señal de transición. Las instrucciones detalladas de este proceso se muestran al usuario como parte de la inicialización del sistema. Una vez capturadas las muestras de entrenamiento, el sistema está listo para clasificar los gestos y mostrar los mensajes que el usuario quiere comunicar.

5.3.3.6 Clasificación

Una vez concluida la etapa de inicial, el dispositivo embebido carga el conjunto de datos de entrenamiento en la memoria. Las características utilizadas por el clasificador son los valores RMS calculados después de n puntos, todas las N muestras de entrenamiento están definidas por estas características; es decir, se cargan en la memoria las matrices G $N \times 8$, donde G corresponde al número de gestos que hay que identificar.

Las nuevas muestras de datos procedentes de los sensores se organizan en una estructura de datos de tamaño n , que puede personalizarse para la precisión. Estas estructuras de datos entran en el proceso de clasificación junto con el conjunto de datos de entrenamiento cargado en la memoria y el parámetro K [56].

KNN calcula la distancia euclidiana entre las características RMS del punto entrante contra todo el conjunto de datos de entrenamiento. Una vez calculada esta distancia, los puntos

resultantes se utilizan para elegir las K distancias menores. Por último, se realiza un recuento de frecuencias por cada identificador de gesto. El grupo identificador con mayor frecuencia de aparición es el resultado del algoritmo, y el mensaje asociado se muestra al usuario que debe leerlo.

5.3.4 Evaluación del rendimiento

Para evaluar el rendimiento de la solución de comunicación visual propuesta, hemos entrenado el sistema utilizando la configuración por defecto. Es decir, la etapa de entrenamiento se efectuó adquiriendo 9 muestras de 2 segundos por gesto. Para la evaluación, se ha asociado los mensajes predefinidos: A, B, I, L, N, O, P, Q y U, como se muestran en la figura 5.3.4.1, según el lenguaje de signos americano.

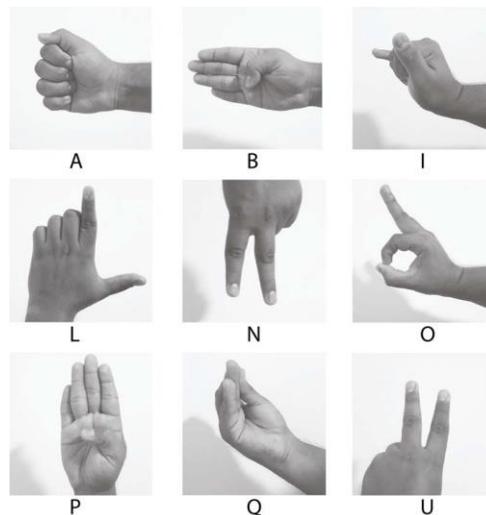


Figura 5.3.4.1 Gestos entrenados basados en Lenguaje de Señas Americano (ASL). [autoría propia]

La figura 5.3.4.2 muestra el sistema propuesto que no se limita a utilizar letras sueltas o a corresponder a símbolos del lenguaje de signos. Los usuarios pueden personalizar cualquier gesto para asociarlo a un mensaje que se ajuste a la pantalla VGA.

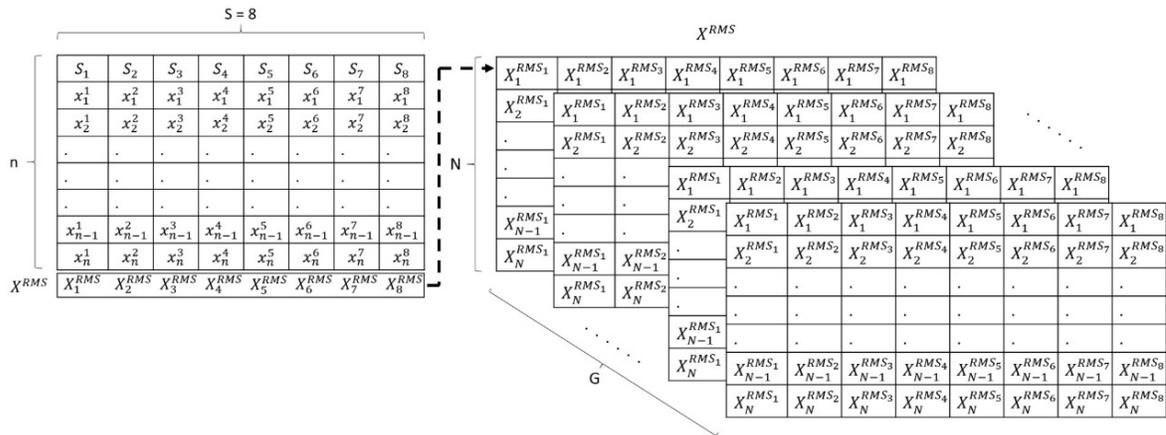


Figura 5.3.4.2 Representación de los datos: Los gestos G se entrenan utilizando $N \in$ muestras de RS. [autoría propia]

Las siguientes pruebas se realizaron en 5 experimentos con 20 gestos, y se pidió a los usuarios de las pruebas que configuren el sistema utilizando el mismo grupo de gestos correspondientes a los mensajes antes mencionados (A, B, I, L, N, O, P, Q y U).

Las pruebas iniciales se realizaron entrenando el clasificador con todas características descritas en la sección 5.3.3.6 simultáneamente, los resultados se muestran en la figura 5.3.4.3. La figura presenta la precisión de las pruebas realizadas para cada gesto entrenado. Como se ha argumentado antes, los valores promedio, como los valores máximos y mínimos de las señales adquiridas por el dispositivo MYO, no contribuyen a caracterizar completamente los gestos. Por lo tanto, utilizar todas las características al mismo tiempo sólo aumenta el ruido en los datos, haciendo que los rasgos caigan en la misma zona espacial euclidiana, lo que da lugar a una precisión de identificación muy baja. Esto se muestra en la figura 5.3.4.3, donde sólo se identifican parcialmente los gestos 3, 4 y 8.

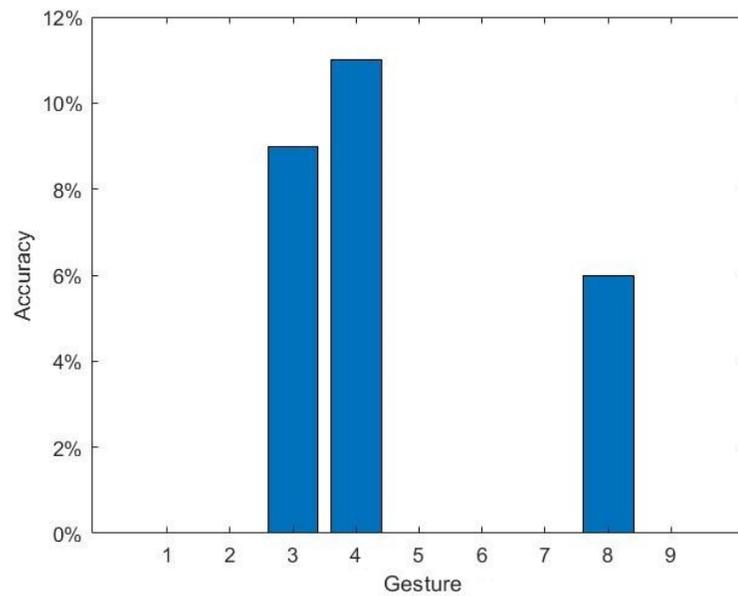


Figura 5.3.4.3 Precisión utilizando 5 características. [autoría propia]

Por otro lado, la figura 5.3.4.4 muestra la precisión de la clasificación cuando se utiliza sólo la característica RMS, en donde la precisión aumenta considerablemente. En estas pruebas, la precisión se ve comprometida para el gesto 6 correspondiente a la letra "O", que el clasificador tiende a decir "P" o "U". Esto podría explicarse analizando la forma en que se conducen los gestos; todos los gestos en los que el clasificador tiende a obtener una menor precisión son aquellos en los que el pulgar tiene una contribución notable. Esta fuerza aplicada por el pulgar puede ser captada significativamente por el MYO y la característica RMS.

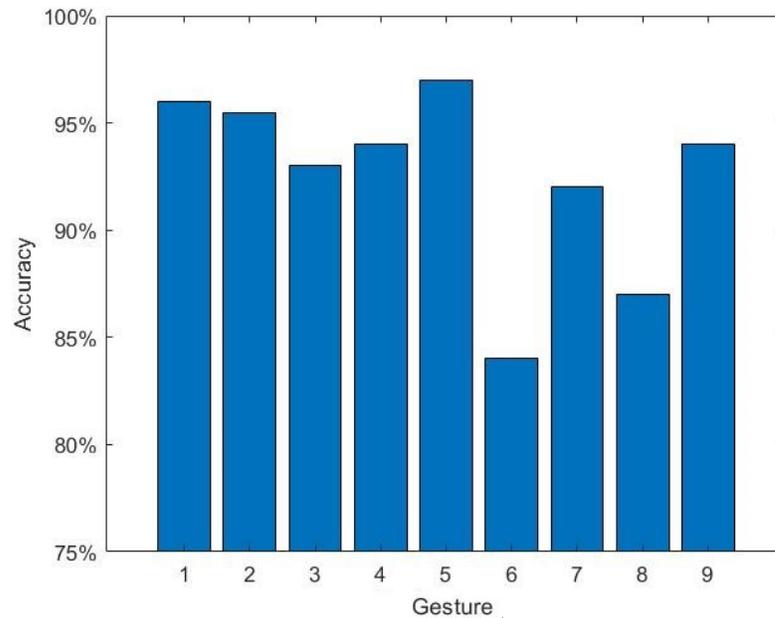


Figura 5.3.4.4 Precisión utilizando el esquema propuesto basado en características RMS. [autoría propia]

Además, la selección del parámetro K se probó en una persona utilizando 40 puntos de prueba. Los resultados mostraron que para $K = 2$ el clasificador no era capaz de tomar una decisión si el punto de prueba tenía dos vecinos más cercanos de diferentes grupos. El uso de $K = 3$ es más eficaz en el proceso de toma de decisiones de KNN, como se muestra en las figuras 5.3.4.5 y 5.3.4.6. Las figuras muestran el número de puntos de datos que no se pueden clasificar como resultados de KNN en puntos cuyas distancias son demasiado similares a una o más representaciones RMS pre-entrenadas. En la figura 5.3.4.5 podemos observar una relación entre los gestos 6 y 7, correspondientes a los mensajes predefinidos como P y O basados en el lenguaje de signos americano, donde el clasificador no puede tomar una decisión.

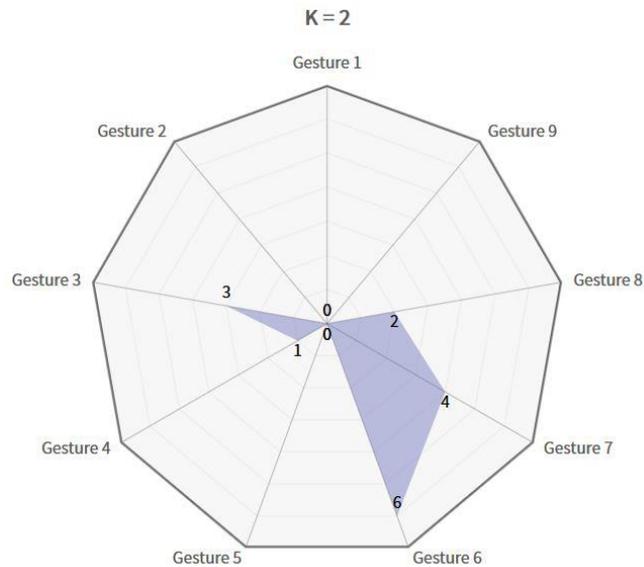


Figura 5.3.4.5 Número de puntos no clasificables utilizando $K = 2$. [autoría propia]

En la figura 5.3.4.6 cuando el parámetro $K = 3$ sólo hubo 1 muestra para los gestos 8, 6 y 3 que no pudo ser clasificado.

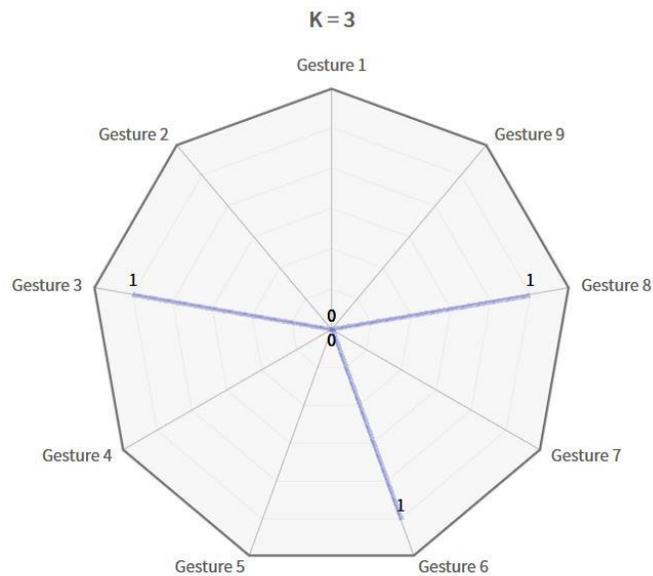


Figura 5.3.4.6 Número de puntos no clasificables utilizando $K = 3$. [autoría propia]

Finalmente, la implementación del prototipo se realizó en una FPGA Cyclone V SoC [52]. Para esta aplicación el consumo de recursos en la FPGA fue del 3% de la lógica de elementos, un 7% de PLL y menos de un 1% de memoria instalada, lo que implica que hay muchos recursos para el desarrollo de futuras actualizaciones. Además, dada la cantidad

de recursos de hardware utilizados, el sistema propuesto es definitivamente adecuado para ser implementado en hardware personalizado con mucho menos recursos que los utilizados en esta evaluación.

5.4 Clasificación de sujetos con enfermedad de Parkinson

Luego de haber demostrado la eficiencia del uso de los algoritmos de clasificación de aprendizaje supervisado, en la detección de intenciones motoras e imagenéticos motoras, en esta sección se presenta una aplicación de clasificación empleando datos diferentes a las señales bioeléctricas, que están relacionadas al tiempo de respuesta de los sujetos de prueba, y que nos permitió verificar la pertinencia de método utilizado.

La enfermedad de Parkinson es el segundo trastorno neurodegenerativo más común y afecta a más de 7 millones de personas en todo el mundo. En este trabajo, clasificamos a los sujetos con la Enfermedad de Parkinson (EP), utilizando los datos de las pulsaciones de los dedos en un teclado. Se utilizó una base de datos gratuita de Physionet con más de 9 millones de registros, preprocesada para eliminar los valores atípicos. En la etapa de extracción de características se obtuvieron 48 características. Utilizamos Google Colaboratory para entrenar, validar y probar nueve algoritmos de aprendizaje supervisado que detectan enfermedades. Como resultado, se alcanzó una tasa de precisión superior al 98%.

5.4.1 Introducción

La Enfermedad de Parkinson (EP) es el segundo trastorno neurodegenerativo más común [57], y se caracteriza por muchos síntomas clínicos como temblor, bradicinesia, rigidez muscular, trastornos del equilibrio, problemas orales (al tragar, hablar). Entre los síntomas no motores se encuentran la depresión, la ansiedad, la anhedonia, la pérdida del gusto y el olfato, y los trastornos del sueño (insomnio) [58,59].

En 2018, la Organización Mundial de la Salud (OMS) estimó que alrededor de 7 millones de personas sufren de EP, y para 2030 el número crecerá a 12 millones. Según la OMS, esta enfermedad tiene un impacto significativo en la comunidad de ancianos; una de cada 100 personas mayores de 60 años tiene EP [60]. Según estas estadísticas, el crecimiento estimado de los diagnósticos de EP es superior al 70%. Los pacientes tardan entre uno y tres años en ser diagnosticados. Por ello, es fundamental detectar esta enfermedad en una

fase temprana para mejorar la calidad de vida, ya que se trata de una enfermedad neurodegenerativa, es decir, sus síntomas se hacen más notorios con el paso del tiempo [58,59].

En las últimas décadas, la tecnología ha revolucionado los tratamientos médicos. Por ejemplo, la tecnología “wearable” es portátil y permite una rápida monitorización, lo que proporciona un mejor seguimiento al paciente [61]. Por su parte, la Inteligencia Artificial (IA) permite interpretar Imágenes de Resonancia Magnética (MRI) y de Tomografía Computarizada (CT), ayudando así a los médicos a diagnosticar y tratar a los pacientes [61,62].

El Aprendizaje Automático (ML) es un subconjunto de la IA. Actualmente, ML ofrece varias oportunidades nuevas debido al acceso a grandes cantidades de datos. Datos personales, demográficos, geográficos, psicográficos o de comportamiento que antes no estaban disponibles o eran limitados. Los algoritmos de ML pueden generar y activar estos datos para convertirlos en información y aprendizaje [62]. Se puede ofrecer un diagnóstico, controlar y categorizar mediante clasificadores. Por lo tanto, podemos detectar trastornos como la EP en una etapa temprana [62].

La evaluación motora es la más común en la EP utilizando algún tipo de tarea repetitiva. La punción del dedo es una de las pruebas más fiables y directas para el rendimiento motor en la Escala Unificada de Calificación de la Enfermedad de Parkinson (UPDRS). En esta evaluación, el clínico busca cualquier disminución de la amplitud, ralentización, irregularidad o congelación del movimiento. Se han realizado algunos esfuerzos utilizando herramientas digitales para medir la pulsación de los dedos e implementando técnicas de IA para clasificar, identificar y seguir a los pacientes con EP.

Aprovechando la tecnología táctil sensible de los teléfonos inteligentes, algunos investigadores miden varios parámetros y características del golpeteo de los dedos de los pacientes con EP [63]. Sin embargo, las aplicaciones se basaron simplemente en las mediciones y en el método de clasificación por umbralización. Otros enfoques también utilizan la pulsación de los dedos en los teléfonos inteligentes como sensores para el seguimiento de los síntomas [64] con un algoritmo Random forest que clasifica los datos de un pequeño número de pacientes. Rodríguez-Cruz et al. [65] también utilizaron los

tiempos que sujetos de prueba teclearon con los dedos con una combinación de técnicas ML y Aprendizaje Profundo (DL) para realizar la detección remota de la EP.

Por lo tanto, esta sección presenta una implementación de una técnica de clasificación basada en ML, que utiliza los datos de la pulsación de los dedos para clasificar a los pacientes con EP y analizar su evolución. Esta es una aplicación de los algoritmos de clasificación de aprendizaje supervisado, que han demostrado tener un desempeño significativo en la detección de intenciones motoras en extremidades superiores e inferiores, pero además nos permitió verificar la pertinencia de la metodología utilizada para responder nuestra pregunta de investigación.

5.4.2 Trabajos relacionados

Los algoritmos de IA que pretenden detectar la EP van desde los clásicos clasificadores hasta las NN. Existe una tendencia en metodologías de los trabajos anteriores a la hora de seleccionar los estímulos incluyendo los que se centran en patrones cerebrales [65].

Chen et al. utilizan MRI y ML. [66] procesan imágenes de IRM en píxeles bidimensionales para la extracción de características y biomarcadores, y, utilizando un algoritmo de Máquina de Vectores de Soporte (SVM), obtienen una precisión del 93%. Este experimento proporciona una mejor comprensión a nivel clínico sobre la enfermedad.

Shah et al. [67] utilizan Electroencefalogramas (EEG) y cinco metodologías diferentes para entrenar las NN. Sin embargo, ellos sostienen que se necesita una mayor cantidad de datos y una mejor calidad de EEG de mejor calidad. Por lo tanto, ninguna de sus metodologías es capaz de entrenar la NN.

El análisis de los patrones cerebrales requiere un preprocesamiento de datos para entrenar una NN. Trabajar con este tipo de patrones es más difícil debido a la complejidad del cerebro y los conocimientos médicos necesarios para manejarlos [68,69]. Otros proyectos de investigación utilizan patrones motores como al hablar (voz) y caminar. Gharehchopogh et al. [70] utilizan NNs y un conjunto de datos de voz. Son capaces de detectar la EP con una precisión del 93,22% empleando una red Perceptrón Multicapa (MLP) con tres capas y 28 nodos de entrada, cinco nodos ocultos y un nodo de salida).

Wroge et al. [71] utilizan seis algoritmos, Árbol de Decisión (DT), Árboles Extra (ET), SVM, Bosque Aleatorio (RF), Red Neuronal artificial (ANN) y Clasificador Impulsado por

Gradiente (GBC). También utilizan dos modelos de preprocesamiento de datos, Audio-Visual Reto de Reconocimiento de Emociones (AVEC) y Conjunto de Parámetros Acústicos Minimalistas de Ginebra (GeMaps). En su trabajo destacan la precisión del 86% del algoritmo GBC con preprocesamiento AVEC en un conjunto de datos de voz y habla recogido por ellos a través de una aplicación de grabación de voz telefónica.

Hariharan et al. [72] utilizan un algoritmo de Máquina de Vectores de Soporte de Mínimos Cuadrados (LS-SVM), una Red Neuronal (NN) y una Red Neuronal de Regresión General (GRNN). Mediante el preprocesamiento de características en un conjunto de datos de voz, consiguen una precisión del 100%. Sadek et al. [73] también logran una precisión del 100% utilizando el mismo conjunto de datos pero con una RNA.

Urcuqui et al. [57] realizaron un experimento en el que pidieron a unos voluntarios, caminaran tres veces un recorrido de cuatro metros. Los grabaron en vídeo y analizaron los datos de los movimientos de sus piernas. Procesaron los datos utilizando cuatro algoritmos de ML, siendo RF el algoritmo más preciso con una precisión del 82%.

Wang et al. [74] utilizan un algoritmo de red neuronal de retropropagación (BPNN) con un conjunto de datos de caminatas. Obtienen una precisión del 42%.

La mayoría de los estudios que implican el análisis de actividades motoras muestran resultados con alta precisión. Existe una gran cantidad de datos accesibles y diversidad de patrones [69].

5.4.3 Conjunto de Datos

Se empleó un conjunto de datos proporcionado por Physionet, una plataforma que contiene una gran variedad de datos con fines de investigación [64]. Todos los sujetos realizaron la prueba voluntariamente, tras firmar un consentimiento informado. Los voluntarios instalaron la aplicación TAPPY en sus ordenadores. Esta aplicación registra cuántas veces y qué teclas se pulsaron o soltaron. Además, TAPPY crea un registro para cada tecla pulsada en una de las tres posibles (R, L y barra espaciadora).

La carpeta Usuarios archivados contiene un archivo “.txt” por cada uno de los 227 voluntarios. El nombre de cada archivo contiene el UserKey (por ejemplo, User 0EA27ICBLF.txt), y cada archivo contiene la siguiente información demográfica:

- Año de nacimiento: Año de nacimiento (por ejemplo, 1952)
- Género: hombre o mujer (por ejemplo, mujer)
- Parkinson: paciente o control (por ejemplo, Verdadero)
- Temblores: sí o no (por ejemplo, Verdadero)
- DiagnósticoAño: la evolución de la enfermedad en años (por ejemplo, 2000)
- Lado: hemicuerpo afectado, derecho, izquierdo o ninguno, realizado por autoevaluación (p. ej., Izquierdo)
- UPDRS: valoración motora evaluada por un especialista (por ejemplo, No sabe)
- Impacto: cuánto afecta la enfermedad a su vida diaria, poco, moderado o severo (por ejemplo, Severo)
- Levodopa: la respuesta binaria en el uso de levodopa medicamento, sí o no (por ejemplo, Verdadero)
- DA: la respuesta binaria en el uso del fármaco agonista de la dopamina agonista de la dopamina, sí o no (por ejemplo, Verdadero)
- MAOB: la respuesta binaria en el uso de fármacos MAO-B sí o no (por ejemplo, falso)
- Otros: la respuesta binaria en el uso de otros fármacos, sí o no (por ejemplo, Falso)

La carpeta "Tappy Data" contiene entre dos y ocho registros almacenados en archivos ".txt" para cada uno de los 227 participantes. Cada archivo contiene los siguientes datos del experimento:

- UserKey: código de 10 caracteres para un usuario (por ejemplo, 0EA27ICBLF)
- Fecha: Con los dos últimos dígitos del año en curso, el mes y el día AAMMDD (por ejemplo, 160722)
- Marca de tiempo: HH:MM: SS.SSS (por ejemplo, 18:41:04.336)
- Mano: tecla "L" o "R" pulsada; donde "L" denota la mano, y "R" denota la mano derecha (por ejemplo, L)
- Tiempo de retención: Tiempo entre la pulsación y la liberación de la tecla actual mmmm.m milisegundos (por ejemplo, 0101.6)
- Dirección: Anterior a la actual "LL", "LR", "RL" y "RR"; "S" es la tecla del espacio (por ejemplo, LL)

- Tiempo de latencia: Tiempo entre la pulsación de la tecla anterior y la tecla actual. Milisegundos (p. ej, 0234.4)
- Tiempo de vuelo: Tiempo entre la liberación de la tecla anterior y la pulsación de la tecla actual. Milisegundos (p. ej, 0156.3)

5.4.4 Metodología

El desarrollo de este estudio sigue los tres pasos que constituyen la metodología aplicada, especificada en la figura 5.4.4.1.



Figura 5.4.4.1 Pasos de la metodología. [autoría propia]

5.4.4.1 Preprocesamiento de datos

Como se muestra en la figura 5.4.4.2.1 (a), primero se enumeró las UserKeys de los 227 participantes en la prueba en la carpeta de usuarios archivados. Utilizando el UserKey como referencia, se realizó la búsqueda de los registros en la carpeta Tappy Data pertenecientes a cada participante.

Estos registros resumen las pulsaciones por usuario específico en un tiempo determinado. La búsqueda dio como resultado 217 sujetos con datos legibles, de los cuales 162 eran pacientes con EP y 55 eran controles sanos. Se normalizaron estos registros con el método Min-Max, como se muestra en la figura 5.4.4.2.1 (b).

5.4.4.2 Extracción de características

La figura 5.4.4.2.1 (c) muestra cómo la extracción de características condensa la información de los registros de cada uno de los 217 participantes en un único archivo “.CSV”, con 217 filas x 48 columnas. El procesamiento de las 48 columnas, representan 48 características de la siguiente manera:

- Las columnas BirthYear y DiagnosisYear se cambiaron a tipo numérico
- Las columnas con valores Verdadero o Falso se codificaron como datos binarios (0, 1): Mujer, Temblores, Levadopa, DA, MAOB y otros

- La variable Lado se codificó (codificación de un punto): Lado Izquierdo, Lado Ninguno, Lado Derecho
- La variable UPDRS se codificó (codificación de una sola vez): UPDRS 1, UPDRS 2, UPDRS 3, UPDRS 4 y UPDRS Don'tKnow
- La variable categórica Impacto fue codificada (codificación de una sola vez): Impacto Medio, Impacto Leve, Impacto Ninguno, Impacto Severo
- El tiempo de espera, el tiempo de latencia y el tiempo de vuelo fueron codificados (codificación de un punto) y divididos en grupos de: "LL", dirección "LR", dirección "LS", dirección "RL", dirección "RR", dirección "RS", dirección "SL", dirección "SR" y "SS".
- Por último, las etiquetas son el diagnóstico de la EP.

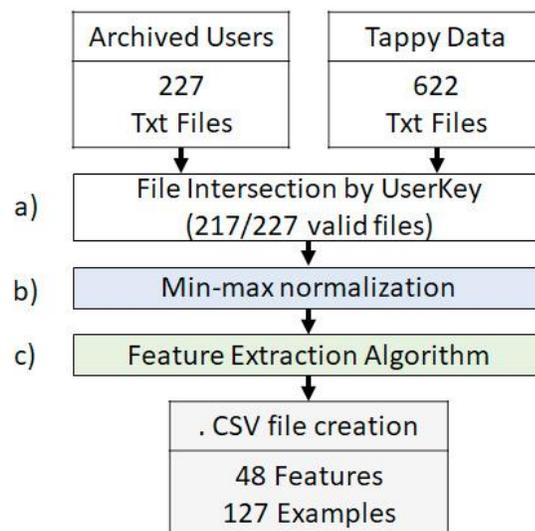


Figura 5.4.4.2.1 a) Búsqueda de registros basada en la lista de UserKey de la carpeta de Usuarios Archivados. b) Normalización Min-Max de los registros de la carpeta Tappy Data. c) Extracción de características para cada uno de los 217 participantes. [autoría propia]

5.4.4.3 Algoritmo de clasificación

El archivo “.CSV” resultante con 217 filas y 48 columnas representa el conjunto de datos utilizado para el proceso de entrenamiento de los algoritmos de clasificación. La Figura 5.4.4.3.1 muestra el conjunto de datos dividido en una proporción de 70:30, es decir, el 70% de los datos son el conjunto de entrenamiento para entrenar los algoritmos de clasificación, mientras que el 30% es el conjunto de pruebas para validarlos.

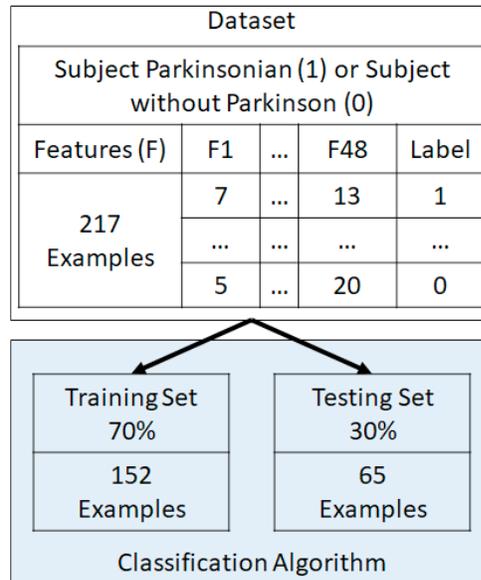


Figura 5.4.4.3.1 División del conjunto de datos en conjuntos de entrenamiento y de prueba. [autoría propia]

Utilizando Google Colaboratory, se ejecutaron cada uno de los algoritmos de clasificación como se muestra en el Algoritmo 5.2. Entre los algoritmos de clasificación empleados se distinguen los siguientes:

- **Naive Bayes (NB):** Clasificador probabilístico basado en el Teorema de Bayes [75]. Los clasificadores NB son un conjunto de algoritmos de aprendizaje supervisado, que pueden ser más rápidos en comparación con algoritmos más sofisticados.
- **Perceptrón Multicapa (MLP):** La red neuronal MLP necesita especificar cuáles son los nodos de entrada y los nodos de salida del algoritmo. El MLP también puede modificar el número de capas ocultas. La red es entrenada de forma iterativa, ya que los parámetros se actualizan en cada iteración dependiendo de la función de pérdida. La precisión del algoritmo mejora en función de los pesos de cada nodo de la capa oculta, a cambio de un mayor coste computacional [76,77].
- **Bosque Aleatorio (RF):** El algoritmo de aprendizaje de conjuntos, en el que el número de grupos de clasificación es previamente especificado [71,75]. RF ajusta varios clasificadores de árboles de decisión en diferentes submuestras del conjunto de datos y utiliza los promedios para mejorar la precisión de la predicción y controlar el sobreajuste.

- **Árboles Extra (ET):** Este algoritmo funciona creando un gran número de árboles de decisión a partir del conjunto de datos de entrenamiento. Las predicciones se realizan utilizando la mayoría de los datos en el caso de la clasificación [78].
- **Regresión Logística (LR):** La regresión logística es una técnica de ML que proviene del campo de la estadística [75].
- **Clasificador Ridge:** La regresión Ridge estima los coeficientes de los modelos de regresión múltiple en escenarios donde las variables independientes están altamente correlacionadas. Tiene aplicaciones en campos como la econometría, la química y la ingeniería [79].
- **Máquina de Vectores de Soporte - Kernel lineal (SVM):** Algoritmo basado en el aprendizaje de vectores de soporte [66] con la capacidad de realizar una clasificación binaria y multiclase en un conjunto de datos. SVM - Kernel lineal permite entradas densas y dispersas.
- **Clasificador de Refuerzo de Gradiente (GBC):** Los GBC son un grupo de algoritmos de ML que combinan muchos modelos de aprendizaje débiles para crear un modelo predictivo robusto [80].
- **Máquina de Refuerzo de Gradiente Ligero (LGBM):** LGBM es un marco de refuerzo de gradientes distribuido, gratuito y de código abierto para el ML desarrollado originalmente por Microsoft [81].

Algoritmo 5.2. Algoritmo de movimiento de manos robóticas. [autoría propia]

Algorithm 1 Training and Testing Classification Algorithm

Result: Classification Algorithm

```

for folder in DataFolders do
  for Training_Set do
    | Apply Classification_Algorithm function to
    | each row.
  end
  for Testing_Set do
    | Apply Classification_Algorithm function to
    | each row.
  end
  Export Accuracy
end

```

5.4.5 Resultados y Discusiones

En los últimos años, el desarrollo de métodos y herramientas para apoyar el reconocimiento de la EP ha aumentado. Se han utilizado varias técnicas, como el análisis de imágenes RMI, la variación de la pulsación con el dedo, y el uso de IA y las técnicas de ML y DL para el análisis de grabaciones de voz, entre otras. Todo ello para monitorear y diagnosticar el proceso de la EP de manera más eficiente. Dado que no existe una prueba específica para detectar la EP, es necesario evaluar constantemente el historial y los síntomas de los pacientes para lograr un diagnóstico preciso. Por este motivo, se generan grandes conjuntos de datos en los que algoritmos de clasificación son cruciales para determinar y discriminar entre pacientes sanos y enfermos.

Esta sección presenta los resultados obtenidos con los algoritmos de clasificación, evaluándolos en relación con los siguientes parámetros:

- Recall o Probabilidad de clasificar verdaderos positivos, calculada mediante los parámetros Verdadero Positivo (TP), Falso Negativo (FN) como se muestra en la ecuación 5.4:

$$Recall(\%) = \frac{TP}{TP + FN}. \quad (5.4)$$

- Exactitud o proximidad de los resultados, calculada mediante los parámetros Verdadero Negativo (TN), Falso Positivo (FP), Falso Negativo (FN), Verdadero Positivo (TP) como se muestra en la ecuación 5.5:

$$Accuracy(\%) = \frac{TN + TP}{TN + FP + FN + TP}. \quad (5.5)$$

- Precisión o dispersión del conjunto de valores obtenidos calculada mediante los parámetros Verdadero Positivo (TP), Falso Positivo (FP) como se muestra en la ecuación 5.6:

$$Precision(\%) = \frac{TP}{FP + TP}. \quad (5.6)$$

- F1(F-Score), utilizado para combinar las medidas de Precisión y Recuperación en un único valor, como se muestra en la ecuación 5.7:

$$F1(F - Score)(\%) = \frac{2 \times Precision \times Recall}{Precision + Recall}. \quad (5.7)$$

La tabla 5.4.5.1 muestra los resultados de la evaluación de los algoritmos de clasificación aplicados en relación con los parámetros descritos anteriormente. Se puede observar que NB alcanzó la mayor precisión con un 98,04%; MLP tuvo la mayor Recall con un 97,35%; NB tuvo la mejor Precisión y F1, con 100% y 98,61%, respectivamente. Por último, se puede afirmar que los resultados de clasificación son generalmente buenos, con el clasificador NB mostrando el mejor rendimiento y calidad sobre el resto de los algoritmos de clasificación.

Tabla 5.4.5.1 Resultados de los algoritmos de clasificación. [autoría propia]

Algoritmo	Accuracy (%)	Recall (%)	Precision (%)	F1 (%)
NB	98.04	97.35	100	98.61
MLP	96.67	98.18	97.42	97.75
RF	96.67	98.18	97.42	97.75
LR	96.00	97.27	97.42	97.22
RIDGE	96.00	97.27	97.42	97.22
SVM	94.04	93.71	98.26	95.79
GBC	94.04	95.53	96.33	95.84
LGBM	94.04	95.53	96.59	95.88

La figura 5.4.5.1 muestra la precisión y el tiempo de ejecución de los algoritmos ML utilizados en el estudio. Se evaluaron los resultados mediante validación cruzada con diez iteraciones de cada algoritmo. Los algoritmos que alcanzaron la mayor precisión fueron NB y MLP con tiempos de ejecución cortos. Del mismo modo, los algoritmos con menor precisión fueron SVM, GBC y LGBM. En general, los resultados de clasificación fueron buenos. Los algoritmos fueron muy precisos y con tiempos de ejecución cortos tiempos de ejecución.

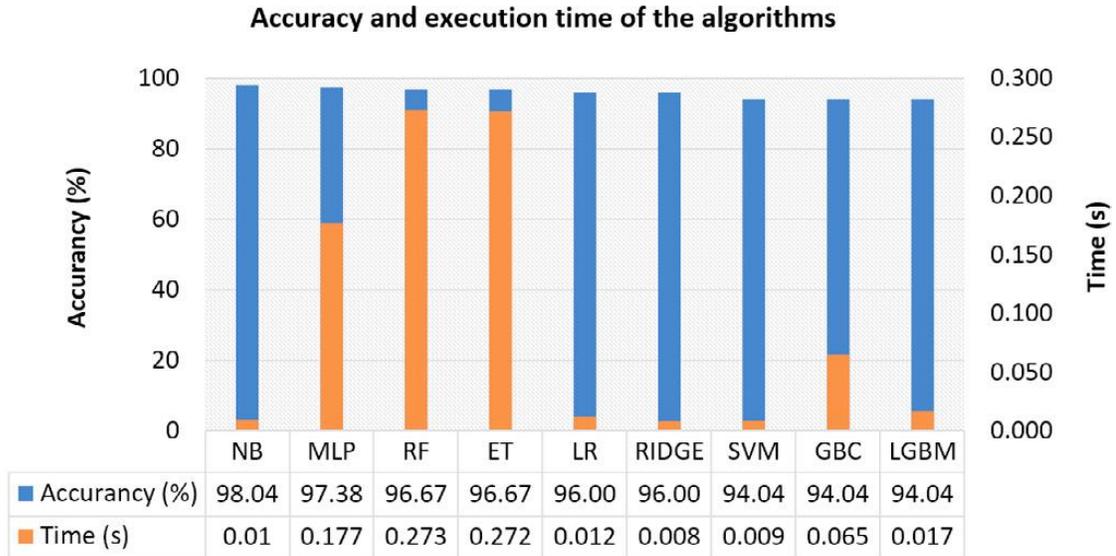


Figura 5.4.5.1 Precisión y tiempo de ejecución de los mejores algoritmos de ML de los mejores algoritmos. [autoría propia]

La matriz de confusión de la figura 5.4.5.2 muestra los falsos positivos que el algoritmo NB clasificó, siendo las casillas superior izquierda e inferior derecha son las predicciones correctas y las superior derecha e inferior izquierda, los errores o falsos positivos.

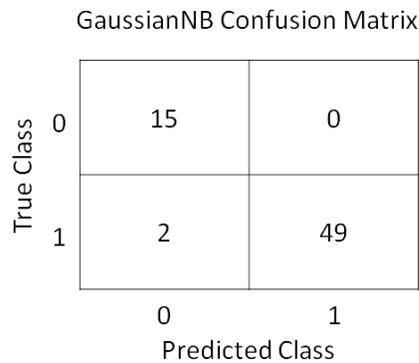


Figura 5.4.5.2 Matriz de confusión. [autoría propia]

La Curva Característica de Funcionamiento del Receptor (ROC) de la figura 5.4.5.3 representa los errores de los algoritmos NB en función de sus falsos positivos y negativos. La ROC es una métrica que evalúa algoritmos de IA.

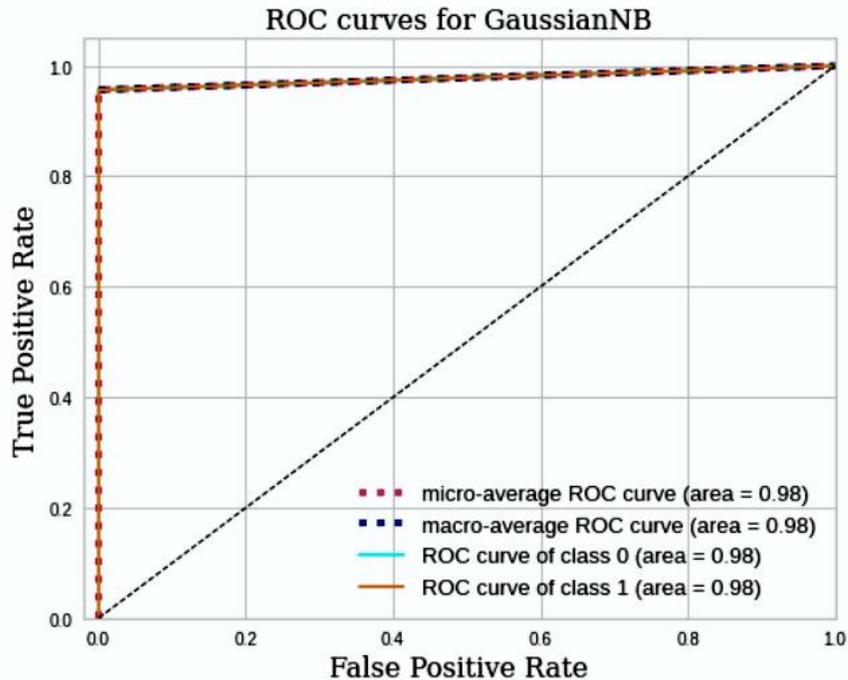


Figura 5.4.5.3 Curva de características operativas del receptor de NB. [autoría propia]

5.5 Conclusiones

A continuación, se presentan las conclusiones que buscan responder a la pregunta ¿Qué algoritmo de aprendizaje automático será eficaz para el análisis EEG-BCI en la detección de las intenciones motoras de las extremidades inferiores?, para cada una de las secciones detalladas anteriormente.

5.5.1 Clasificación de una tarea motora imaginaria y una tarea motora en extremidades inferiores

Cuando se utilizan datos de señales temporales de EEG, es importante seleccionar las características apropiadas que permitan una representación adecuada de los eventos a clasificar, pero si la aplicación utiliza recursos de hardware limitados, las características no deben tener un alto coste computacional para ser extraídas de los datos en bruto. En este caso, la red neuronal de tres capas con 30 neuronas en la capa oculta, tuvo un mejor rendimiento detectando eventos IE2 (93,8%) frente a ME2 (92,1%) en este sistema de clasificación basado en FPGA; esto nos permitirá utilizar datos de tareas motoras imaginarias para controlar prótesis de personas que han perdido algún miembro, o que debido a accidentes, han sufrido daños en la médula espinal y ya no pueden utilizar otros

miembros de asistencia; además, podríamos controlar la rehabilitación de equipos de asistencia, en sujetos con habilidades motoras residuales.

Los tiempos de procesamiento y el total de recursos utilizados en la FPGA son lo suficientemente óptimos para ejecutar NN de datos caracterizados, y luego poder clasificarlos en tiempo casi real; sin embargo, el tiempo de caracterización de los datos con PSD hace que el tiempo total de clasificación de la red aumente a 5 segundos.

5.5.2 Detección de intensiones motoras de extremidades superiores e inferiores basado en combinación de algoritmos supervisados y no supervisados

Se observa que la ubicación de los electrodos para cada tarea coincide con la ubicación de las extremidades en el homúnculo de Penfield: para M1, los electrodos se concentran en el extremo de la corteza motora y somatosensorial; para M2 en la parte central del cerebro. La localización también coincide con las áreas de Brodmann para el movimiento motor imaginario y tareas visuales imaginarias.

La clasificación basada en las señales captadas a través de los electrodos que están correlacionadas en el tiempo es posible. El modelo de clasificación permitió interpretar los movimientos imaginarios del sujeto con una precisión del 93,7%, que luego serán trasladados a la mano protésica.

El tiempo de procesamiento y la cantidad total de recursos utilizados en la FPGA son lo suficientemente óptimos para ejecutar la red neuronal MLP y clasificar los datos en aproximadamente 8,8 μ s.

5.5.3 Algoritmos de clustering en la detección de tareas motoras e imagenéticas motoras de señales EEG

La implementación del sistema propuesto muestra que los datos EMG son suficientes para realizar clasificaciones de gestos utilizando sólo 8 sensores y 1 característica por sensor. Empleando muy pocos recursos de hardware de la plataforma evaluada el sistema logró un mínimo garantizado del 93,4% de precisión y teniendo menos del 1% de puntos no clasificables. Los resultados mostraron que la implementación simple de ingeniería de características junto con KNN puede proporcionar un sistema de reconocimiento de gestos portátil y preciso para dispositivos con recursos limitados. Además, la presente propuesta

requiere tiempos de entrenamiento cortos y características totalmente personalizables, lo que permite una mejor interacción con el usuario. Aunque el dispositivo MYO dispone de otros sensores, como un giroscopio y un acelerómetro, no se utilizaron para mantener una baja complejidad computacional y garantizar la fácil migración y el sistema embebido para que sea portátil y llevable. Actualmente, se están realizando pruebas del sistema con más sujetos, para determinar qué características son adecuadas en la detección de tareas motoras mediante el dispositivo MYO, y además se espera probar otros algoritmos de aprendizaje supervisado y no supervisado para determinar la idoneidad de la implementación en sistemas embebidos basados en FPGA, empleando como métrica principal el consumo de macroceldas y la precisión de la detección.

5.5.4 Clasificación de sujetos con enfermedad de Parkinson

La EP es uno de los trastornos neurodegenerativos más comunes, que afecta a millones de personas en todo el mundo. Utilizando técnicas de ML, se logró la capacidad de clasificar a los pacientes con EP con una precisión del 98,04%.

Los resultados muestran que utilizar 48 características para cada participante fue adecuado, ya que se obtuvieron valores de precisión superiores al 98%. Como se muestra en la figura 5.4.5.1, los nueve algoritmos NB, MLP, RF, ET, LR, RIDGE, SVM, GBC y LGBM mostraron valores de precisión del 98,04%, 97,38%, 96,67%, 96%, 94,04%, 94,04% y 94,04%, respectivamente. Las aplicaciones que necesitan alta precisión podrían utilizar los algoritmos NB o MLP. Por otro lado, para las aplicaciones que necesitan respuestas en tiempo real, los algoritmos que presentan tiempos de ejecución más cortos son SVM y NB (valores de unos 10 ns).

La implementación de modelos de aprendizaje autónomo en la clasificación de pacientes con EP mostró resultados positivos, especialmente el modelo NB. Según nuestros resultados, los algoritmos NB son mejores que las redes neuronales a la hora de clasificar sujetos de control.

Se recomienda preprocesar los datos ampliamente porque un conjunto de datos más limpio mejora la precisión de la predicción cuando se trabaja con algoritmos de clasificación. En cuanto al trabajo futuro se propone añadir una etapa de selección automática de características para identificar las características que contribuyen a los clasificadores. Además, se sugiere utilizar métodos basados en DeepLearning como clasificadores. Por

último, se propone emplear el filtro Hampel para el preprocesamiento de las señales de EEG.

5.6 Publicaciones

El estudio desarrollado para la detección de intenciones motoras de extremidades inferiores basados en algoritmos de aprendizaje supervisado, presentado en este capítulo dio como resultado un artículo científico titulado: "Implementation of a Classification System of EEG Signals Based on FPGA", el que fué presentado en el eDemocracy & eGovernment (ICEDEG) en Buenos Aires Argentina, en el 2020 [1].

La combinación de los algoritmos de aprendizaje no supervisado junto con algoritmos de aprendizaje supervisado permitió realizar la detección en tiempo real de intenciones motoras en extremidades superiores e inferiores. Los resultados fueron publicados en el artículo científico titulado: "BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control", el mismo que fue presentado el 2021 en el "International Federation of Automatic Control (IFAC) Symposium on Biological and Medical Systems (BMS)" en la universidad de Ghent en Bélgica [2].

Otro trabajo en el que se utilizó algoritmos de aprendizaje supervisado en combinación con señales de EMG, permitió realizar la detección de 9 gestos realizados con mano. Los resultados fueron publicados en el artículo científico titulado: "K-NN-Based EMG Recognition for Gestures Communication with Limited Hardware Resources", el mismo que fue presentado el 2019 en el congreso "SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)" en Leicester, United Kingdom [3].

Finalmente, los algoritmos de aprendizaje supervisado fueron utilizados con datos de tecleando con el dedo de sujetos sanos y paciente con EP. Los resultados demostraron que es posible detectar sujetos que padecen EP es su etapa temprana de desarrollo. Los resultados fueron publicados en el artículo científico titulado: "Classification of Subjects with Parkinson's Disease using Finger Tapping Dataset", el mismo que fue presentado el 2021 en el "International Federation of Automatic Control (IFAC) Symposium on Biological and Medical Systems (BMS)" en la universidad de Ghent en Bélgica [4].

5.7 Bibliografía

- [1] Asanza, V.; Constantine, A.; Valarezo, S.; Peláez, E. Implementation of a Classification System of EEG Signals Based on FPGA. 2020 Seventh International Conference on eDemocracy eGovernment (ICEDEG), 2020, pp. 87–92. Doi:10.1109/ICEDEG48599.2020.9096752.
- [2] Constantine, A., Asanza, V., Loayza, F. R., Peláez, E., & Peluffo-Ordóñez, D. (2021). BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control. *IFAC-PapersOnLine*, 54(15), 364-369.
- [3] C. Cedeño Z., J. Cordova-Garcia, V. Asanza A., R. Ponguillo and L. Muñoz M., "k-NN-Based EMG Recognition for Gestures Communication with Limited Hardware Resources," 2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI), Leicester, United Kingdom, 2019, pp. 812-817.
- [4] Asanza, V., Sánchez-Pozo, N. N., Lorente-Leyva, L. L., Peluffo-Ordóñez, D. H., Loayza, F. R., & Peláez, E. (2021). Classification of Subjects with Parkinson's Disease using Finger Tapping Dataset. *IFAC-PapersOnLine*, 54(15), 376-381.
- [5] Ruiz-Rosero, J., Ramirez-Gonzalez, G., & Khanna, R. (2019). Field programmable gate array applications—a scientometric review. *Computation*, 7(4), 63.
- [6] Harris, S., & Harris, D. (2015). *Digital design and computer architecture: arm edition*. Morgan Kaufmann.
- [7] Reaz, M. B. I, Hussain, M. S. and Mohd-Yasin, F., "Techniques of EMG signal analysis: detection, processing, classification and applications", *Biological Procedures Online*, vol. 8, no. 1, 2006.
- [8] Britton JW, Frey LC, Hopp JLet al., authors; St. Louis EK, Frey LC, editors. *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants* [Internet]. Chicago: American Epilepsy Society; 2016
- [9] Gordleeva, S. Y., Lukoyanov, M. V., Mineev, S. A., Khoruzhko, M. A., Mironov, V. I., Kaplan, A. Y., & Kazantsev, V. B. (2017). Exoskeleton control system based on motor-imaginary brain-computer interface.
- [10] Shin, Y. K., Lee, D. R., Hwang, H. J., You, S. J. H., & Im, C. H. (2012). A novel EEG-based brain mapping to determine cortical activation patterns in normal children and children with cerebral palsy during motor imagery tasks. *NeuroRehabilitation*, 31(4), 349-355.
- [11] Bashivan, P., Rish, I., Yeasin, M., & Codella, N. (2015). Learning representations from EEG with deep recurrent-convolutional neural networks. *arXiv preprint arXiv:1511.06448*
- [12] Zhang, Y., Liu, B., Ji, X., & Huang, D. (2017). Classification of EEG signals based on autoregressive model and wavelet packet decomposition. *Neural Processing Letters*, 45(2), 365-378.
- [13] Subasi, A., & Gursoy, M. I. (2010). EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert systems with applications*, 37(12), 8659-8666.
- [14] Bastos-Filho, T., Floriano, A., Couto, E., & Godinez-Tello, R. J. (2018). Towards a system to command a robotic wheelchair based on independent SSVEP-BCI. In *Smart Wheelchairs and Brain-Computer Interfaces* (pp. 369-379).
- [15] Becerra, M. A., Londoño-Delgado, E., Pelaez-Becerra, S. M., Castro-Ospina, A. E., Mejia-Arboleda, C., Durango, J., & Peluffo-Ordóñez, D. H. (2018, September). Electroencephalographic

Signals and Emotional States for Tactile Pleasantness Classification. In International Workshop on Artificial Intelligence and Pattern Recognition (pp. 309-316). Springer, Cham.

[16] Tello, R. M., Müller, S. M., Hasan, M. A., Ferreira, A., Krishnan, S., & Bastos, T. F. (2016). An independent-BCI based on SSVEP using Figure-Ground Perception (FGP). *Biomedical Signal Processing and Control*, 26, 69-79.

[17] Iandola, F., & Keutzer, K. (2017, October). Small neural nets are beautiful: enabling embedded systems with small deep-neural-network architectures. In Proceedings of the Twelfth IEEE/ACM/IFIP International Conference on Hardware/Software Codesign and System Synthesis Companion (p. 1). ACM.

[18] Rodríguez-Sotelo, J., Osorio-Forero, A., Jiménez-Rodríguez, A., Cuesta-Frau, D., Cirugeda-Roldán, E., & Peluffo, D. (2014). Automatic sleep stages classification using EEG entropy features and unsupervised pattern analysis techniques. *Entropy*, 16(12), 6573-6589.

[19] Lisi, G., Noda, T., & Morimoto, J. (2014). Decoding the ERD/ERS: influence of afferent input induced by a leg assistive robot. *Frontiers in systems neuroscience*, 8, 85.

[20] Castillo-Garcia, J. F., Caicedo-Bravo, E. F., & Bastos, T. F. (2018). Adaptive Spontaneous Brain-Computer Interfaces Based on Software Agents. *Advances in Data Science and Adaptive Analysis*.

[21] Gao, Z. K., Cai, Q., Yang, Y. X., Dong, N., & Zhang, S. S. (2017). Visibility graph from adaptive optimal kernel time-frequency representation for classification of epileptiform EEG. *International Journal of Neural Systems*, 27(04), 1750005.

[22] Schirmer, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., ... & Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human brain mapping*, 38(11), 5391-5420.

[23] Becerra, M. A., Londoño-Delgado, E., Pelaez-Becerra, S. M., Serna-Guarín, L., Castro-Ospina, A. E., Marin-Castrillón, D., & Peluffo-Ordóñez, D. H. (2018, September). Odor Pleasantness Classification from Electroencephalographic Signals and Emotional States. In Colombian Conference on Computing (pp. 128-138). Springer, Cham.

[24] Movahedi, F., Coyle, J. L., & Sejdić, E. (2018). Deep belief networks for electroencephalography: A review of recent contributions and future outlooks. *IEEE journal of biomedical and health informatics*, 22(3), 642-652.

[25] Ordóñez, F. J., & Roggen, D. (2016). Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, 16(1), 115.

[26] Murad, A., & Pyun, J. Y. (2017). Deep recurrent neural networks for human activity recognition. *Sensors*, 17(11), 2556.

[27] Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering* 51(6):1034-1043, 2004.

[28] Kenny, R., & Watt, J. (2016). The breakthrough advantage for FPGAs with Tri-Gate technology. URL: https://www.altera.com/en_US/pdfs/literature/wp/wp-01201-fpga-tri-gate-technology.pdf (дата обращения: 12.10. 2017).

[29] McDonald, C.L., Westcott-McCoy, S., Weaver, M.R., Haagsma, J., and Kartin, D. (2020). Global prevalence of traumatic non-fatal limb amputation. *Prosthetics and Orthotics International*, 0(0), 0309364620972258. doi: 10.1177/0309364620972258.

[30] Zilles, K. (2018). Brodmann: a pioneer of human brain mapping—his impact on concepts of cortical organization. *Brain*, 141(11), 3262–3278. doi:10.1093/brain/awy273.

- [31] Osborn, L.E., Dragomir, A., Betthausen, J.L., Hunt, C.L., Nguyen, H.H., Kaliki, R.R., and Thakor, N.V. (2018). Prosthesis with neuromorphic multilayered e-skin perceives touch and pain. *Science Robotics*, 3(19), eaat3818. doi:10.1126/scirobotics.aat3818.
- [32] Petrini, F., Mazzoni, A., Rigosa, J., Giambattistelli, F., Granata, G., Barra, B., Pampaloni, A., Guglielmelli, E., Zollo, L., Capogrosso, M., Micera, S., and Raspopovic, S. (2019). Microneurography as a tool to develop de-coding algorithms for peripheral neuro-controlled hand prostheses. *BioMedical Engineering OnLine*, 18. doi: 10.1186/s12938-019-0659-9.
- [33] Zhang, T., Jiang, L., and Liu, H. (2018). Design and functional evaluation of a dexterous myoelectric hand prosthesis with biomimetic tactile sensor. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(7), 1391–1399. doi:10.1109/TNSRE.2018.2844807.
- [34] Parr, J.V.V., Vine, S.J., Wilson, M.R., Harrison, N.R., and Wood, G. (2019). Visual attention, EEG alpha power and t7-fz connectivity are implicated in prosthetic hand control and can be optimized through gaze training. *Journal of NeuroEngineering and Rehabilitation*, 16(1). doi:10.1186/s12984-019-0524-x.
- [35] Asanza, V., Peláez, E., Loayza, F., Mesa, I., Díaz, J., and Valarezo, E. (2018). Emg signal processing with clustering algorithms for motor gesture tasks. In 2018 IEEE Third Ecuador Technical Chapters Meeting (ETCM), 1– 6. doi:10.1109/ETCM.2018.8580270.
- [36] Becerra, M.A., Londoño-Delgado, E., Botero-Henao, O.I., Marín-Castrillón, D., Mejía-Arboleda, C., and Peluffo-Ordóñez, D.H. (2019). Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), volume 11466 LNBI, inbook Low Resolution Electroencephalographic-Signals-Driven Semantic Retrieval: Preliminary Results, 333–342. Springer Verlag.
- [37] Fuentes-Gonzalez, J., Infante-Alarcón, A., Asanza, V., and Loayza, F.R. (2021). A 3d-printed eeg based prosthetic arm. In 2020 IEEE International Conference on E-health Networking, Application Services (HEALTH-COM), 1–5. doi:10.1109/HEALTHCOM49281.2021.9399035.
- [38] Goldberger, A.L., Amaral, L.A.N., Glass, L., Hausdorff, J.M., Ivanov, P.C., Mark, R.G., Mietus, J.E., Moody, G.B., Peng, C.K., and Stanley, H.E. (2000). PhysioBank, PhysioToolkit, and PhysioNet. *Circulation*, 101(23). doi:10.1161/01.cir.101.23.e215.
- [39] Armijos, V.A., Chan, N.S., Saquicela, R., and Lopez, L.M. (2020). Monitoring of system memory usage embedded in fpga. In 2020 International Conference on Applied Electronics (AE), 1–4. doi:10.23919/AE49394.2020.9232863.
- [40] Schalk, G., McFarland, D., Hinterberger, T., Birbaumer, N., and Wolpaw, J. (2004). BCI2000: A general-purpose brain-computer interface (BCI) system. *IEEE Transactions on Biomedical Engineering*, 51(6), 1034–1043. doi: 10.1109/tbme.2004.827072.
- [41] Bansal, D. and Mahajan, R. (2019). Chapter 2 - eeg-based brain-computer interfacing (bci). In *EEG-Based Brain-Computer Interfaces*, 21–71. Academic Press. doi: <https://doi.org/10.1016/B978-0-12-814687-3.00002-8>.
- [42] Sinaga, K.P. and Yang, M.S. (2020). Unsupervised k-means clustering algorithm. *IEEE Access*, 8, 80716– 80727. doi:10.1109/ACCESS.2020.2988796.
- [43] Zaki, M.J. and Meira, W. (2014). *Data Mining and Analysis: Fundamental Concepts and Algorithms*. Cambridge University Press, USA.
- [44] Rezankov'a, H. (2018). Different approaches to the silhouette coefficient calculation in cluster evaluation. In 21st International Scientific Conference AMSE Applications of Mathematics and Statistics in Economics 2018, 1–10.

- [45] Artoni, F., Delorme, A., and Makeig, S. (2018). Applying dimension reduction to EEG data by principal component analysis reduces the quality of its subsequent independent component decomposition. *NeuroImage*, 175, 176–187. doi:10.1016/j.neuroimage.2018.03.016.
- [46] Svozil, D., Kvasnicka, V., and Pospíchal, J. (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and Intelligent Laboratory Systems*, 39, 43–62.
- [47] Mary R. Power, Des Power, Louise Horstmanhof; Deaf People Communicating via SMS, TTY, Relay Service, Fax, and Computers in Australia, *The Journal of Deaf Studies and Deaf Education*, Volume 12, Issue 1, 1 January 2007, Pages 8092, <https://doi.org/10.1093/deafed/enl016>.
- [48] Koon, R. A., Vega, M. E. (s.f.). Atencin a la diversidad. Obtenido de <http://diversidad.murciaeduca.es/tecnoneet/docs/2000/14-2000.pdf>.
- [49] Phinyomark, A., Scheme, E. (2018, March). A feature extraction issue for myoelectric control based on wearable EMG sensors. In 2018 IEEE Sensors Applications Symposium (SAS) (pp. 1-6). IEEE.
- [50] Mithileysh Sathiyarayanan, Sharanya Rajan, 2016 ,MYO Armband for physiotherapy healthcare: A case study using gesture recognition application, 2016 8th International Conference on Communication Systems and Networks (COMSNETS) ISBN 978-1-4673-9622-6
- [51] Liu, L. (2018). Acceleration of k-Nearest Neighbor and SRAD Algorithms Using Intel FPGA SDK for OpenCL.
- [52] Board, A. D. Version 1.00 Copyright 2009 Terasic Technologies.
- [53] Fabrizio Eloy Ramirez, Marco Segura-Morales, Marco Benalczar, 2018 ,Design of a Software Architecture and Practical Applications to Exploit the Capabilities of a Human Arm Gesture Recognition System, 2018 IEEE Third Ecuador Technical Chapters Meeting (ETCM) ISBN 978-1-5386-6657-9
- [54] Vctor Asanza, Enrique Pelez, Francis Loayza, Iker Mesa, Javier Daz, Edwin Valarezo, 2018 ,EMG Signal Processing with Clustering Algorithms for motor gesture Tasks, 2018 IEEE Third Ecuador Technical Chapters Meeting (ETCM) ISBN 978-1-5386-6657-9
- [55] Seema Rawat, Somya Vats, and Praveen Kumar. 2016. Evaluating and exploring the MYO ARMBAND. In 2016 International Conference System Modeling Advancement in Research Trends (SMART). DOI=<http://dx.doi.org/10.1109/SYSMART.2016.7894501>
- [56] Cover, T. M., Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.
- [57] Urcuqui, C., Castaño, Y., Delgado, J., Navarro, A., Diaz, J., Muñoz, B., and Orozco, J. (2018, September). Exploring machine learning to analyze parkinson's disease patients. In 2018 14th International Conference on Semantics, Knowledge and Grids (SKG), 160–166.
- [58] Maccarrone, M. (2020). Missing pieces to the endocannabinoid puzzle. *Trends in molecular medicine*, 26(3), 263–272.
- [59] Sveinbjornsdottir, S. (2016). The clinical symptoms of parkinson's disease. *Journal of neurochemistry*, 130, 318–324.
- [60] Brown, E.G. and Goldman, S.M. (2020). Modulation of the microbiome in parkinson's disease: Diet, drug, stool transplant, and beyond. *Neurotherapeutics*, 1–12.
- [61] Farahani, B., Firouzi, F., Chang, V., Badaroglu, M., Constant, N., and Mankodiya, K. (2018). Towards fogdriven iot ehealth: Promises and challenges of iot in medicine and healthcare. *Future Generation Computer Systems*, 78, 659–676.

- [62] Lau, A.Y. and Staccini, P. (2019). Artificial intelligence in health: New opportunities, challenges, and practical implications. *Yearbook of medical informatics*, 28(01), 174–178.
- [63] Bhatti, D., Thompson, R., Hellman, A., Penke, C., Bertoni, J.M., and Torres-Russotto, D. (2017). Smartphone apps provide a simple, accurate bedside screening tool for orthostatic tremor. *Movement disorders clinical practice*, 4(6), 852–857.
- [64] Goldberger, A.L., Amaral, L.A., Glass, L., Hausdorff, J.M., Ivanov, P.C., Mark, R.G., Mietus, J.E., Moody, G.B., Peng, C.K., and Stanley, H.E. (2000). Physiobank, physiokit, and physionet: components of a new research resource for complex physiologic signals. *circulation*, 101(23), e215–e220.
- [65] Rodríguez-Cruz, A., Romo-Mancillas, A., Mendiola-Precoma, J., Escobar-Cabrera, J.E., García-Alcocer, G., and Berumen, L.C. (2020). Effect of valerianic acid on neuroinflammation in a mptp-induced mouse model of parkinson's disease. *IBRO reports*, 8, 28–35.
- [66] Chen, Y., Zhu, G., Liu, D., Liu, Y., Yuan, T., Zhang, X., Jiang, Y., Du, T., and Zhang, J. (2020). The morphology of thalamic subnuclei in parkinson's disease and the effects of machine learning on disease diagnosis and clinical evaluation. *Journal of the neurological sciences*, 411, 116721.
- [67] Shah, S.A.A., Zhang, L., and Bais, A. (2020). Dynamical system based compact deep hybrid network for classification of parkinson disease related eeg signals. *Neural Networks*, 130, 75–84.
- [68] Bastidas, D., Piñeros, C., Peluffo-Ordóñez, D.H., Sierra, L.M., Becerra, M.A., and Umaquina-Criollo, A.C. (2020). Analytic study on the performance of multiclassification approaches in case-based reasoning systems: Medical data exploration. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*.
- [69] Germine, L., Strong, R.W., Singh, S., and Sliwinski, M.J. (2021). Toward dynamic phenotypes and the scalable measurement of human behavior. *Neuropsychopharmacology*, 46(1), 209–216.
- [70] Pereira, C.R., Pereira, D.R., Rosa, G.H., Albuquerque, V.H., Weber, S.A., Hook, C., and Papa, J.P. (2018). Handwritten dynamics assessment through convolutional neural networks: An application to parkinson's disease identification. *Artificial intelligence in medicine*, 87, 67–77.
- [71] Wroge, T.J., Özkanca, Y., Demiroglu, C., Si, D., Atkins, D.C., and Ghomi, R.H. (2018, December). Parkinson's disease diagnosis using machine learning and voice. In *2018 IEEE signal processing in medicine and biology symposium. (SPMB)*, 1–7.
- [72] Hariharan, M., Polat, K., and Sindhu, R. (2014). A new hybrid intelligent system for accurate detection of parkinson's disease. *Computer methods and programs in biomedicine*, 113(3), 904–913.
- [73] Sadek, R.M., Mohammed, S.A., Abunbehan, A.R.K., Ghattas, A.K.H.A., Badawi, M.R., Mortaja,
- [74] Wang, T., Zhang, D., Wang, Z., Jia, J., Ni, H., and Zhou, X. (2015, August). Recognizing gait pattern of parkinson's disease patients based on fine-grained movement function features. In *2015 IEEE 12th Intl Conf on Ubiquitous Intelligence and Computing and 2015 IEEE 12th Intl Conf on Autonomic and Trusted Computing and 2015 IEEE 15th Intl Conf on Scalable Computing and Communications and Its Associated Workshops (UICATC-ScalCom)*, 1–10.
- [75] Abedin, M.M., Maniruzzaman, M., Ahmed, N.F., Ahammed, B., and Ali, M. (2019). Classification and prediction of parkinson disease: A machine learning approach. In *International Conference Data Science and SDGs: Challenges, Opportunities and Realities*.
- [76] Asanza, V., Sanchez, G., Cajo, R., and Peláez, E. (2020). Behavioral signal processing with machine learning based on fpga. In *International Conference on Systems and Information Sciences*, 196–207. Springer.

- [77] Asanza, V., Martin, C.A., Eslambolchilar, P., van Woerden, H., Cajo, R., and Salazar, C. (2017). Finding a dynamical model of a social norm physical activity intervention. In 2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM), 1–6. doi:10.1109/ETCM.2017.8247450.
- [78] Shtar, G., Rokach, L., Shapira, B., Nissan, R., and Hershkovitz, A. (2021). Using machine learning to predict rehabilitation outcomes in postacute hip fracture patients. *Archives of physical medicine and rehabilitation*, 102(3), 386–394.
- [79] Singh, A., Prakash, B.S., and Chandrasekaran, K. (2016). A comparison of linear discriminant analysis and ridge classifier on twitter data. In 2016 International Conference on Computing, Communication and Automation (ICCCA), 133–138. IEEE.
- [80] Karabayir, I., Goldman, S.M., Pappu, S., and Akbilgic, O. (2020). Gradient boosting for parkinson's disease diagnosis from voice recordings. *BMC Medical Informatics and Decision Making*, 20(1), 1–7.
- [81] Chun, P.j., Izumi, S., and Yamane, T. (2021). Automatic detection method of cracks from concrete surface imagery using two-step light gradient boosting machine. *Computer-Aided Civil and Infrastructure Engineering*, 36(1), 61–72.

6 Capítulo 6: Conclusiones generales

La mayoría de los sujetos con Parálisis Cerebral Infantil (PCI) no tienen la capacidad de controlar sus extremidades, y es compleja la medición de las señales biomédicas que les permiten controlar los dispositivos, a través de los cuales se busca mitigar los efectos de su enfermedad [1,2]. A diferencia de las señales de Electromiografía (EMG) que requieren un esfuerzo muscular para generar bioseñales [3,4], las señales de Electroencefalografía (EEG) pueden generar actividad eléctrica relacionada a intenciones motoras, sin necesidad de realizar dicha tarea [5].

El método de registro de señales EEG superficiales es uno de los métodos más accesibles y no invasivos para el desarrollo de prototipos, debido a su bajo coste y el riesgo casi nulo para el paciente [6], pues están disponibles en el mercado diversos dispositivos que cumplen con el estándar internacional 10-10 (para la distribución de sus electrodos), los que permitieron su utilización inmediata en la implementación de los prototipos y bancos de prueba de nuestros algoritmos, con resultados lo suficientemente buenos para el análisis, discusión y comparación de resultados, tal como se describió en el capítulo 3.

En los capítulos 3, 4 y 5, se presenta un mecanismo de Reconocimiento de Patrones (RP) [7] compuesto principalmente por etapas, que va desde la adquisición de datos, preprocesamiento, extracción de características, hasta su clasificación. El capítulo 3 está relacionado con la etapa de adquisición de datos y responde a la pregunta ¿Cómo podría detectarse el patrón de actividad motora cortical de los sujetos con Parálisis Cerebral Infantil (PCI) al realizar tareas de intención motora de las extremidades inferiores?.

El capítulo 4 está relacionado con la etapa de extracción de características y da respuesta a la pregunta ¿Cómo podrían adaptarse los actuales algoritmos de caracterización utilizados en EEG-BCI para extraer las características adecuadas de las intenciones motoras de las extremidades inferiores?.

Finalmente, el capítulo 5 está relacionado con la etapa de clasificación y se da respuesta a la pregunta ¿Qué algoritmo de aprendizaje autónomo será eficaz para el análisis del EEG-BCI en la detección de las intenciones motoras de las extremidades inferiores?.

En cuanto al registro de señales EEG, se han establecido las siguientes tareas que realizan los sujetos de prueba, las cuales permiten adquirir datos de forma directa desde los

electro nodos, algunas de las cuales fueron requeridas para el análisis y búsqueda de las respuestas a nuestras preguntas de investigación: a) movimientos activos, y b) imagenético motor [8].

Para dar respuesta a la primera pregunta de investigación, se realizó un diseño experimental que permitió el registro de la actividad motora en extremidades inferiores, empleando tareas que incluyeron los movimientos activos e imagenético motor. Se descartaron los movimientos asistidos y estímulos eléctricos de miembros inferiores, debido a la restricción de movilidad para los sujetos que padecen PCI. La metodología experimental desarrollada en el capítulo 3 demuestra ser útil en el registro de señales EEG no invasiva, tanto para sujeto sanos, sujetos con amputación en extremidades superiores, sujetos con amputación en extremidades inferiores, así como en sujetos con PCI leve. Los resultados nos demuestran que sí es posible realizar la detección de intenciones motoras en sujetos con PCI, llegando a obtener una precisión de hasta un 74.6%. El dataset generado en esta investigación, se encuentra disponible en el siguiente enlace: <https://data.mendeley.com/datasets/w9xfz56txv/2> [9]; además, nos permitió producir el artículo titulado “MILimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motor Imagery Tasks”, el mismo que fue enviado a la revista MDPI DATA (www.mdpi.com/journal/data), y actualmente está en proceso de revisión.

En cuanto a la detección de intenciones motoras en extremidades inferiores empleando señales EEG, algunas de las características utilizadas fueron extraídas desde el dominio del tiempo, así como del análisis espectral de potencia, y basados en el análisis de correlación [8]. Para dar respuesta a la segunda pregunta de investigación, en el capítulo 4 se presenta la extracción de características de señales EEG, que permitieron hacer la detección de diferentes tareas, que incluye la actividad motora e imaginaria de las extremidades superiores e inferiores. En la sección 4.1, se demuestra el uso de características basadas en el análisis espectral de potencia, pese al uso de algoritmos de aprendizaje no supervisado, los features demostraron ser bastante buenos logrando obtener hasta un 87% de precisión en la detección de las tareas motoras de ambos pies [10]. Estos resultados fueron publicados en el artículo titulado “EEG signal clustering for motor and imaginary motor tasks on hands and feet”, que fue presentado en el Congreso “IEEE Second Ecuador Technical Chapters Meeting” (ETCM - 2017) [10]. Por otro lado, las

características temporales y basadas en un análisis de correlación han demostrado ser eficaces en la selección de electrodos EEG, que presentan actividad durante la ejecución de una tarea motora ya sea en extremidades superiores o inferiores [11]. Los resultados fueron publicados en el artículo científico titulado: “BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control”, el mismo que fue presentado el 2021 en el “International Federation of Automatic Control (IFAC) Symposium on Biological and Medical Systems (BMS)”, en Ghent - Bélgica [11].

Por otro lado, en cuanto a la detección de señales EEG relacionadas a intenciones motoras en extremidades inferiores, los algoritmos de clasificación utilizados se basaron en las Redes Neuronales (NN) [8]. En el capítulo 5 se da respuesta a la tercera pregunta de investigación y se presenta el uso de una NN que tuvo una precisión de 93.8%; por otro lado, en la detección de la actividad motora de ambos pies se obtuvo una precisión de 92,1%; esto nos demuestra la factibilidad de detectar intenciones motoras en extremidades inferiores, las que permiten controlar prótesis de personas que han perdido algún miembro, o que debido a accidentes, han sufrido daños en la médula espinal y ya no pueden utilizar otros mecanismos de asistencia; además, controlar equipos de asistencia en la rehabilitación de sujetos con habilidades motoras residuales [12]. Los resultados de este estudio desarrollado para la detección de intenciones motoras de extremidades inferiores, basados en algoritmos de aprendizaje supervisado, fueron publicados en el artículo científico titulado: “Implementation of a Classification System of EEG Signals Based on FPGA”, el cual fue presentado en el Congreso eDemocracy & eGovernment (ICEDEG) en Buenos Aires Argentina, en el 2020 [12].

Los resultados presentados en esta investigación doctoral, permiten tener un mejor entendimiento de la detección de intenciones motoras en extremidades inferiores que permitirán mejorar la calidad de vida de las personas que sufren limitaciones de movilidad.

El uso de una metodología experimental basada en actividades motoras e imagenéticas motoras de extremidades inferiores permiten hacer un adecuado registro de señales EEG. Mediante el uso del sistema RP, en la etapa de extracción de características el uso de características basadas en Densidad Espectral en combinación con un análisis temporal de las características mejora la interpretabilidad de los datos.

Finalmente, en el uso de los algoritmos de detección queda demostrado la superioridad de los algoritmos de aprendizaje supervisado vs. los algoritmos de aprendizaje no supervisado, siendo uno de los algoritmos más utilizados las NN.

6.1 Bibliografía

- [1] Mattern-Baxter, K. (2009). Effects of partial body weight supported treadmill training on children with cerebral palsy. *Pediatric physical therapy*, 21(1), 12-22.
- [2] Grecco, L. A. C., Zanon, N., Sampaio, L. M. M., & Oliveira, C. S. (2013). A comparison of treadmill training and overground walking in ambulant children with cerebral palsy: randomized controlled clinical trial. *Clinical rehabilitation*, 0269215513476721.
- [3] Toledo-González M. Concepto. Etiología. Alto riesgo del recién nacido. In Toledo González M, ed. *Parálisis cerebral*. Madrid: Departamento de estudios y publicaciones del SEREM; 1977. p. 25-45.
- [4] Bringas-Grande, A., Fernández-Luque, A., García-Alfaro, C., Barrera-Chacon, M., Toledo-Gonzalez, M., & Domínguez Roldan, J. M. (2002). Parálisis cerebral infantil: estudio de 250 casos. *Rev Neurol*, 35(9), 812-17.
- [5] Guger, C., Schlogl, A., Neuper, C., Walterspacher, D., Strein, T., & Pfurtscheller, G. (2001). Rapid prototyping of an EEG-based brain-computer interface (BCI). *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 9(1), 49-58.
- [6] Guger, C., Daban, S., Sellers, E., Holzner, C., Krausz, G., Carabalona, R., ... & Edlinger, G. (2009). How many people are able to control a P300-based brain-computer interface (BCI)?. *Neuroscience letters*, 462(1), 94-98.
- [7] Lee, J. J., Lee, D. R., Kyum Shin, Y., Lee, N. G., Han, B. S., & You, S. J. H. (2013). Comparative neuroimaging in children with cerebral palsy using fMRI and a novel EEG-based brain mapping during a motor task—a preliminary investigation. *NeuroRehabilitation*, 32(2), 279-285.
- [8] Asanza, V.; Peláez, E.; Loayza, F.; Lorente-Leyva, L.L.; Peluffo-Ordóñez, D.H. Identification of Lower-Limb Motor Tasks via Brain-Computer Interfaces: A Topical Overview. *Sensors* 2022, 22, 2028. <https://doi.org/10.3390/s22052028>
- [9] Asanza, Víctor; Montoya, Daniel; Peláez, Enrique; Loayza, Francis; Lorente-Leyva, Leandro L.; Peluffo-Ordóñez, Diego H.; González, Kléber (2021), "MILimbEEG: An EEG Signals Dataset based on Upper and Lower Limb Task During the Execution of Motor and Motor Imagery Tasks", Mendeley Data, V2, doi: 10.17632/w9xfz56txv.2.
- [10] Asanza, V., Pelaez, E., & Loayza, F. (2017, October). EEG signal clustering for motor and imaginary motor tasks on hands and feet. In *Ecuador Technical Chapters Meeting (ETCM)*, 2017 IEEE (pp. 1-5). IEEE.
- [11] Constantine, A., Asanza, V., Loayza, F. R., Peláez, E., & Peluffo-Ordóñez, D. (2021). BCI System using a Novel Processing Technique Based on Electrodes Selection for Hand Prosthesis Control. *IFAC-PapersOnLine*, 54(15), 364-369.
- [12] Asanza, V.; Constantine, A.; Valarezo, S.; Peláez, E. Implementation of a Classification System of EEG Signals Based on FPGA. *2020 Seventh International Conference on eDemocracy eGovernment (ICEDEG)*, 2020, pp. 87–92. Doi:10.1109/ICEDEG48599.2020.9096752.