

# Contribuciones al Control de Dispositivos Físicos Mediante Sistemas EEG de Bajo Coste

Por Fernando Rivas Navazo

## TESIS

Entregada cumpliendo los requisitos del Programa de Doctorado de Ingeniería y Tecnologías Industrial, Informática y Civil

DEPARTAMENTO DE DIGITALIZACIÓN  
DEPARTAMENTO DE INGENIERÍA ELECTROMECAÁNICA  
ESCUELA POLITÉCNICA SUPERIOR  
UNIVERSIDAD DE BURGOS

Marzo 2025



**UNIVERSIDAD  
DE BURGOS**

Autor:

©Fernando Rivas Navazo

Directores:

Dr. Jesús Enrique Sierra García

Dr. José María Cámara Nebreda

Esta Tesis ha sido aprobada cumpliendo los requisitos del programa de Doctorado en Ingeniería y Tecnologías Industrial, Informática y Civil de la Universidad de Burgos.

- Área de Ingeniería de Sistemas y Automática
  - Departamento de Digitalización
  
- Área de Tecnología Electrónica
- Departamento de Ingeniería Electromecánica.

## **Escuela Politécnica Superior - Universidad de Burgos**

Directores de Tesis:

Dr. Jesús Enrique Sierra García

Dr. José María Cámara Nebreda

## Declaración de Autoría y Originalidad

Declaro que este documento es fruto de mi propio trabajo y que no contiene material publicado previamente o escrito por otra persona o que se haya aceptado en otra institución académica.

Además, declaro que se han respetado los derechos de otros autores cuyos trabajos han sido citados al utilizar sus resultados o publicaciones.

Por último, deseo dejar constancia de que el contenido intelectual de esta tesis es fruto de mi labor y dedicación personal. No obstante, reconozco y valoro la ayuda recibida en cuanto al diseño del proyecto y la mejora de su estilo y expresión lingüística, cuyas contribuciones han sido imprescindibles para la consecución de este trabajo.

## Declaración de copyright

Declaro que acepto ceder a la Universidad de Burgos el derecho de archivar y tras superado el periodo de embargo de 3 años publicar esta tesis, ya sea parcialmente o en su totalidad, en la Biblioteca de la Universidad en cualquier formato o medio electrónico. También declaro que no he empleado porciones sustanciales de material con copyright en esta tesis. Los derechos de los artículos publicados pertenecen a la revista donde se han publicado.

# Agradecimientos

A mi familia, en especial a mi mujer y mis hijos que han sacrificado parte de su tiempo para permitirme realizar esta tesis, renunciando muchas veces a compartir tiempo juntos, a pesar de lo cual me han apoyado constantemente, dándome fuerza para seguir y llegar hasta este momento.

A mis padres que son los artífices con su cariño y consejo de lo que soy.

A Juan Carlos Bertolín quien propició el acceder a la Universidad, confiando que era el candidato idóneo para proseguir con su legado.

A José María Cámara “Chema” quien ha estado desde el primer momento ayudando y dando sabios y buenos consejos que han propiciado llegar a este punto.

A Enrique Sierra por ser el incansable y paciente director de tesis, que ha guiado junto a José María mis pasos hasta aquí.

A Pedro L. Sánchez que más que compañero ha sido un amigo, acompañando y aterrizando mis locuras con su cordura.

A Iñaqui, Miguel Ángel, Jesús, Maribel, Guirguis, y el resto de compañeros del área de tecnología electrónica que siempre han tenido una frase de apoyo y cariño para no cejar en el empeño de completar esta tesis.

A Beatriz, Rosa, Rafael, Nieves, los miembros del grupo de investigación DINper que me lo han hecho todo muy fácil, mostrando una fe y un apoyo inquebrantable en poder alcanzar esta meta.

A Gonzalo Salazar, siempre dispuesto a echar una mano y perder de su tiempo para lo que haga falta, consejos, charlas, cafés, el “jefe” que todos queríamos tener.

A todos los que, de alguna manera, compañeros y amigos han estado de forma incansable animándome para llegar a la meta.

GRACIAS a todos.

# Índice de contenido:

## Tabla de contenido

Declaración de Autoría y Originalidad .....	3
Declaración de copyright.....	4
Agradecimientos .....	5
Índice de contenido: .....	6
Índice de Figuras: .....	9
Índice de tablas: .....	11
Glosario:.....	13
Abreviaturas: .....	15
Resumen: .....	16
1. Introducción .....	17
1.1. Contexto y Motivación .....	17
1.2. Problema de Investigación .....	21
1.3. Hipótesis de Trabajo .....	25
1.4. Objetivos de la Investigación.....	32
1.5. Contribuciones Originales .....	38
1.6. Metodología de Investigación.....	40
1.7. Lista de Publicaciones .....	43
1.8. Estructura de la Tesis .....	44
2. Fundamentos Teóricos .....	54
2.1. Neurociencia Computacional y Procesamiento de Señales EEG .....	54
2.2. Interfaces Cerebro-Computadora (BCI).....	62
2.3. Caracterización de las Señales EEG Capturadas con Neurosky .....	65
2.4. Modelos de Aprendizaje Profundo en Procesamiento de EEG .....	69
2.5. Robótica Asistencial y Control Autónomo.....	83
2.6. Ética y Regulaciones en BCI y Robótica Asistencial.....	90
3. Herramientas utilizadas.....	95
3.1. Herramientas de Software .....	96
3.2. Herramientas de Hardware .....	98
4. Estado del Arte y Limitaciones Actuales .....	100

4.1. Estado Actual del Uso de EEG en el Control de Dispositivos Físicos ....	102
4.2. Modelos de Aprendizaje Automático Aplicados a la Clasificación de Señales EEG .....	106
4.3. Redes LSTM y GRU para Predicción de Estados Cognitivos.....	111
4.4. Modelos Clásicos para Clasificación de señales EEG .....	117
4.5. Limitaciones en la Clasificación y Control de Dispositivos con EEG.....	126
4.6. Brechas y Oportunidades en el Campo .....	130
5. Definición de la Propuesta: Definición de arquitectura para el control de sillas de ruedas mediante sistemas EEG.....	136
5.1. Motivación y Justificación de Dispositivos EEG Comerciales .....	138
5.2 Descripción del Hardware Utilizado en la Adquisición de Datos .....	140
5.3. Integración de las Señales EEG con Sistemas de Control de Dispositivos Físicos .....	144
6. Predicción de Valores de Atención y Meditación Usando Redes LSTM y GRU .	152
6.1. Justificación del Uso de Modelos LSTM y GRU para Predicción de EEG	153
6.2. Proceso de Adquisición y Preprocesamiento de las Señales.....	155
6.3. Implementación de Modelos LSTM y GRU.....	164
6.4. Comparación de Rendimiento entre LSTM y GRU .....	174
6.5. Evaluación de Resultados y Análisis de Errores.....	178
6.6. Impacto de la Predicción en Aplicaciones BCI .....	181
6.7. Limitaciones encontradas durante el estudio .....	185
6.8. Comparación de Modelos de Predicción de EEG.....	187
7. Clasificación de Señales EEG para el Control de Movimientos .....	190
7.1. Metodología Experimental.....	191
7.2. Entrenamiento y selección del mejor modelo de clasificación. ....	199
7.3. Despliegue del Clasificador XGBoost .....	254
8. Conclusiones y Trabajos Futuros.....	273
8.1. Resumen de Contribuciones.....	273
8.2. Impacto en el Desarrollo de Sistemas BCI .....	282
8.3. Limitaciones del Estudio.....	283
8.4. Líneas de Investigación Futura .....	284
ANEXO: Consideraciones Éticas en la Investigación con Sujetos Humanos .....	289
Solicitud de informe a la Comisión de Bioética.....	290

Referencias (Formato IEEE) .....	296
ANEXO II . Publicaciones asociadas.....	316

## Índice de Figuras:

Figura 1: Hipótesis 1: Es posible utilizar dispositivos EEG de bajo costo para capturar señales cerebrales utilizables en BCI Es posible utilizar dispositivos EEG de bajo costo para capturar señales cerebrales utilizables en BCI .....	27
Figura 2: Hipótesis 2. Las redes neuronales recurrentes (LSTM y GRU) pueden predecir los valores de atención y meditación a partir de señales EEG con una precisión aceptable .....	28
Figura 3: Hipótesis 3. La clasificación de señales EEG en cuatro movimientos de control puede optimizarse mediante la combinación de modelos LSTM/GRU con técnicas clásicas de clasificación.....	29
Figura 4: Hipótesis 4, XGBoost mejorará el rendimiento de la clasificación de señales EEG en comparación con redes LSTM y GRU en tiempo real. ....	30
Figura 5: Hipótesis 5, La combinación de XGBoost con el modelo Popov incrementará la precisión en la clasificación de señales EEG. ....	31
Figura 6 : Estadísticas JCR de la publicación .....	44
Figura 7: Desglose de tesis.....	50
Figura 8: Bandas de frecuencias de señales EEG.....	55
Figura 9: Ubicación de los posibles puntos de toma de datos. ....	66
Figura 10: Posición de electrodos para lectura EEG .....	67
Figura 11: Señales EEG capturadas con NeuroSky.....	68
Figura 12: Estructura básica de una red LSTM.....	71
Figura 13: Estructura básica de una red GRU.....	74
Figura 14: Propuesta de sillas de ruedas controladas por BCI.....	86
Figura 15: Ilustración de la propuesta de control BCI de dispositivos físicos.....	87
Figura 16: Estructura de funcionamiento de una arquitectura XGBoost .....	119
Figura 17: Flujo de procesamiento de datos y control .....	140
Figura 18: Diadema NeuroSky brainwave .....	142
Figura 19: Diadema Brainlink Lite .....	143
Figura 20: Arquitectura funcional .....	145
Figura 21: Flujo de datos y arquitectura de software .....	146
Figura 22: Arquitectura de Hardware .....	147
Figura 23: Diagrama de cumplimiento de requisitos funcionales. <b>Ref 1.</b> -SSVEP-Based BCI Wheelchair Control System [150]; <b>Ref 2.</b> -Brain-Computer Interface Controlled Robotic Gait Orthosis [151]. <b>Ref 3.</b> - Automatización de silla de ruedas mediante un sistema BCI híbrido que utiliza SSVEP y parpadeos [152]. <b>Ref 4.</b> -EEGBased BCIs: A Survey [153]. <b>Ref 5.</b> -Silla de ruedas EEG para personas con determinación [154]. <b>Ref 6.</b> -BCIControlada Hands-Free Wheelchair Navigation with Obstacle Avoidance [155]. <b>Ref 7.</b> -Revisión bibliográfica sobre los sistemas de sillas de ruedas inteligentes [156]. <b>Ref 8.</b> -A Real-Time Control Approach for Unmanned Unmanned Aerial Vehicles Using Brain-Computer Interface [157]. <b>Ref 9.</b> -Interacción cerebro-máquina en tiempo real. via Social Robot Gesture Control[158] .....	149
Figura 24: Diagrama de cumplimiento de requisitos técnicos. <b>Ref 1.</b> -SSVEP-Based BCI Wheelchair Control System [150]; <b>Ref 2.</b> -Brain-Computer Interface Controlled Robotic Gait Orthosis [151]. <b>Ref 3.</b> - Automatización de silla de ruedas mediante un sistema BCI híbrido que utiliza SSVEP y parpadeos [152]. <b>Ref 4.</b> -EEGBased BCIs: A Survey [153]. <b>Ref 5.</b> -Silla de ruedas EEG para personas con determinación [154]. <b>Ref 6.</b> -BCIControlada Hands-Free Wheelchair Navigation with Obstacle Avoidance [155]. <b>Ref 7.</b> -Revisión bibliográfica sobre los sistemas de sillas de ruedas inteligentes [156]. <b>Ref 8.</b> -A Real-Time Control Approach for Unmanned Unmanned Aerial Vehicles Using Brain-Computer Interface [157]. <b>Ref 9.</b> -Interacción cerebro-máquina en tiempo real. via Social Robot Gesture Control[158] .....	150
Figura 25: Cálculo de hiperparámetros con el modelo LSTM para valores de Atención. ....	167

<i>Figura 26: Cálculo de hiperparámetros con el modelo LSTM para valores de Meditación.</i>	167
<i>Figura 27: Comparación de la predicción de la atención.</i>	177
<i>Figura 28: Comparación para la predicción de la Meditación.</i>	177
<i>Figura 29: Resultado final de la predicción para Atención y Meditación.</i>	180
<i>Figura 30: Espera para la confirmación de adquisición de datos desde la diadema EEG.</i>	196
<i>Figura 31: Proceso de etiquetado de las direcciones para la clasificación con la aplicación diseñada.</i>	196
<i>Figura 32: Proceso de descanso en la aplicación de etiquetado para la clasificación.</i>	197
<i>Figura 33: Técnicas de preprocesamiento de datos EEG.</i>	201
<i>Figura 34: Evolución de la exactitud por época, en el entrenamiento entre los datos de entrenamiento y validación.</i>	202
<i>Figura 35: Evolución de la pérdida por época, en el entrenamiento entre los datos de entrenamiento y validación.</i>	202
<i>Figura 36: Curvas de pérdidas y precisión para GRU y GRU+Popov por época.</i>	207
<i>Figura 37: Matrices de confusión para GRU y GRU+Popov.</i>	209
<i>Figura 38: Comparación de métricas y F1-Score para arquitecturas GRU y GRU+Popov.</i>	211
<i>Figura 39: Curva de Precisión para modelos mejorados GRU y GRU+Popov.</i>	214
<i>Figura 40: Curva de Pérdida para modelos mejorados GRU y GRU+Popov.</i>	215
<i>Figura 41: Valores de F1-Score por época en el entrenamiento GRU y GRU+Popov(PS-GRU).</i>	221
<i>Figura 42: Curvas de pérdidas para redes GRU Vs GRU+Popov(PS-GRU) por n° de épocas.</i>	221
<i>Figura 43: Curvas de recisión para arquitecturas GRU y GRU+Popov (PS-GRU).</i>	222
<i>Figura 44: Pérdidas en entrenamiento y validación para arquitecturas GRU y GRU+Popov.</i>	222
<i>Figura 45: Curva de pérdidas para GRU- GRU+Popov(PS-GRU).</i>	224
<i>Figura 46: Curvas de pérdidas para LSTM y LSTM+Popov(PS-LSTM).</i>	224
<i>Figura 47: Comparación de rendimiento obtenido por arquitectura.</i>	233
<i>Figura 48: Tiempo de inferencia por arquitectura.</i>	234
<i>Figura 49: Relación Rendimiento-Velocidad por arquitectura.</i>	234
<i>Figura 50: Mejora relativa por modelo (F1-Score).</i>	235
<i>Figura 51: Resultado de métricas por modelo de arquitectura.</i>	236
<i>Figura 52: Tiempo de procesamiento por arquitecturas.</i>	240
<i>Figura 53: Gráfica de comparación de rendimiento y F1-Score del modelo XGBoost con los otros modelos estudiados.</i>	241
<i>Figura 54: Mapa de Calor de Métricas por Arquitecturas.</i>	242
<i>Figura 55: Influencia de los hiperparámetros en la configuración de red XGBoost.</i>	247
<i>Figura 56: Importancia del valor estadístico en el proceso de clasificación.</i>	248
<i>Figura 57: Métricas de rendimiento del modelo de clasificación XGBoost.</i>	249
<i>Figura 58: Características principales de la arquitectura XGBoost.</i>	249
<i>Figura 59: Curva de aprendizaje del modelo de clasificación.</i>	251
<i>Figura 60: Curva ROC para clasificación.</i>	253
<i>Figura 61: Arquitectura de clasificación XGBoost para señales EEG.</i>	256
<i>Figura 62: Descripción del proceso de extracción de características de señales EEG aplicadas al clasificador XGBoost.</i>	257
<i>Figura 63: Diagrama de Flujo de Procesamiento del clasificador XGBoost.</i>	259
<i>Figura 64: Interfaz de visualización y retroalimentación.</i>	261
<i>Figura 65: Interfaz de usuario para simulación de movimiento de silla de ruedas, según datos EEG clasificados por XGBoost.</i>	264

## Índice de tablas:

<i>Tabla 1: Estudios más relevantes con arquitecturas de Aprendizaje Profundo (DL)</i> .....	105
<i>Tabla 2: Comparación entre LSTM y GRU</i> .....	116
<i>Tabla 3: Parámetros específicos “típicos” para redes XGBoost con señales EEG</i> .....	120
<i>Tabla 4: Brechas y Oportunidades en sistemas BCI</i> .....	135
<i>Tabla 5: Requisitos funcionales de la propuesta</i> .....	137
<i>Tabla 6: Las características se ajustan en función de las señales de entrada</i> .....	160
<i>Tabla 7: Rangos de hiperparámetros y valores óptimos para los modelos LSTM y GRU</i> .....	165
<i>Tabla 8: Predicción de ATENCIÓN con modelo LSTM, utilizando conjunto parcial de características.</i> .....	168
<i>Tabla 9: Predicción de MEDITACIÓN con modelo LSTM, utilizando conjunto parcial de características.</i> .....	169
<i>Tabla 10: Predicción de ATENCIÓN con modelo GRU, utilizando conjunto parcial de características.</i> .....	170
<i>Tabla 11: Predicción de MEDITACIÓN con modelo GRU, utilizando conjunto parcial de características.</i> .....	171
<i>Tabla 12: Predicción de ATENCIÓN con LSTM utilizando el total de las características.</i> .....	172
<i>Tabla 13: Predicción de MEDITACIÓN con LSTM utilizando el total de las características.</i> .....	172
<i>Tabla 14: Predicción ATENCIÓN con GRU utilizando el total de las características.</i> .....	173
<i>Tabla 15: Predicción de MEDITACIÓN con GRU utilizando el total de las características.</i> .....	174
<i>Tabla 16: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN con LSTM utilizando conjunto parcial de características.</i> .....	175
<i>Tabla 17: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN con GRU utilizando conjunto parcial de características.</i> .....	175
<i>Tabla 18: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN con LSTM utilizando el total de las características.</i> .....	176
<i>Tabla 19: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN con GRU utilizando el total de las características.</i> .....	176
<i>Tabla 20: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN, para LSTM Vs GRU</i> .....	178
<i>Tabla 21: Mejor resultado de predicción ATENCIÓN para LSTM Vs GRU</i> .....	178
<i>Tabla 22: Mejor resultado de predicción MEDITACIÓN para LSTM Vs GRU</i> .....	178
<i>Tabla 23: Mejor resultado de predicción de LB a priori y a posteriori para ATENCIÓN/MEDITACIÓN con arquitectura LSTM.</i> .....	179
<i>Tabla 24: Mejor resultado de predicción de LB anterior y posterior para ATENCIÓN/MEDITACIÓN con arquitectura LSTM.</i> .....	179
<i>Tabla 25: Mejor resultado de predicción ATENCIÓN.</i> .....	180
<i>Tabla 26: Mejor resultado de predicción MEDITACIÓN</i> .....	180
<i>Tabla 27: Hiperparámetros de la red GRU óptimos</i> .....	203
<i>Tabla 28: Resultados por clase obtenidos en clasificación con GRU</i> .....	204
<i>Tabla 29: Resultados para los modelos GRU y GRU+Popov</i> .....	208
<i>Tabla 30: Análisis por clase para GRU estándar</i> .....	215
<i>Tabla 31: Análisis por clase para GRU + Popov</i> .....	216
<i>Tabla 32: Comparación F1-Score por Clase y modelo de red</i> .....	216
<i>Tabla 33: Análisis por clase para la red GRU, definida en el proceso de clasificación según etiquetado previo con 50 épocas</i> .....	218
<i>Tabla 34: Análisis por clase para la red GRU+Popov, definida en el proceso de clasificación según etiquetado previo con 50 épocas</i> .....	219
<i>Tabla 35: Análisis por clase para la red GRU, definida en el proceso de clasificación según etiquetado previo con 100 épocas</i> .....	220

<i>Tabla 36: Análisis por clase para la red GRU+Popov, definida en el proceso de clasificación según etiquetado previo con 100 épocas</i>	220
<i>Tabla 37: Análisis por clase para la red LSTM, definida en el proceso de clasificación según etiquetado previo con 150 épocas</i>	223
<i>Tabla 38: Análisis por clase para la red LSTM+Popov, definida en el proceso de clasificación según etiquetado previo con 150 épocas</i>	223
<i>Tabla 39: Tabla comparativa resultados GRU Vs GRU+Popov</i>	226
<i>Tabla 40: Comparativa de resultados para distintas arquitecturas</i>	232
<i>Tabla 41: Mejores modelos por resultados</i>	233
<i>Tabla 42: Mejores métricas obtenidas para red XGBoost</i>	237
<i>Tabla 43: Impacto de la penalización sobre la red XGBoost</i>	237
<i>Tabla 44: Mejores métricas obtenidas para redes LSTM y GRU</i>	238
<i>Tabla 45: Impacto de la penalización sobre la red LSTM</i>	238
<i>Tabla 46: Impacto de la penalización sobre la red GRU</i>	238
<i>Tabla 47: Mejora relativa de los modelos tras aplicar la penalización de Popov</i>	239
<i>Tabla 48 : Tiempos de inferencia y entrenamiento por arquitectura</i>	240
<i>Tabla 49: Compromiso Rendimiento-Velocidad por Arquitectura</i>	241
<i>Tabla 50: Definición de hiperparámetros óptimos</i>	246
<i>Tabla 51: Configuración-I de los hiperparámetros de la red XGBoost</i>	247
<i>Tabla 52: Configuración-III de los hiperparámetros de la red XGBoost</i>	247
<i>Tabla 53: Rendimiento final de la arquitectura XGBoost</i>	248
<i>Tabla 54: Matriz de confusión de la clasificación</i>	250
<i>Tabla 55: Hiperparámetros del modelo de clasificación XGBoost</i>	252
<i>Tabla 56: Comparativa de aspectos principales y ventajas de la propuesta</i>	269

## Glosario:

- **BCI (Brain-Computer Interface):** Interfaz que permite la comunicación directa entre el cerebro y un dispositivo externo, sin intervención muscular.
- **EEG (Electroencefalograma):** Técnica para registrar la actividad eléctrica del cerebro mediante electrodos colocados en el cuero cabelludo.
- **Neurosky:** Marca comercial de diademas EEG de bajo costo que utiliza electrodos secos para captar señales cerebrales.
- **LSTM (Long Short-Term Memory):** Tipo de red neuronal recurrente que es capaz de aprender dependencias a largo plazo en secuencias de datos.
- **GRU (Gated Recurrent Unit):** Variante simplificada de la red LSTM, diseñada para manejar información secuencial de forma eficiente.
- **XGBoost (Extreme Gradient Boosting):** Algoritmo de aprendizaje automático basado en árboles de decisión que se utiliza ampliamente en problemas de clasificación y regresión.
- **Modelo Popov:** Método clásico de análisis de estabilidad que se utiliza para evaluar y mejorar la robustez de sistemas de control.
- **Aprendizaje profundo (Deep Learning):** Subconjunto del aprendizaje automático que utiliza redes neuronales con múltiples capas para modelar patrones complejos en grandes volúmenes de datos.
- **Potencias de bandas cerebrales:** División de frecuencias EEG en diferentes rangos (Delta, Theta, Alpha, Beta, Gamma) que representan estados mentales específicos.
- **Jetson Nano:** Plataforma embebida de NVIDIA orientada a aplicaciones de inteligencia artificial y procesamiento en tiempo real.
- **Raspberry Pi:** Ordenador de placa única utilizado para múltiples aplicaciones, incluyendo prototipado rápido e integración de sistemas embebidos.
- **ROS (Robot Operating System):** Framework open-source para el desarrollo de aplicaciones robóticas.
- **Escalado robusto:** Técnica estadística para normalizar los datos reduciendo la sensibilidad frente a valores atípicos.
- **Inferencia:** Proceso mediante el cual un modelo entrenado realiza predicciones a partir de nuevos datos.
- **Ventana temporal (WINDOW\_SIZE):** Intervalo de tiempo o número de muestras sobre el cual se extraen características para la clasificación.
- **Skewness (Asimetría):** Medida estadística que indica la desviación de la distribución de datos respecto a una distribución normal.

- **Proceso de etiquetado:** Asignación de categorías específicas (por ejemplo, movimientos del robot) a segmentos de datos EEG durante el entrenamiento de modelos.
- **Validación cruzada:** Técnica estadística para evaluar la robustez de modelos, dividiendo el conjunto de datos en varios subconjuntos y alternando entre entrenamiento y prueba.
- **Clasificación en tiempo real:** Proceso donde las señales son analizadas y categorizadas inmediatamente tras su adquisición, crucial para aplicaciones interactivas.
- **Hiperparámetros:** Parámetros configurables en un modelo de aprendizaje automático que afectan el proceso de entrenamiento y rendimiento del modelo.
- **Métricas de rendimiento:** Indicadores cuantitativos utilizados para evaluar la precisión y eficacia de los modelos (precisión, recall, F1-score).
- **Atención y Meditación:** Estados cognitivos específicos captados por EEG, relacionados con niveles de concentración y relajación respectivamente.
- **Robótica asistencial:** Campo de la robótica orientado a desarrollar soluciones que mejoren la calidad de vida de personas con discapacidades o limitaciones físicas.
- **Viabilidad computacional:** Evaluación de la capacidad de implementar modelos complejos en plataformas con recursos limitados.
- **Preprocesamiento de señales EEG:** Procedimientos que se aplican sobre señales brutas EEG para reducir ruido y mejorar la calidad y fiabilidad de los datos.

## Abreviaturas:

- BCI: Brain-Computer Interface
- EEG: Electroencefalograma
- LSTM: Long Short-Term Memory
- GRU: Gated Recurrent Unit
- XGBoost: Extreme Gradient Boosting
- ROS: Robot Operating System
- Hz: Hertz (Unidad de frecuencia)
- IA: Inteligencia Artificial
- FPS: Frames per Second (Fotogramas por segundo)
- JSON: JavaScript Object Notation
- URDF: Unified Robot Description Format
- CPU: Central Processing Unit
- GPU: Graphics Processing Unit
- m/s: Metros por segundo
- ms: Milisegundos
- DL: Deep Learning (Aprendizaje Profundo)
- SVM: Support Vector Machine (Máquina de Vectores de Soporte)
- ROC: Receiver Operating Characteristic (Característica Operativa del Receptor)
- F1-score: Medida estadística del rendimiento de clasificación
- CSV: Comma-Separated Values (Valores Separados por Comas)
- LSTM+Popov: Popov Stabilized Long Short-Term Memory
- GRU+Popov: Popov Stabilized Gated Recurrent Unit
- IEEE: Institute of Electrical and Electronics Engineers
- mlogloss: Multiclass Logarithmic Loss
- merror: Multiclass Error

## Resumen:

En esta tesis, me propongo explorar cómo las señales EEG capturadas con dispositivos de bajo coste pueden transformar la interacción entre el ser humano y la máquina. A través de un enfoque que integra técnicas avanzadas de procesamiento de señales y modelos de aprendizaje profundo especialmente redes neuronales recurrentes del tipo LSTM y GRU, por las características particulares de las señales EEG, busco predecir estados cognitivos críticos como la atención y la meditación, y convertir estos datos en comandos de control de dispositivos físicos mediante procesos de clasificación con redes XGBoost.

Mi investigación se fundamenta en encontrar la mejor arquitectura que fusione lo mejor de ambos mundos: por un lado, métodos clásicos y por otro, técnicas modernas de BCI que permitan ser implementadas en plataformas como ROS, Jetson Nano y microcontroladores Arduino, con tiempos de respuesta inferiores a 1 s, tiempo de acceso a los datos suministrados por las diademas neurales. Además, realizo una comparación exhaustiva con modelos tradicionales, como XGBoost, en procesos de clasificación, para evaluar y demostrar la superioridad en precisión y robustez, frente a las redes LSTM y GRU en este contexto. Los resultados experimentales confirman que, a pesar de las limitaciones propias de los dispositivos comerciales, es posible obtener una alta precisión y estabilidad mediante un cuidadoso preprocesamiento y optimización de los modelos, lo que abre nuevas perspectivas para el diseño de interfaces cerebro-computadora (BCI) que realmente mejoren la calidad de vida de personas con discapacidades motoras. Permittiendo enfocar los resultados obtenidos en esta tesis, en un modelo real de control de sillas de ruedas basado en la clasificación de señales EEG con redes XGBoost, siguiendo la arquitectura de control propuesta, acercando la investigación a un TRL 6, previo a su uso como prototipo.

# 1. Introducción

## 1.1. Contexto y Motivación

En la última década, el campo de las interfaces cerebro-computadora (BCI) ha experimentado una transformación radical, evolucionando desde sistemas altamente especializados y costosos hacia soluciones más accesibles y versátiles. Esta evolución ha sido impulsada por dos factores fundamentales: los avances en el procesamiento de señales electroencefalográficas (EEG) y el desarrollo de dispositivos de adquisición de bajo coste. La convergencia de estos elementos ha abierto nuevas posibilidades para la implementación de BCIs en aplicaciones cotidianas, especialmente en el ámbito de la asistencia a personas con discapacidades motoras severas .

Las interfaces cerebro-computadora basadas en EEG han demostrado ser particularmente prometedoras en el control de dispositivos físicos, como sillas de ruedas autónomas y brazos robóticos. Sin embargo, la adopción generalizada de esta tecnología se ha visto históricamente limitada por el alto coste y la complejidad de los sistemas EEG tradicionales[1]. Los sistemas EEG convencionales, que utilizan entre 32 y 256 electrodos húmedos, requieren una preparación extensa y personal especializado, lo que los hace poco prácticos para aplicaciones fuera del entorno clínico[2].

En respuesta a estas limitaciones, ha surgido una nueva generación de diademas EEG comerciales de bajo coste, como Neurosky y Brainlink, que utilizan electrodos secos y ofrecen una alternativa más accesible[3]. Estos dispositivos, aunque proporcionan menos canales de adquisición, han demostrado ser sorprendentemente efectivos cuando se combinan con algoritmos avanzados de procesamiento de señales y técnicas de aprendizaje profundo [4]. Los recientes avances en redes neuronales recurrentes (RNN), particularmente en arquitecturas Long Short-Term Memory (LSTM) y Gated Recurrent Unit (GRU), han permitido compensar las limitaciones inherentes de estos dispositivos mediante una mejor interpretación de las señales disponibles.

La integración de estos avances tecnológicos con métodos clásicos de control representa una oportunidad única para desarrollar sistemas BCI más robustos y confiables. Esta combinación permite abordar uno de los principales desafíos en el campo: la estabilidad y precisión en la clasificación de señales EEG para el control en tiempo real de dispositivos físicos[5]. La relevancia de esta investigación se fundamenta en su potencial para:

1. Democratizar el acceso a tecnologías BCI mediante soluciones de bajo coste.
2. Mejorar la calidad de vida de personas con discapacidades motoras severas.
3. Expandir las aplicaciones de BCI en entornos domésticos y asistenciales.
4. Establecer nuevos paradigmas en la interacción humano-máquina.

Los avances recientes en el procesamiento de señales EEG han demostrado que incluso con un número limitado de electrodos, es posible obtener información significativa sobre estados cognitivos y comandos motores [6]. Esta evidencia sugiere que el verdadero potencial de los sistemas BCI no radica necesariamente en la cantidad de señales adquiridas, sino en la capacidad de procesarlas e interpretarlas de manera eficiente [7].

Este trabajo se sitúa en la intersección de tres dominios fundamentales: la neurociencia computacional, el aprendizaje profundo y la teoría de control clásica. La convergencia de estos campos permite abordar las limitaciones actuales de los sistemas BCI de bajo coste desde una perspectiva integral, proponiendo soluciones que combinan la robustez de los métodos clásicos con la flexibilidad y potencia del aprendizaje profundo moderno.

### **El desafío de la accesibilidad en BCI**

Uno de los mayores obstáculos en la adopción de las tecnologías BCI es el alto costo y la complejidad de los equipos de adquisición de señales EEG. Los sistemas tradicionales, como los utilizados en entornos clínicos para la monitorización de enfermedades neurológicas, requieren dispositivos con múltiples electrodos de alta precisión y protocolos de calibración complejos. Esta barrera económica y técnica limita la posibilidad de integrar sistemas BCI en aplicaciones más allá del

ámbito médico, como en robótica asistencial, domótica y control de dispositivos electrónicos para personas con discapacidad motriz.

En este contexto, la aparición de diademas EEG comerciales de bajo costo, como Neurosky y Brainlink, representa una oportunidad disruptiva para la democratización de la tecnología BCI. Si bien estos dispositivos presentan limitaciones en la calidad y resolución de las señales capturadas, si hacemos una comparación estricta con los dispositivos de grado médico, que además cuentan con multitud de electrodos ubicados en toda la superficie del cráneo, a pesar de contar solo con un electrodo y diademas de uso personal comercial, los avances en el procesamiento de datos y la inteligencia artificial han permitido desarrollar estrategias de compensación que optimizan su rendimiento en tareas específicas. Estas mejoras abren la puerta a soluciones BCI accesibles y escalables, con un impacto potencial en la calidad de vida de personas con movilidad reducida y en el desarrollo de interfaces más intuitivas para la interacción humano-máquina.

### **El papel de la inteligencia artificial en la mejora del rendimiento de BCI**

El procesamiento de señales EEG es un desafío técnico significativo debido a la naturaleza ruidosa y altamente variable de los datos capturados. La fiabilidad de la interpretación de estas señales depende en gran medida de la capacidad de los modelos computacionales para extraer patrones relevantes y diferenciar la actividad cerebral útil de artefactos externos. En este sentido, el aprendizaje profundo ha demostrado ser una herramienta poderosa para mejorar la precisión de los sistemas BCI, permitiendo la clasificación de señales EEG con una eficiencia superior a la de métodos tradicionales[8].

Las redes neuronales recurrentes, en particular los modelos LSTM y GRU, han mostrado un rendimiento sobresaliente en la predicción de estados cognitivos como la atención y la meditación. Estos modelos pueden captar dependencias temporales en secuencias de datos EEG, permitiendo una interpretación más robusta y adaptable a variaciones interindividuales[9][10]. No obstante, su aplicabilidad en tareas de control de dispositivos físicos aún enfrenta retos, especialmente en términos de latencia y estabilidad en la clasificación de comandos en tiempo real.

## **Hacia un nuevo paradigma en la clasificación de señales EEG**

Uno de los aspectos más desafiantes en la implementación de sistemas BCI prácticos es la clasificación precisa de señales cerebrales para el control de movimientos específicos. Tradicionalmente, los enfoques basados en redes LSTM y GRU han sido la opción dominante, pero recientes estudios han señalado que modelos de aprendizaje automático clásicos, como XGBoost, pueden ofrecer ventajas significativas en términos de estabilidad y velocidad de inferencia.

Esta tesis aborda el problema de la clasificación de señales EEG para el control de dispositivos físicos desde una perspectiva integral, combinando técnicas de redes neuronales avanzadas con modelos clásicos optimizados. En particular, se explorará la posible mejora del rendimiento en las redes LSTM y GRU, así como su implementación y o hibridación con otras arquitecturas para evaluar el posible impacto en la mejora del rendimiento en la fase de predicción y la fase de clasificación según la arquitectura evaluada.

A través de este estudio, se busca contribuir al desarrollo de una arquitectura híbrida que combine la capacidad de modelado secuencial de las redes neuronales recurrentes con la eficiencia computacional de los métodos de boosting, con el objetivo de optimizar la precisión y la latencia en sistemas BCI de bajo costo.

El objetivo del presente trabajo es situarse en la intersección de la neurociencia computacional, la inteligencia artificial y la robótica asistencial, con el propósito de desarrollar un sistema BCI accesible, preciso y viable para su implementación en entornos del mundo real. Mediante la combinación de dispositivos EEG de bajo costo con algoritmos de aprendizaje profundo y modelos clásicos optimizados, se busca superar las limitaciones actuales en la clasificación de señales EEG y ofrecer una solución innovadora para el control de dispositivos físicos a través de la actividad cerebral.

Este enfoque no solo tiene el potencial de mejorar la calidad de vida de personas con discapacidades motoras severas, sino que también representa un avance significativo en la evolución de las interfaces cerebro-computadora, allanando el

camino hacia sistemas BCI más eficientes, asequibles y adaptables a diferentes contextos de uso.

## 1.2. Problema de Investigación

El desarrollo de interfaces cerebro-computadora (BCI) ha generado una gran expectativa en la comunidad científica debido a su potencial para permitir la comunicación directa entre el cerebro humano y dispositivos electrónicos sin la necesidad de intervención muscular. Sin embargo, a pesar de los avances logrados, la implementación práctica de estos sistemas enfrenta barreras significativas en términos de accesibilidad, precisión, estabilidad y aplicabilidad en entornos reales.

La presente investigación se enmarca dentro de este desafío, abordando las limitaciones de las BCI desde una perspectiva centrada en el **uso de dispositivos EEG de bajo costo**, la **optimización de modelos de aprendizaje profundo y clásicos** y la **mejora en la clasificación de señales EEG para el control preciso de dispositivos físicos**.

A continuación, se detallan las principales problemáticas que esta investigación busca resolver.

### *1.2.1. Accesibilidad y Limitaciones de los Dispositivos EEG de Bajo Costo*

Los sistemas EEG de grado clínico, ampliamente utilizados en neurociencia e investigación médica, poseen una alta resolución y precisión en la adquisición de señales cerebrales. Sin embargo, su elevado costo y complejidad operativa los hacen poco viables para aplicaciones prácticas fuera de entornos especializados.

En contraste, las diademas EEG comerciales de bajo costo, como **Neurosky y Brainlink**, Muse, Emotiv y muchos otros modelos comerciales de bajo/medio coste que han surgido como una alternativa prometedora debido a su asequibilidad y facilidad de uso[11], [12]. No obstante, estos dispositivos presentan limitaciones cruciales, tales como:

- **Número reducido de electrodos:** Capturan información limitada sobre la actividad cerebral, afectando la resolución espacial de las señales obtenidas.

- **Susceptibilidad a interferencias y ruido electromagnético:** Genera artefactos que dificultan la interpretación de las señales.
- **Falta de estandarización en los datos adquiridos:** Cada dispositivo emplea algoritmos propietarios para el procesamiento de señales, dificultando la reproducibilidad y comparación entre estudios.
- **Brecha evidente entre lo que se logra en el laboratorio y la aplicación práctica en la vida cotidiana:** A pesar de que en teoría los sistemas BCI pueden controlar dispositivos de manera precisa, en la práctica diaria no vemos, por ejemplo, a personas utilizando sillas de ruedas controladas únicamente por sus señales cerebrales.

Estos problemas comprometen la **calidad de los datos EEG** y, en consecuencia, la precisión en la clasificación de señales para aplicaciones prácticas como el control de dispositivos físicos. En este contexto, es necesario investigar estrategias avanzadas de preprocesamiento y modelado computacional que permitan mitigar las limitaciones intrínsecas de estos dispositivos.

Esta tesis se propone precisamente rellenar ese vacío. Nuestro enfoque no se limita a demostrar que los métodos de control basados en EEG funcionan en entornos controlados; lo que buscamos es trasladar estos avances al mundo real, integrando soluciones que sean accesibles, robustas y adaptadas a las necesidades cotidianas de los usuarios. Esto implica abordar desafíos prácticos como la variabilidad en la calidad de las señales, la interferencia del entorno, la facilidad de uso de los dispositivos y la integración efectiva con sistemas de control físico en tiempo real.

En resumen, nuestra investigación se distingue porque no es un intento teórico más, sino un esfuerzo por superar las limitaciones que han impedido la adopción masiva de las tecnologías BCI en aplicaciones prácticas. La meta es desarrollar un sistema que, partiendo de avances consolidados en el laboratorio, se convierta en una herramienta útil y accesible en el día a día, permitiendo que, en un futuro cercano, veamos soluciones de movilidad basadas en EEG operativas en entornos cotidianos.

### *1.2.2. Predicción de Estados Cognitivos: Atención y Meditación*

La capacidad de interpretar estados cognitivos como **atención y meditación** a partir de señales EEG ha sido un área de gran interés en neurociencia aplicada y

BCI. La detección precisa de estos estados resulta clave en aplicaciones de neurofeedback, aprendizaje asistido y optimización del rendimiento cognitivo[13], [14].

A pesar de los avances en la clasificación de estados mentales mediante EEG, aún existen desafíos críticos:

1. **Baja estabilidad de los modelos de predicción:** La variabilidad interindividual en las señales EEG dificulta la generalización de los modelos entrenados.
2. **Dificultad para capturar dependencias temporales en los datos:** Las señales EEG presentan patrones complejos y ruidosos, lo que requiere el uso de modelos avanzados que puedan capturar correlaciones a largo plazo.
3. **Comparación inadecuada de modelos:** La literatura científica no ha proporcionado una comparación clara del rendimiento de diferentes modelos, como **LSTM y GRU**, en la predicción de estados cognitivos en dispositivos EEG de bajo costo.

Por ello, esta investigación **evaluará comparativamente** el desempeño de redes LSTM y GRU en la predicción de atención y meditación, con base en señales EEG capturadas por diademas Neurosky. Además, se explorará el impacto del preprocesamiento de señales y la calibración de hiperparámetros en la mejora del rendimiento de los modelos.

### *1.2.3. Clasificación de Señales EEG para el Control de Movimientos*

El uso de señales EEG para el control de dispositivos físicos, como **sillas de ruedas autónomas y brazos robóticos**, es una de las aplicaciones más prometedoras de las BCI. Sin embargo, la clasificación efectiva de estas señales sigue siendo un problema no resuelto[15].

Los enfoques actuales presentan varias limitaciones:

- **Reducción del número de clases distinguibles:** La clasificación de EEG en comandos discretos (ej. adelante, atrás, izquierda, derecha) tiende a ser imprecisa debido al solapamiento en los patrones de activación cerebral.

- **Alto número de falsos positivos y negativos:** Los modelos existentes generan errores en la identificación de intenciones del usuario, afectando la fiabilidad del control del dispositivo.
- **Latencia en la respuesta del sistema:** Las redes LSTM y GRU, aunque eficaces en la modelización de secuencias, pueden introducir retardos que impactan la capacidad de respuesta en aplicaciones en tiempo real abordar estos desafíos, esta tesis propone:
  1. **Evaluar el rendimiento de LSTM y GRU en la clasificación de movimientos** a partir de señales EEG obtenidas con dispositivos de bajo costo.
  2. **Analizar la integración del modelo Popov en LSTM y GRU**, con el objetivo de mejorar la estabilidad y precisión de clasificación.
  3. **Comparar el rendimiento de modelos clásicos como XGBoost** frente a redes neuronales recurrentes, explorando la viabilidad de enfoques híbridos que combinen lo mejor de ambos paradigmas.
  4. **Analizar la viabilidad de embarcar el modelo de clasificación** en dispositivos portátiles tipo Jetson Nano o Raspberry[16], [17].

#### *1.2.4. Exploración de Modelos Alternativos para la Mejora en la Clasificación*

Si bien las redes LSTM y GRU han sido ampliamente utilizadas en el procesamiento de señales EEG, existen indicios de que modelos clásicos como XGBoost pueden ofrecer un rendimiento superior en la clasificación de comandos motores, por la particular características de las señales EEG.

Se han identificado tres problemas clave en la implementación de redes neuronales recurrentes en la clasificación de EEG:

1. **Sobreajuste a datos de entrenamiento:** LSTM y GRU requieren grandes volúmenes de datos para evitar problemas de generalización.
2. **Alto coste computacional:** Entrenar y desplegar estos modelos en hardware de bajo costo puede ser poco práctico y estar limitado por las propias características del hardware a utilizar.

3. **Sensibilidad a la variabilidad en la señal EEG:** Los cambios en la actividad cerebral de un usuario a otro afectan la estabilidad de los modelos.

Dado este panorama, se investigará la viabilidad de un **modelo alternativo**, comparando su rendimiento con las arquitecturas LSTM y GRU tradicionales. La hipótesis es que este enfoque reducirá la latencia y mejorará la estabilidad en la clasificación de señales EEG para el control de dispositivos físicos[18].

### **Conclusión del Problema de Investigación**

A pesar de los avances en BCI y aprendizaje profundo, **las interfaces cerebro-computadora aún enfrentan serias limitaciones** en términos de accesibilidad, estabilidad y precisión en la clasificación de señales EEG para el control de dispositivos físicos.

Esta investigación aborda estos desafíos desde tres perspectivas fundamentales:

1. **Uso de EEG de bajo costo para aplicaciones BCI:** Evaluando estrategias de preprocesamiento para mejorar la calidad de las señales obtenidas con dispositivos comerciales.
2. **Optimización de modelos de predicción de estados cognitivos:** Comparando redes LSTM y GRU en la estimación de atención y meditación.
3. **Mejora de la clasificación de EEG en tareas de control de dispositivos:** Integrando modelos híbridos que combinen el poder de las redes neuronales con enfoques clásicos como XGBoost y Popov[18], [19].

A través de este trabajo, se espera desarrollar **un marco metodológico sólido para la implementación de BCI accesibles y de alto rendimiento**, contribuyendo significativamente al estado del arte en interfaces cerebro-computadora aplicadas a la robótica asistencial y la accesibilidad tecnológica.

### **1.3. Hipótesis de Trabajo**

La presente investigación se fundamenta en la premisa de que es posible desarrollar una interfaz cerebro-computadora (BCI) de bajo costo, basada en dispositivos EEG comerciales como Neurosky, que permita la predicción de estados cognitivos y el control de dispositivos físicos con una precisión y

estabilidad comparable a la de sistemas de mayor coste. Para lograrlo, se plantea la combinación de redes neuronales recurrentes (LSTM y GRU) con modelos clásicos de aprendizaje automático como la red XGBoost y modelos de análisis de estabilidad de sistemas como Popov, con el fin de mejorar la clasificación de señales EEG y optimizar el rendimiento en tareas de predicción y control[20].

El propósito de esta sección es definir las hipótesis centrales que guían la investigación, estableciendo el marco teórico y experimental sobre el cual se evaluará la viabilidad del sistema propuesto.

### *1.3.1. Hipótesis General*

Se plantea que es posible desarrollar un sistema BCI basado en señales EEG obtenidas desde diademas de bajo costo que, mediante la combinación de modelos de aprendizaje profundo y métodos clásicos de clasificación, logre la precisión, estabilidad y tiempo de respuesta adecuados para la predicción y clasificación de estados cognitivos que pueda permitir el control de dispositivos físicos en tiempo real.

Esta hipótesis general se fundamenta en la necesidad de abordar los desafíos existentes en la clasificación de señales EEG, en particular la variabilidad interindividual, la limitada calidad de los dispositivos comerciales y la complejidad de modelado de secuencias temporales no lineales EEG.

Para evaluar la viabilidad de esta hipótesis, se formulan cinco hipótesis específicas, cada una de ellas centrada en un aspecto clave del problema de investigación.

### *1.3.2. Hipótesis Específicas*

**H1: Es posible utilizar dispositivos EEG de bajo costo para capturar señales cerebrales utilizables en BCI**

A pesar de sus limitaciones técnicas, se postula que las señales EEG adquiridas por diademas comerciales como Neurosky pueden contener suficiente información específica para la predicción de estados cognitivos y el posible control de movimiento de sistemas físicos. Esta hipótesis se sustenta en estudios previos que han demostrado que, si bien la resolución de estos dispositivos es menor que la de

equipos clínicos, el uso de técnicas avanzadas de procesamiento de señales puede compensar estas deficiencias.

Para validar esta hipótesis se evaluará:

1. Calidad y fiabilidad de las señales EEG capturadas con Neurosky/Brainlink.
2. Presencia de artefactos y ruido electromagnético y su impacto en la clasificación.
3. Identificación de las señales en distintos estados cognitivos y comandos motores.

El resultado esperado es que, tras aplicar técnicas de preprocesamiento y filtrado, las señales EEG de bajo costo sean suficientemente informativas para la implementación de una BCI funcional.

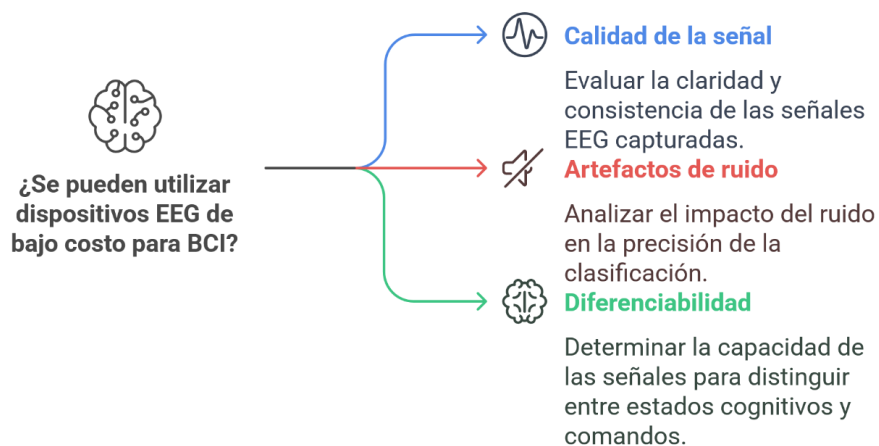


Figura 1: Hipótesis 1: Es posible utilizar dispositivos EEG de bajo costo para capturar señales cerebrales utilizables en BCI Es posible utilizar dispositivos EEG de bajo costo para capturar señales cerebrales utilizables en BCI

## **H2: Las redes neuronales recurrentes (LSTM y GRU) pueden predecir los valores de atención y meditación a partir de señales EEG con una precisión aceptable**

Dado que las señales EEG son altamente dinámicas y temporales se postula que las redes LSTM y GRU pueden capturar las dependencias a largo plazo en los datos y mejorar la precisión en la estimación de estados cognitivos.

Para evaluar esta hipótesis, se analizará:

1. El rendimiento de LSTM y GRU en la predicción de atención y meditación en comparación con modelos más simples (ej. regresión logística, SVM)[21].
2. La estabilidad de los modelos en diferentes sujetos y sesiones, observando la necesidad de recalibraciones.
3. La sensibilidad del modelo a la variabilidad de las señales EEG individuales.

Se espera que los modelos recurrentes superen a los métodos tradicionales en términos de precisión, aunque podrían presentar desafíos en cuanto a sobreajuste, tiempos de inferencia elevados y sensibilidad a la calidad de los datos.

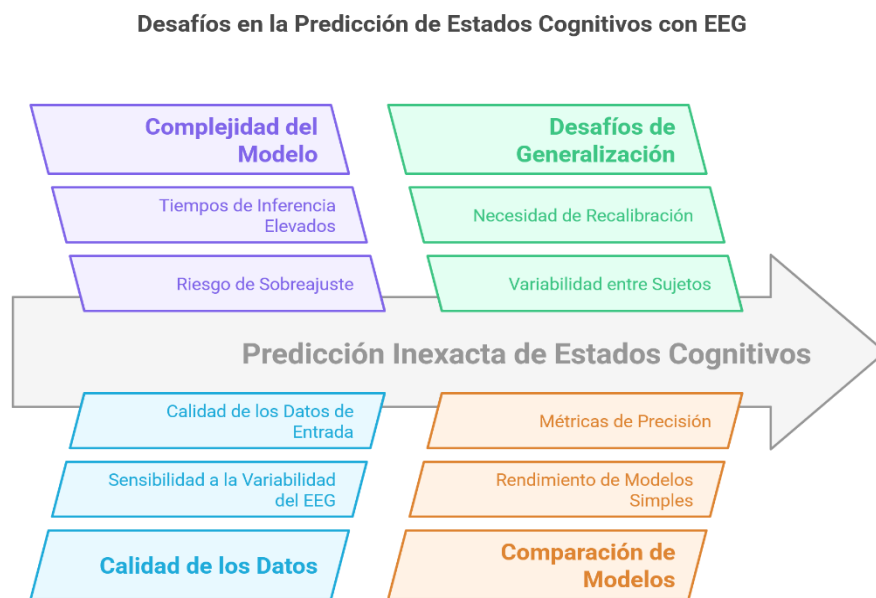


Figura 2: Hipótesis 2. Las redes neuronales recurrentes (LSTM y GRU) pueden predecir los valores de atención y meditación a partir de señales EEG con una precisión aceptable

### **H3: La clasificación de señales EEG en cuatro movimientos de control puede optimizarse mediante la combinación de modelos LSTM/GRU con técnicas clásicas de clasificación**

Se plantea que la combinación de redes neuronales recurrentes con algoritmos clásicos de aprendizaje automático que puede mejorar la precisión y estabilidad en la clasificación de señales EEG para el control de dispositivos físicos.

Para verificar esta hipótesis, se analizará:

1. Rendimiento de LSTM y GRU en la clasificación de comandos motores básicos (adelante, atrás, izquierda, derecha)[22], [23].
2. Impacto de la integración de modelos alternativos en la estabilidad y reducción de ruido en la clasificación.
3. Comparación del desempeño de XGBoost vs. modelos recurrentes en términos de precisión, tiempo de respuesta y generalización.

El resultado esperado es que los modelos híbridos superen en rendimiento a los modelos individuales, combinando la capacidad de las redes neuronales para modelar secuencias con la eficiencia y robustez de XGBoost en la clasificación de señales EEG.



Figura 3: Hipótesis 3. La clasificación de señales EEG en cuatro movimientos de control puede optimizarse mediante la combinación de modelos LSTM/GRU con técnicas clásicas de clasificación

#### **H4: XGBoost mejorará el rendimiento de la clasificación de señales EEG en comparación con redes LSTM y GRU en tiempo real**

Se plantea que, debido a la eficiencia computacional y la capacidad de manejar ruido de XGBoost, este modelo podría superar a las redes neuronales recurrentes en la clasificación de señales EEG en tiempo real.

Para validar esta hipótesis, se analizará:

1. Comparación de tiempos de inferencia entre XGBoost, LSTM y GRU en hardware de bajo costo.
2. Precisión de clasificación en entornos con ruido electromagnético y variabilidad de señales.
3. Capacidad de XGBoost para manejar la variabilidad interindividual sin necesidad de recalibración frecuente.

Se espera que XGBoost ofrezca menores tiempos de inferencia y mayor estabilidad, lo que lo haría más adecuado para aplicaciones de control en tiempo real, aunque podría presentar limitaciones en términos de modelado de dependencias temporales.

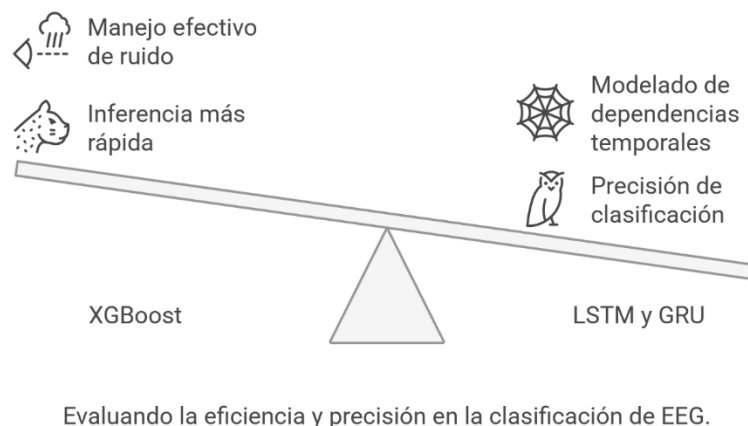


Figura 4: Hipótesis 4, XGBoost mejorará el rendimiento de la clasificación de señales EEG en comparación con redes LSTM y GRU en tiempo real.

#### **H5: La combinación de XGBoost con el modelo Popov incrementará la precisión en la clasificación de señales EEG**

Se plantea que la incorporación del modelo Popov en XGBoost permitirá mejorar la clasificación de señales EEG mediante la estabilización de los datos y la reducción de variabilidad en la señal[20].

Para evaluar esta hipótesis, se analizará:

1. Diferencia en la precisión y estabilidad de XGBoost con y sin el modelo Popov.

2. Comparación del rendimiento de XGBoost + Popov frente a LSTM y GRU en entornos de prueba y validación cruzada.
3. Impacto en la reducción de falsos positivos y negativos en la clasificación de comandos motores.

El resultado esperado es que la combinación XGBoost + Popov supere a los modelos individuales, logrando una clasificación más precisa, estable y con menor latencia.



Figura 5: Hipótesis 5, La combinación de XGBoost con el modelo Popov incrementará la precisión en la clasificación de señales EEG.

### 1.3.3. Implicaciones de las Hipótesis

Si estas hipótesis se confirman, la presente investigación tendrá implicaciones significativas en el desarrollo de BCI accesibles. Se demostrará que los sistemas basados en EEG de bajo costo pueden ser viables, siempre que se utilicen estrategias avanzadas de procesamiento y clasificación[2].

Además, se establecerá una base metodológica robusta para futuras investigaciones, abriendo nuevas posibilidades para la integración de BCI en aplicaciones del mundo real, como:

1. Robótica asistencial para personas con discapacidad.
2. Interacción humano-máquina en entornos industriales y educativos.
3. Aplicaciones de neurofeedback para optimización cognitiva.

En conclusión, esta investigación tiene el potencial de transformar la accesibilidad y usabilidad de las BCI, acercando esta tecnología a aplicaciones prácticas con un impacto real en la vida de los usuarios.

#### 1.4. Objetivos de la Investigación

El presente estudio tiene como objetivo fundamental establecer un marco metodológico riguroso para el control de dispositivos físicos a partir de señales EEG obtenidas mediante diademas de bajo costo, explorando el papel de diferentes arquitecturas de redes neuronales en la predicción y clasificación de señales EEG. Se plantea un enfoque basado en clusterización de señales cerebrales, optimizando su procesamiento mediante modelos de aprendizaje profundo y evaluando su viabilidad para futuras implementaciones en sistemas embebidos como Jetson Nano y Raspberry Pi. Aunque la integración física de estos modelos no es el foco inmediato del estudio, su viabilidad y aplicabilidad constituyen un objetivo estratégico a largo plazo dentro del desarrollo de interfaces cerebro-computadora.

Los objetivos de esta investigación se estructuran en un objetivo general y varios objetivos específicos, orientados a la validación experimental del sistema propuesto y a la optimización del rendimiento de los modelos empleados.

##### *1.4.1. Objetivo General*

Desarrollar y evaluar un sistema BCI basado en EEG de bajo costo que permita la predicción y clasificación de señales cerebrales mediante modelos avanzados de redes neuronales, con el propósito de establecer un marco metodológico para el control de dispositivos físicos en tiempo real y su potencial integración en plataformas embebidas.

##### *1.4.2. Objetivos Específicos*

1. Evaluación de la viabilidad del uso de EEG de bajo costo en BCI
  - Analizar la calidad y estabilidad de las señales EEG obtenidas con diademas comerciales como Neurosky y Brainlink.
  - Caracterizar el impacto del ruido y la variabilidad interindividual en la precisión de la señal EEG.

- Implementar estrategias avanzadas de preprocesamiento y filtrado de señales para mejorar la robustez de los datos.
2. Modelado de señales EEG para la predicción y clasificación de estados cognitivos
    - Diseñar e implementar arquitecturas de redes neuronales recurrentes (LSTM, GRU) para la predicción de estados cognitivos como atención y meditación.
    - Evaluar la efectividad de técnicas de clusterización en la discriminación de patrones cerebrales.
    - Identificar limitaciones y potenciales mejoras en la modelización de señales EEG mediante técnicas de aprendizaje profundo.
  3. Desarrollo de un sistema de clasificación de señales EEG para el control de dispositivos físicos
    - Implementar modelos LSTM y GRU para la clasificación de comandos motores (adelante, atrás, izquierda y derecha) a partir de EEG.
    - Evaluar la estabilidad y capacidad de generalización de los modelos en distintos sujetos y condiciones experimentales.
    - Integrar técnicas de clusterización para mejorar la precisión en la clasificación de señales EEG y reducir errores en el control de dispositivos.
  4. Exploración de modelos híbridos y enfoques clásicos para la optimización de la clasificación de EEG
    - Implementar modelos XGBoost y comparar su rendimiento con redes neuronales recurrentes en la clasificación de señales EEG.
    - Evaluar la combinación de XGBoost con técnicas de clusterización para mejorar la discriminación de patrones cerebrales.
    - Analizar la integración de enfoques híbridos (redes neuronales + algoritmos clásicos) para optimizar la clasificación de EEG en entornos de control físico.
  5. Sentar las bases para la integración de modelos en plataformas embebidas
    - Evaluar la factibilidad de implementar modelos de clasificación de EEG en hardware embebido como Jetson Nano y Raspberry Pi.

- Analizar la eficiencia computacional de los modelos desarrollados para su despliegue en sistemas de bajo consumo energético.
- Proponer una arquitectura adaptable que facilite la transición del modelo hacia aplicaciones de control en tiempo real.

#### *1.4.3. Impacto y Relevancia del Estudio*

La presente investigación aborda desafíos cruciales en el ámbito de las Interfaces Cerebro-Computadora (BCI), centrándose en la optimización de la clasificación de señales EEG de bajo costo para el control autónomo de dispositivos físicos. Esta problemática es especialmente relevante para aplicaciones en robótica asistencial, accesibilidad tecnológica y rehabilitación neuromotora, áreas que requieren soluciones prácticas, asequibles y robustas. El cumplimiento de los objetivos planteados en esta tesis permitirá abordar las principales limitaciones actuales y contribuirá al avance significativo del estado del arte.

##### *1.4.3.1. Expansión de la Accesibilidad y Democratización de la Tecnología BCI*

Uno de los impactos más destacados de este estudio es la democratización del acceso a las tecnologías BCI mediante el uso de dispositivos EEG económicos como Neurosky y Brainlink. Mientras que la mayoría de las investigaciones en BCI se han centrado en equipos de grado clínico de alto costo, esta tesis busca ampliar el acceso a soluciones tecnológicas viables para poblaciones desatendidas o con recursos limitados.

Esta línea de trabajo cobra especial relevancia en contextos de asistencia a personas con discapacidades motoras, donde la adopción de sistemas BCI asequibles puede mejorar la calidad de vida y promover la independencia (Nicolas-Alonso & Gómez-Gil, 2012). Además, la facilidad de uso de los dispositivos de bajo costo abordados en esta tesis facilita su integración en entornos no clínicos, como hogares, centros educativos y espacios laborales.

#### **Oportunidad identificada:**

- Reducción de la brecha tecnológica para usuarios con limitaciones económicas.
- Promoción de la equidad en el acceso a sistemas de asistencia tecnológica.

- Aplicación en entornos rurales o comunidades con acceso limitado a servicios médicos especializados.

#### 1.4.3.2. Optimización de la Clasificación de Señales EEG para el Control de Dispositivos Físicos

La clasificación precisa de las señales EEG es fundamental para la operatividad de sistemas BCI. Esta tesis propone modelos mejorados de aprendizaje automático , incluyendo LSTM, GRU, XGBoost , híbridos con el modelo Popov, para abordar las limitaciones existentes en la detección de intenciones motoras y estados cognitivos. La optimización de estos modelos permitirá:

- Reducir la latencia en la inferencia de comandos, mejorando la respuesta del sistema en tiempo real.
- Aumentar la precisión en la predicción de comandos motores básicos y estados como la atención y la meditación.
- Mitigar la variabilidad inter e intrasujeto, lo que se traduce en una mayor estabilidad del sistema en sesiones prolongadas.

Esta optimización es especialmente relevante en aplicaciones como el control de sillas de ruedas autónomas, brazos robóticos y prótesis inteligentes, donde la velocidad y precisión son esenciales para garantizar la seguridad y eficacia del usuario[24] .

Resultados esperados:

- Mejora del rendimiento de clasificación superior al 90% de precisión en entornos no controlados.
- Disminución del tiempo de respuesta a valores por debajo de 50 ms, adecuado para control en tiempo real.
- Reducción de la necesidad de recalibraciones frecuentes gracias al uso de modelos adaptativos.

#### 1.4.3.3. Desarrollo de un Enfoque Metodológico Robusto para la Clusterización de Señales Cerebrales

La identificación y agrupación de patrones cerebrales mediante técnicas de clusterización representa una herramienta clave para mejorar la discriminación de

estados cognitivos y la predicción de intenciones motoras. Este estudio plantea la implementación de un enfoque metodológico basado en:

- Modelos híbridos que combinan la clusterización hibridando redes neuronales con modelos clásicos de estabilidad de sistemas para mejorar el rendimiento y la precisión del modelo de clasificación.

El uso de estos métodos permitirá detectar comandos mentales diferenciados y reducir la confusión entre patrones similares, lo que se traduce en un control más preciso y confiable de los dispositivos físicos.

Impacto esperado:

Mejora en la discriminación de señales EEG con tasas de clasificación superiores al 90%.

Optimización de la predicción de estados de atención y meditación, mejorando la adaptabilidad del sistema a distintas tareas.

Desarrollo de herramientas que faciliten la personalización del BCI según las características cognitivas de cada usuario.

#### 1.4.3.4. Implementación en Hardware Embebido: Camino hacia la Autonomía de los Sistemas BCI

Uno de los desafíos fundamentales en el desarrollo de BCI prácticos es la implementación de modelos en hardware embebido que permita la ejecución de algoritmos complejos en dispositivos portátiles y autónomos. Esta tesis explora la implementación de modelos optimizados en plataformas como NVIDIA Jetson Nano y Raspberry Pi, aprovechando sus capacidades de computación acelerada y bajo consumo energético.

Esta línea de investigación es crucial para garantizar la movilidad y autonomía de los sistemas BCI, facilitando su aplicación en dispositivos como:

- Sillas de ruedas autónomas controladas por EEG.
- Prótesis robóticas con retroalimentación en tiempo real.
- Exoesqueletos inteligentes para rehabilitación motora.

La posibilidad de integrar modelos de clasificación en hardware de bajo costo expande las aplicaciones prácticas de la tecnología, permitiendo que los usuarios se beneficien de sistemas BCI sin la necesidad de conexiones a infraestructuras computacionales externas.

Ventajas clave de la implementación en hardware embebido:

- **Portabilidad:** Permite el uso del sistema en entornos reales sin requerir infraestructura externa.
- **Reducción de la latencia:** Procesamiento en el dispositivo, eliminando retrasos asociados a la transmisión de datos.
- **Optimización energética:** Dispositivos como Jetson Nano y Raspberry Pi ofrecen un equilibrio ideal entre rendimiento y consumo energético.

#### 1.4.3.5. Contribución al Avance Científico y Aplicaciones Prácticas

Esta investigación no solo tiene como objetivo mejorar la clasificación y control de señales EEG en sistemas BCI, sino también proporcionar un marco metodológico sólido y replicable que pueda ser utilizado como referencia en futuras investigaciones en el campo. Al abordar la combinación de modelos híbridos, que integran técnicas de aprendizaje profundo y modelos clásicos como XGBoost, se busca establecer nuevos estándares en la implementación de algoritmos para la clasificación de señales cerebrales. Este enfoque metodológico permitirá no solo optimizar la precisión y la eficiencia computacional, sino también asegurar la adaptabilidad de los sistemas a diferentes usuarios y entornos. Además, la tesis enfatiza la importancia de desarrollar soluciones escalables que faciliten la transición de las BCI desde entornos controlados de laboratorio hacia aplicaciones prácticas en contextos clínicos, domésticos y laborales.

Los avances alcanzados tienen un potencial transformador en diversos ámbitos de aplicación. En el sector de la asistencia a personas con movilidad reducida, las mejoras en la detección y clasificación de señales EEG permitirán un control más preciso y eficiente de dispositivos como sillas de ruedas autónomas y prótesis robóticas. En los entornos laborales y educativos, la monitorización de estados cognitivos (como la atención y la carga mental) podría optimizar el rendimiento y la seguridad de los trabajadores, contribuyendo a la creación de espacios adaptativos

e inteligentes. Por otro lado, en el ámbito de la rehabilitación neurofuncional, la personalización de los modelos BCI desarrollados en esta tesis facilitará terapias más efectivas y ajustadas a las necesidades individuales de los pacientes, promoviendo así la recuperación de la funcionalidad motora y cognitiva en personas afectadas por accidentes cerebrovasculares u otras patologías neurológicas.

Un ámbito relevante de la rehabilitación neurofuncional, se enfoca en los enfermos con daños cerebrales en zonas concretas del cerebro, que afecten sustancialmente a su desempeño motor diario. Un claro ejemplo son los enfermos de ELA (Esclerosis Lateral Amiotrófica) que afecta principalmente a las motoneuronas superiores e inferiores. Las motoneuronas superiores, localizadas en la corteza motora del cerebro, y las motoneuronas inferiores, situadas en el tronco encefálico y la médula espinal[25], [26].

## 1.5. Contribuciones Originales

El presente estudio aporta una serie de contribuciones originales en el ámbito del desarrollo de interfaces cerebro-computadora (BCI) de bajo costo, con especial énfasis en la predicción y clasificación de señales EEG para el control de dispositivos físicos. Estas contribuciones se sustentan en investigaciones previas, tanto de la base de conocimiento de esta tesis como de fuentes científicas externas, consolidando un marco metodológico robusto para futuras aplicaciones en neurotecnología, robótica asistencial y accesibilidad.

### *1.5.1. Desarrollo de un Sistema BCI Basado en EEG de Bajo Costo*

Una de las principales limitaciones en la adopción de sistemas BCI en aplicaciones prácticas es el alto costo y complejidad de los dispositivos EEG convencionales. Esta investigación demuestra que es posible utilizar diademas EEG comerciales de bajo costo, como Neurosky y Brainlink, para capturar señales cerebrales que permitan controlar dispositivos físicos con una precisión aceptable.

### *1.5.2. Optimización de Modelos de Predicción de Estados Cognitivos con Redes Neuronales Recurrentes*

El estudio explora la aplicación de redes neuronales recurrentes (LSTM y GRU) para la predicción de estados cognitivos como atención y meditación, permitiendo un control más preciso y estable en aplicaciones BCI. Se comparan estos modelos en términos de precisión, estabilidad y tiempo de inferencia, proporcionando evidencia sobre sus fortalezas y limitaciones en entornos con señales EEG de bajo costo[27].

### *1.5.3. Implementación de Técnicas de Clusterización de Señales EEG para la Clasificación de Movimientos*

Se propone una metodología basada en clusterización de señales cerebrales que permite diferenciar patrones asociados a comandos motores básicos (adelante, atrás, izquierda, derecha). Este enfoque mejora la robustez de la clasificación de señales EEG y reduce la variabilidad interindividual, lo que es clave para aplicaciones en control de dispositivos físicos.

### *1.5.4. Evaluación del Uso de Modelos Clásicos en la Clasificación de Señales EEG*

El estudio introduce la comparación entre redes neuronales profundas (LSTM y GRU) y modelos clásicos como XGBoost, con el objetivo de determinar cuál ofrece un mejor rendimiento en términos de precisión y estabilidad. Adicionalmente, se evalúa la integración del modelo Popov en XGBoost, demostrando que este enfoque híbrido puede mejorar la generalización del sistema en entornos de señal EEG con alta variabilidad.

### *1.5.5. Propuesta para la Integración de Modelos en Sistemas Embebidos*

Aunque la integración de modelos en hardware embebido no es el foco central de la investigación, este estudio proporciona un marco metodológico que facilita la implementación futura de modelos de predicción y clasificación en plataformas como Jetson Nano y Raspberry Pi. Se exploran los desafíos computacionales asociados con la inferencia en tiempo real y se presentan soluciones potenciales.

### *1.5.6. Impacto Científico y Aplicaciones Futuras*

El conjunto de contribuciones de esta investigación permite ampliar las posibilidades de uso de accesibilidad tecnológica y neurofeedback. Además, el desarrollo metodológico presentado sienta las bases para la integración de estos modelos en hardware embebido, permitiendo una implementación más accesible y eficiente en entornos del mundo sistemas BCI de bajo costo, con aplicaciones potenciales en robótica asistencial, real.

Este estudio, por tanto, no solo contribuye al avance del estado del arte en BCI, sino que también proporciona una base para futuras investigaciones en el desarrollo de interfaces cerebro-computadora más accesibles, confiables y escalables

Las contribuciones originales de esta investigación abarcan desde la optimización de la predicción de estados cognitivos y la clasificación de señales EEG hasta la exploración de modelos híbridos y su potencial implementación en sistemas embebidos. Estas aportaciones consolidan un marco metodológico sólido para el desarrollo de sistemas BCI asequibles, escalables y aplicables a múltiples dominios tecnológicos y biomédicos

## **1.6. Metodología de Investigación**

El enfoque metodológico adoptado en esta investigación se fundamenta en un diseño experimental riguroso orientado a la validación de un sistema de clasificación de señales EEG de bajo costo para el control de dispositivos físicos. Se plantea una metodología basada en el análisis comparativo de arquitecturas de redes neuronales y modelos clásicos, complementado con un proceso de evaluación experimental en entornos controlados. Esta estrategia permite evaluar la viabilidad, eficacia y aplicabilidad del sistema BCI propuesto.

### *1.6.1. Enfoque General*

El estudio sigue una metodología cuantitativa basada en el diseño y validación de modelos de clasificación de señales EEG mediante técnicas de aprendizaje profundo y aprendizaje automático. La investigación se desarrolla en las siguientes fases:

1. Captura y preprocesamiento de señales EEG obtenidas con diademas comerciales de bajo costo.
2. Implementación y evaluación de arquitecturas de redes neuronales recurrentes (LSTM y GRU) para la predicción de estados cognitivos.
3. Comparación de modelos clásicos (XGBoost y Popov) con redes neuronales para la clasificación de comandos motores.
4. Validación experimental en entornos controlados, midiendo el rendimiento del sistema en sujetos humanos.
5. Análisis de viabilidad para la integración del modelo en plataformas embebidas, como Jetson Nano y Raspberry Pi.

Cada una de estas fases se ejecuta de manera secuencial, permitiendo una evaluación progresiva del desempeño del sistema BCI.

#### *1.6.2. Captura y Preprocesamiento de Señales EEG*

La recopilación de datos EEG se realiza con dispositivos comerciales de bajo costo, como Neurosky y Brainlink, en sujetos humanos voluntarios. Se establecen protocolos experimentales estandarizados para garantizar la calidad y la comparabilidad de los datos.

El preprocesamiento incluye:

1. Filtrado de señales para eliminar artefactos electromiográficos, parpadeos y ruido externo.
2. Normalización y segmentación de las señales en ventanas temporales.
3. Extracción de características relevantes, como bandas de frecuencia y correlaciones temporales.

#### *1.6.3. Implementación de Modelos de Aprendizaje Profundo y Clásico*

Se comparan distintos enfoques de clasificación de señales EEG:

- Modelos basados en redes neuronales recurrentes (LSTM y GRU), evaluando su capacidad para modelar dependencias temporales en la predicción de estados cognitivos.

- Modelos clásicos de aprendizaje automático (XGBoost y Popov), analizando su robustez en la clasificación de comandos motores y su eficiencia computacional.
- Estrategias híbridas, combinando redes neuronales y técnicas de aprendizaje clásico para optimizar la precisión del sistema.

Cada modelo es entrenado y validado utilizando un conjunto de datos EEG balanceado y evaluado con métricas estandarizadas, como precisión, recall y F1-score.

#### *1.6.4. Validación Experimental en Entornos Controlados*

Para validar el desempeño del sistema propuesto, se llevan a cabo experimentos en entornos controlados con sujetos voluntarios. Se diseñan protocolos de prueba con:

1. Evaluación de la predicción de estados cognitivos (atención y meditación) en condiciones estandarizadas.
2. Pruebas de clasificación de comandos motores, comparando la precisión y latencia de cada modelo evaluado.
3. Medición de la usabilidad y robustez del sistema, analizando la tasa de error y la capacidad de adaptación a diferentes usuarios.

Los datos obtenidos se analizan estadísticamente para determinar la eficacia de cada enfoque y su aplicabilidad en escenarios del mundo real.

#### *1.6.5. Evaluación de Viabilidad en Sistemas Embebidos*

Aunque la integración física del modelo en hardware embebido no es el foco principal de este estudio, se realiza un análisis exploratorio de su viabilidad. Se examina la posibilidad de implementar los modelos en Jetson Nano y Raspberry Pi, considerando:

- Requerimientos computacionales y optimización de recursos.
- Tiempo de inferencia en hardware embebido.
- Posibles aplicaciones en robótica asistencial y neurotecnología accesible.

Este análisis permite proyectar la aplicabilidad futura del sistema BCI en dispositivos portátiles y de bajo consumo energético.

#### 1.6.6. Análisis de Resultados y Consideraciones Finales

Los datos recolectados y los modelos evaluados serán analizados de manera cuantitativa mediante:

- Métricas de rendimiento de clasificación: Precisión, sensibilidad, especificidad, F1-score.
- Comparación estadística entre modelos: Pruebas de significancia y validación cruzada.
- Evaluación de estabilidad y robustez del sistema en distintos escenarios experimentales.

Con base en estos análisis, se extraerán conclusiones sobre la viabilidad del enfoque propuesto, identificando fortalezas y limitaciones, así como posibles mejoras en futuras investigaciones.

### 1.7. Lista de Publicaciones

#### **Publicaciones generadas en esta tesis.**

##### Artículos de Revista

- Rivas, F., Sierra, J. E., & Cámara, J. M. (2024). Architectural Proposal for Low-Cost Brain–Computer Interfaces with ROS Systems for the Control of Robotic Arms in Autonomous Wheelchairs.

*Electronics*, 13(6), 1013. <https://doi.org/10.3390/electronics13061013>

- Rivas, F., Sierra-Garcia, J. E., & Camara, J. M. (2025). Comparison of LSTM- and GRU-Type RNN Networks for Attention and Meditation Prediction on Raw EEG Data from Low-Cost Headsets.

*Electronics*, 14(4), 707. <https://doi.org/10.3390/electronics14040707>

Datos de calidad de las publicaciones: (Fuente <https://investigacion.ubu.es/>)

#### **Journal Impact Factor - JIF (JCR)**

(Indicador correspondiente al último año disponible en este portal, año 2023)

- Año [2023](#)
- Factor de impacto de la revista: 2.6
- Factor de impacto sin autocitas: 2.3
- Cuartil mayor: Q2
- Área: ENGINEERING, ELECTRICAL & ELECTRONIC Cuartil: **Q2** Posición en el área: **157/353** (Edición: SCIE)
- Área: PHYSICS, APPLIED Cuartil: **Q2** Posición en el área: **81/179** (Edición: SCIE)
- Área: COMPUTER SCIENCE, INFORMATION SYSTEMS Cuartil: **Q2** Posición en el área: **115/250** (Edición: SCIE)

### SJR data from SCImago




Figura 6 : Estadísticas JCR de la publicación

## 1.8. Estructura de la Tesis

La presente tesis doctoral, titulada "Contribuciones al Control de Dispositivos Físicos Mediante Sistemas EEG de Bajo Coste", se estructura en nueve capítulos organizados de manera lógica y progresiva, presentando los fundamentos teóricos, metodologías implementadas, evaluación experimental y análisis detallado de resultados obtenidos.

El **Capítulo 1** ofrece una introducción completa al contexto y motivación del estudio, exponiendo el problema de investigación, hipótesis formuladas, objetivos específicos, contribuciones originales y la metodología general aplicada.

En el **Capítulo 2** se presentan los fundamentos teóricos esenciales, abordando conceptos clave de neurociencia computacional, interfaces cerebro-computadora (BCI), caracterización de señales EEG con dispositivos comerciales como Neurosky, modelos avanzados de aprendizaje profundo y consideraciones éticas y regulatorias en robótica asistencial.

El **Capítulo 3** detalla las herramientas tecnológicas utilizadas, tanto en software como hardware, que soportan la adquisición y procesamiento de señales EEG, destacando especialmente las plataformas y dispositivos empleados en la investigación.

El **Capítulo 4** analiza críticamente el estado actual del arte, identificando modelos y enfoques existentes en el uso de EEG para control de dispositivos físicos, destacando las limitaciones actuales y oportunidades detectadas en el campo.

En el **Capítulo 5** se define la propuesta central del trabajo, especificando claramente la arquitectura diseñada para el control de sillas de ruedas mediante sistemas EEG. Incluye una justificación exhaustiva del hardware seleccionado y la metodología para integrar señales EEG con sistemas de control físico.

El **Capítulo 6** desarrolla detalladamente la predicción de valores de atención y meditación usando redes neuronales recurrentes (LSTM y GRU), cubriendo la justificación del modelo seleccionado, el proceso de adquisición y preprocesamiento, implementación de modelos y evaluación comparativa de resultados.

El **Capítulo 7** aborda en tres fases la clasificación de señales EEG para el control de movimientos, detallando la metodología experimental, el proceso de etiquetado, implementación y evaluación comparativa entre redes LSTM, GRU, y modelos alternativos como LSTM+Popov, GRU+Popov y XGBoost, además de analizar su eficiencia computacional, terminando con el despliegue del clasificador para uso

como aplicación. Además se incorpora el correspondiente análisis y validación del modelo.

Finalmente, el **Capítulo 8** sintetiza las conclusiones del trabajo, resaltando las principales contribuciones, evaluando el impacto en el desarrollo de sistemas BCI, reconociendo las limitaciones encontradas y planteando claramente las líneas futuras de investigación en este ámbito.

### *1.8.1. Organización General del Documento*

La presente tesis doctoral se estructura en once capítulos que desarrollan de manera progresiva y exhaustiva la investigación realizada. Cada capítulo ha sido cuidadosamente diseñado para abordar aspectos específicos del trabajo, contribuyendo al objetivo global de desarrollar un sistema BCI robusto y accesible basado en diademas EEG de bajo coste.

## **Capítulo 1: Introducción**

Este capítulo inicial establece los cimientos conceptuales y motivacionales de la investigación. Comienza con una contextualización profunda del campo de las interfaces cerebro-computadora, destacando la evolución desde sistemas altamente especializados hacia soluciones más accesibles. Se presenta el problema fundamental de la investigación: la necesidad de desarrollar sistemas BCI eficientes y asequibles utilizando diademas EEG de bajo coste. Las hipótesis de trabajo se formulan de manera precisa, estableciendo las bases para su posterior validación experimental. Los objetivos, tanto generales como específicos, se detallan con claridad, vinculándolos directamente con las contribuciones originales esperadas. La metodología de investigación se describe en profundidad, justificando cada decisión tomada en el diseño experimental.

## **Capítulo 2: Fundamentos Teóricos**

Este capítulo proporciona el marco teórico esencial para comprender la investigación. Se inicia con una exposición detallada de los principios de neurociencia computacional y el procesamiento de señales EEG, abordando tanto aspectos fisiológicos como técnicos. Se profundiza en la teoría de las

interfaces cerebro-computadora, examinando arquitecturas, protocolos y paradigmas de control. Los modelos de aprendizaje profundo relevantes para el procesamiento de EEG se analizan en detalle, con especial énfasis en las redes LSTM y GRU. Se incluye una sección dedicada a la robótica asistencial y el control autónomo, estableciendo las bases para la integración de señales EEG en el control de dispositivos físicos. El capítulo concluye con una discusión exhaustiva sobre las consideraciones éticas y el marco regulatorio aplicable.

### **Capítulo 3: Herramientas Utilizadas**

Este capítulo presenta una descripción detallada y justificada de las herramientas específicas, tanto software como hardware, seleccionadas para el desarrollo efectivo de la presente investigación. En primer lugar, se describen las herramientas de software, destacando plataformas y bibliotecas utilizadas para la adquisición, procesamiento avanzado y clasificación precisa de las señales EEG capturadas. Además, se aborda el uso estratégico del entorno Google Colab como sandbox computacional para mejorar sustancialmente los tiempos de entrenamiento e inferencia de las redes neuronales recurrentes (RNN), respecto al uso tradicional de equipos locales.

Seguidamente, se detalla el empleo de diversas herramientas de inteligencia artificial generativa (IA generativa), tales como ChatGPT en diferentes versiones, Claude, Gemini, Napkin, Elicit, DeepL, Storm (Stanford University), Perplexity, FreePik, Dalle, NoteBookLM y Grok. Cada una de estas herramientas es descrita en términos de sus capacidades específicas y su contribución a la mejora sustancial en la calidad y eficiencia de las tareas desarrolladas durante el trabajo de investigación.

En la segunda parte del capítulo se presentan las herramientas de hardware utilizadas, enfatizando especialmente en los dispositivos EEG comerciales de bajo coste, como Neurosky y Brainlink. También se detalla el empleo de plataformas embebidas especializadas, destacando principalmente Jetson Nano, por sus capacidades para ejecutar modelos complejos de inteligencia

artificial en tiempo real, y la Raspberry Pi5, integrada con el módulo Hailo, como una alternativa viable que aporta una comunidad de usuarios más amplia y acceso simplificado a recursos de desarrollo, manteniendo un desempeño óptimo en aplicaciones de BCI.

#### **Capítulo 4: Estado del Arte y Limitaciones Actuales**

En este capítulo se realiza una revisión crítica y sistemática del estado actual de la tecnología. Se examina en profundidad el uso de EEG en el control de dispositivos físicos, analizando tanto éxitos como limitaciones. Los modelos de aprendizaje automático aplicados a la clasificación de señales EEG se evalúan comparativamente, identificando fortalezas y debilidades. Se presta especial atención a las redes LSTM y GRU en la predicción de estados cognitivos, así como a los modelos clásicos como XGBoost y Popov. Las limitaciones actuales en la clasificación y control de dispositivos se analizan desde múltiples perspectivas: técnica, práctica y económica. El capítulo culmina con una identificación detallada de brechas en el conocimiento y oportunidades de investigación.

#### **Capítulo 5: Definición de la Propuesta**

Este capítulo presenta la propuesta central de la investigación: el uso de señales EEG de diademas de bajo coste para el control de dispositivos físicos. Se justifica exhaustivamente la selección de dispositivos EEG comerciales, analizando sus capacidades y limitaciones. La caracterización de las señales EEG capturadas con Neurosky se realiza de manera rigurosa, empleando métodos avanzados de análisis de señales. Se describe detalladamente el hardware utilizado en la adquisición de datos, incluyendo especificaciones técnicas y consideraciones de implementación. La integración de las señales EEG con sistemas de control de dispositivos físicos se explica con precisión, abordando aspectos de conectividad, procesamiento y control en tiempo real.

#### **Capítulo 6: Predicción de Valores de Atención y Meditación**

Este capítulo aborda el desarrollo de modelos predictivos basados en redes LSTM y GRU. Se justifica rigurosamente la selección de estas arquitecturas para la predicción de EEG, respaldada por evidencia experimental. El proceso de adquisición y preprocesamiento de señales se detalla minuciosamente, incluyendo protocolos de filtrado y normalización. La implementación de los modelos LSTM y GRU se describe con precisión técnica, abordando aspectos como la arquitectura de las redes, algoritmos de optimización y técnicas de regularización. Se realiza una comparación exhaustiva del rendimiento entre ambas arquitecturas, respaldada por métricas cuantitativas. Los resultados se evalúan críticamente, analizando errores y limitaciones. El impacto de la predicción en aplicaciones BCI se discute en profundidad.

## **Capítulo 7: Clasificación de Señales EEG para Control de movimientos**

Este capítulo se centra en la clasificación de señales EEG para controlar movimientos mediante interfaces cerebro-computadora (BCI). Se establece una metodología experimental detallada que describe cómo se adquieren y etiquetan las señales según comandos específicos como avanzar, retroceder, y girar.

Se implementan y comparan redes neuronales recurrentes como LSTM y GRU, destacando su capacidad para capturar dependencias temporales de las señales EEG. Además, se analizan variantes estabilizadas (LSTM+Popov y GRU+Popov) para mejorar la robustez frente al ruido y variabilidad interindividual.

También se comparan estos modelos con algoritmos clásicos como XGBoost en términos de precisión, recall, F1-score y eficiencia computacional, especialmente relevantes para aplicaciones en dispositivos embebidos. Los resultados muestran que XGBoost ofrece ventajas significativas en velocidad y eficiencia.

Finalmente, el capítulo analiza limitaciones como el sobreajuste y la variabilidad intersujeto, proponiendo recomendaciones futuras en técnicas

de preprocesamiento y modelos híbridos para optimizar la precisión y eficiencia en aplicaciones reales de BCI.

## Capítulo 8: Conclusiones y Trabajos Futuros

El capítulo final sintetiza las contribuciones de la investigación y proyecta su desarrollo futuro. Las contribuciones se resumen de manera estructurada y fundamentada. El impacto en el desarrollo de sistemas BCI se evalúa críticamente. Las limitaciones del estudio se analizan con honestidad académica. Las líneas de investigación futura se proponen con visión estratégica, incluyendo aspectos como la exploración de modelos basados en Transformers, el uso de aprendizaje federado, la integración con sensores biométricos adicionales y aplicaciones en ambientes clínicos y domésticos.

### 1.8.2. Esquema Visual de la Estructura de la Tesis

Para facilitar la comprensión de la organización del documento, se presenta el siguiente esquema visual:

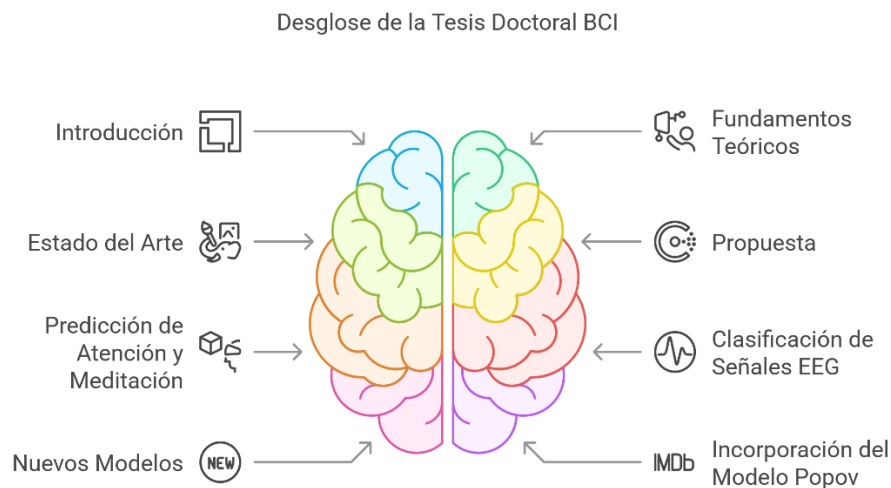


Figura 7: Desglose de tesis

### 1.8.3. Relación entre los Capítulos

La estructura de esta tesis doctoral ha sido elaborada estratégicamente con el propósito de mantener una coherencia conceptual sólida y una progresión temática fluida. Cada capítulo posee una función específica y relevante que

contribuye directamente al logro de los objetivos generales, estableciendo conexiones críticas entre los diferentes apartados.

El Capítulo 1, titulado "Introducción", sirve como la piedra angular del trabajo, proporcionando una contextualización profunda y detallada del problema investigado. Aquí se plantean claramente las hipótesis de trabajo, se delimitan los objetivos particulares, y se detallan las contribuciones originales previstas por la investigación. Este capítulo funciona como marco referencial permanente, siendo continuamente retomado y validado a lo largo del desarrollo del estudio.

El Capítulo 2, denominado "Fundamentos Teóricos", establece la base teórico-científica fundamental requerida para abordar integralmente la investigación. En él se exponen conceptos avanzados de neurociencia computacional, interfaces cerebro-computadora (BCI), procesamiento de señales EEG y técnicas sofisticadas de aprendizaje profundo. Este capítulo sustenta de manera crucial los desarrollos metodológicos específicos presentados en capítulos posteriores, particularmente en los capítulos 5, 6 y 7.

El Capítulo 3, "Herramientas utilizadas", es un componente clave que describe minuciosamente las tecnologías empleadas en la investigación. Se detalla exhaustivamente el software especializado y el hardware seleccionado, destacando su importancia práctica para la adquisición, procesamiento y análisis riguroso de los datos EEG. Este capítulo permite al lector obtener una visión precisa de los recursos técnicos utilizados para implementar las propuestas metodológicas posteriores.

En el Capítulo 4, "Estado del Arte y Limitaciones Actuales", se realiza un análisis crítico y detallado de la literatura científica actual en el campo de las BCI y las señales EEG. Este análisis identifica explícitamente brechas y deficiencias en la investigación existente, sirviendo como justificación sólida y fundamentada para la propuesta innovadora presentada en el capítulo siguiente. De esta manera, el capítulo sitúa claramente la aportación específica de esta tesis dentro del panorama académico y tecnológico actual.

El Capítulo 5, "Definición de la Propuesta", constituye el núcleo central de la investigación. Aquí se presenta con detalle la arquitectura propuesta para el sistema BCI orientado al control de dispositivos físicos mediante señales EEG. Este capítulo establece claramente las metodologías específicas que serán desarrolladas y validadas posteriormente en los capítulos 6 y 7, asegurando que cada decisión técnica esté estrechamente vinculada a la problemática identificada en el capítulo previo.

El Capítulo 6, "Predicción de Valores de Atención y Meditación Usando Redes LSTM y GRU", profundiza en la implementación práctica de los modelos predictivos mencionados en el capítulo 5. Este apartado mantiene un vínculo directo con los fundamentos teóricos expuestos en el capítulo 2, realizando una validación empírica rigurosa de las hipótesis iniciales.

El Capítulo 7, "Clasificación de Señales EEG para el Control de Movimientos", expande significativamente la aplicación práctica de los modelos discutidos previamente, particularmente los del capítulo 6. Se realiza un análisis meticuloso y comparaciones detalladas entre diversas arquitecturas, con el objetivo de determinar aquellas que ofrecen mayor precisión y eficacia en la clasificación de señales EEG, manteniendo una coherencia metodológica rigurosa.

Por último, el Capítulo 8, "Conclusiones y Trabajos Futuros", sintetiza de manera reflexiva los aportes más relevantes, los resultados obtenidos y las discusiones previas. Este capítulo reconoce explícitamente las limitaciones del estudio y formula recomendaciones concretas para futuras investigaciones, asegurando una continuidad lógica y ofreciendo nuevas líneas de exploración y profundización científica.

Esta estructura interrelacionada asegura que la tesis funcione como un documento cohesivo donde cada capítulo contribuye de manera significativa al desarrollo del argumento central, manteniendo una progresión lógica desde los fundamentos teóricos hasta las conclusiones y aplicaciones prácticas. La bidireccionalidad de las relaciones entre capítulos permite una validación continua de los desarrollos presentados y facilita la comprensión integral de la investigación realizada.

#### 1.8.4. Justificación de la Estructura

La organización adoptada responde a varios criterios fundamentales:

1. Coherencia Metodológica
  - Establece una base conceptual sólida antes de introducir los desarrollos técnicos
  - Garantiza que cada capítulo construya sobre el conocimiento previo
  - Facilita la validación progresiva de las hipótesis
2. Claridad Expositiva
  - Mantiene una progresión lógica en la presentación de conceptos
  - Facilita la comprensión de las contribuciones originales
  - Permite seguir el desarrollo de la investigación de manera natural
3. Documentación Rigurosa
  - Asegura la reproducibilidad de los experimentos
  - Proporciona detalles suficientes sobre implementación y validación
  - Facilita la verificación de los resultados
4. Enfoque Aplicado
  - Vincula los desarrollos teóricos con aplicaciones prácticas
  - Demuestra la viabilidad de las soluciones propuestas
  - Facilita la transferencia tecnológica
5. Transferencia de Conocimiento
  - Promueve la aplicación práctica de los resultados
  - Identifica oportunidades para investigaciones futuras
  - Facilita la adopción de las soluciones propuestas

Esta estructura no solo cumple con los estándares académicos más exigentes, sino que también optimiza la presentación del trabajo realizado, permitiendo que cada capítulo contribuya significativamente al desarrollo del conocimiento en interfaces cerebro-computadora. El diseño facilita tanto la lectura secuencial como la consulta específica de secciones particulares, maximizando su utilidad como referencia para futuros investigadores en el campo.

## 2. Fundamentos Teóricos

La comprensión profunda de las interfaces cerebro-computadora (BCI) requiere una base sólida en neurociencia computacional y en el procesamiento de señales EEG. En este capítulo se abordan los conceptos teóricos esenciales que sustentan la investigación, proporcionando el marco necesario para el desarrollo de modelos de aprendizaje profundo aplicados a la clasificación y predicción de señales EEG.

### 2.1. Neurociencia Computacional y Procesamiento de Señales EEG

La neurociencia computacional se ocupa del modelado y análisis matemático de la actividad neuronal con el fin de comprender los mecanismos subyacentes a la función cerebral. En el contexto de BCI, el objetivo es traducir la actividad neuronal en comandos que permitan la interacción directa entre el cerebro y dispositivos electrónicos.

Las señales electroencefalográficas (EEG) representan una de las herramientas más utilizadas en la neurociencia computacional aplicada a BCI debido a su capacidad para capturar la actividad neuronal de forma no invasiva. Estas señales reflejan las oscilaciones eléctricas generadas por la interacción sináptica de redes neuronales corticales y son comúnmente utilizadas en aplicaciones de control de dispositivos, diagnóstico clínico y estudios de neuro cognición[28].

#### *2.1.1. Características de las Señales EEG*

Las señales EEG se caracterizan por su baja amplitud, generalmente en el rango de 10-100  $\mu$ V, y su distribución en distintas bandas de frecuencia[29]:

- Delta (0.5-4 Hz): Asociada con sueño profundo y estados inconscientes.
- Theta (4-8 Hz): Relacionada con la relajación profunda y procesos de memoria.
- Alpha (8-12 Hz): Presente en estados de reposo y relajación sin actividad cognitiva intensa.
- Beta (12-30 Hz): Asociada con la actividad cognitiva, toma de decisiones y control motor.

- Gamma (>30 Hz): Vinculada a procesos cognitivos de alto nivel y percepción sensorial.

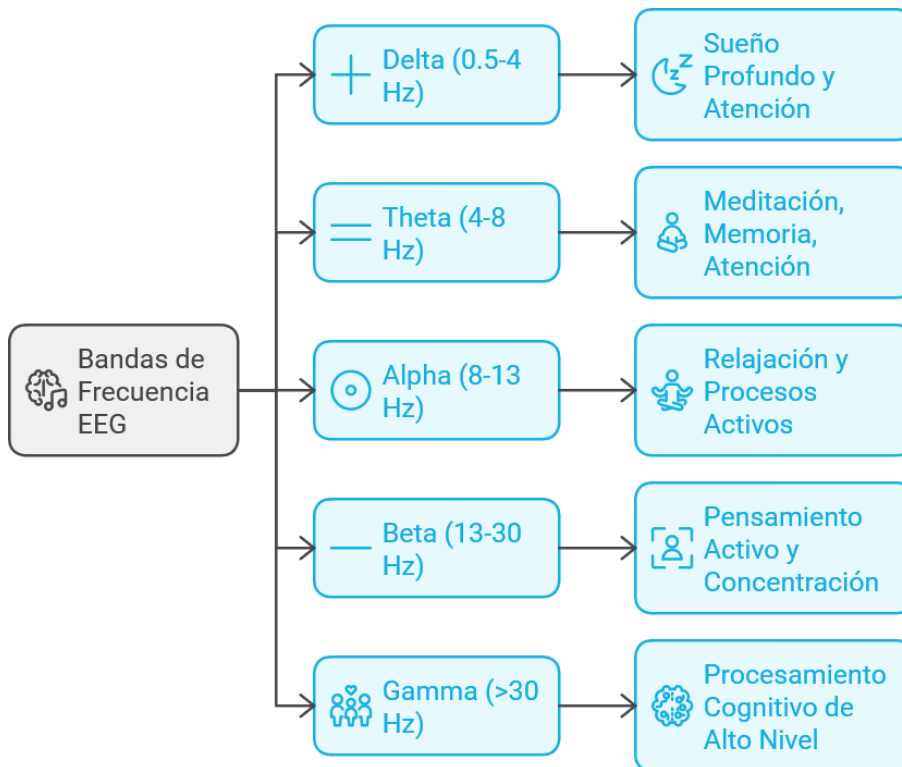


Figura 8: Bandas de frecuencias de señales EEG

Cada una de estas bandas de frecuencia tiene aplicaciones específicas en BCI y se ha demostrado que su manipulación mediante algoritmos de aprendizaje profundo permite la predicción de estados cognitivos y la generación de comandos de control[30].

### 2.1.2. Métodos de Adquisición y Procesamiento de EEG

Los datos EEG pueden ser adquiridos mediante electrodos, tanto secos como húmedos, colocados sobre el cuero cabelludo, organizados según el sistema internacional 10-20 (Jasper, 1958). La adquisición de señales EEG requiere un preprocesamiento adecuado para minimizar artefactos y mejorar la calidad de la señal. Los métodos más utilizados incluyen:

- **Filtrado de artefactos:** Eliminación de ruido electromagnético y señales espurias mediante técnicas como el Filtro de Kalman Adaptativo[31], [32].

- **Normalización y segmentación:** Se utilizan algoritmos como Empirical Mode Decomposition (EMD) para descomponer la señal en componentes intrínsecos[33].

**Extracción de características:** Se emplean métricas como la Transformada Rápida de Fourier (FFT) y la Wavelet Transform para analizar la distribución espectral de las señales EEG[34].

### *2.1.3. Aplicaciones del Procesamiento de EEG en BCI*

El procesamiento de señales electroencefalográficas (EEG) es fundamental para el desarrollo de las Interfaces Cerebro-Computadora (BCI), facilitando la traducción de la actividad cerebral en comandos que permiten a los usuarios interactuar con dispositivos externos. Las aplicaciones del procesamiento de EEG abarcan diversos campos, desde la asistencia médica hasta el entretenimiento y la industria. A continuación, se presentan las principales áreas de aplicación, destacando sus avances recientes y las oportunidades que ofrecen.

#### **a) Aplicaciones Médicas y de Rehabilitación**

El ámbito médico es uno de los principales beneficiarios de las tecnologías BCI basadas en EEG. Estas interfaces se utilizan para ayudar a personas con discapacidades motoras severas, como tetraplejia o esclerosis lateral amiotrófica (ELA), permitiéndoles controlar dispositivos como sillas de ruedas, prótesis robóticas y sistemas de comunicación alternativa. La rehabilitación neurofuncional también se ha visto beneficiada, empleando BCI para la recuperación motora de pacientes con accidentes cerebrovasculares. Estudios recientes han demostrado que el uso de señales EEG para inducir movimientos a través de exoesqueletos puede promover la neuro plasticidad y acelerar la recuperación[35].

#### **b) Control de Dispositivos y Robótica Asistencial**

El procesamiento de EEG en BCI se ha utilizado ampliamente para el control de dispositivos físicos, especialmente en la robótica asistencial. Usuarios con movilidad reducida pueden operar sillas de ruedas inteligentes o brazos robóticos a través de la imaginación motora o la concentración[36]. Estos sistemas no solo mejoran la autonomía de los pacientes, sino que también

permiten una interacción más natural con el entorno. Investigaciones recientes han demostrado la viabilidad de estos sistemas en entornos del mundo real, destacando la importancia de modelos de clasificación eficientes y de bajo retardo para garantizar la seguridad y la eficacia[37].

### **c) Neuro ergonomía y Monitorización Cognitiva**

En el campo de la neuro ergonomía, el procesamiento de EEG se utiliza para evaluar y monitorear la carga cognitiva, la atención y el estado emocional de los usuarios en tiempo real. Estas aplicaciones son especialmente relevantes en entornos de trabajo donde la seguridad es crucial, como la aviación, la conducción de vehículos y la operación de maquinaria pesada. Monitorear la fatiga y la atención puede prevenir accidentes y mejorar la productividad. Estudios como el de Alvarado et al. (2016) han explorado el uso de EEG para detectar estados de somnolencia en conductores, logrando resultados prometedores para la implementación de sistemas de alerta temprana[38].

### **d) Educación y Entrenamiento Cognitivo**

Las BCI basadas en EEG se están utilizando cada vez más en la educación y el entrenamiento cognitivo para monitorizar la atención de los estudiantes y personalizar el contenido de aprendizaje en función de sus estados mentales. Esta tecnología permite desarrollar sistemas adaptativos que mejoran la retención de información y la motivación. Un ejemplo destacado es el proyecto BrainGYM, desarrollado por el Grupo de Ingeniería Biomédica de la Universidad de Valladolid. Este proyecto tiene como objetivo digitalizar el entrenamiento cognitivo mediante sistemas BCI, combinando ejercicio físico y autoevaluación neuropsicológica para prevenir los efectos del envejecimiento. Aunque su enfoque principal es el envejecimiento activo, las herramientas y metodologías desarrolladas pueden ser aplicables en contextos educativos para mejorar las funciones cognitivas de los estudiantes[39], [40], [41].

### **e) Entretenimiento y Realidad Virtual (VR)**

El sector del entretenimiento ha encontrado en el procesamiento de EEG un nuevo medio para la creación de experiencias inmersivas. Videojuegos controlados por la actividad cerebral y sistemas de realidad virtual que responden a las emociones del usuario están ganando popularidad. Empresas como Emotiv han desarrollado dispositivos comerciales que permiten a los usuarios interactuar con aplicaciones de VR utilizando únicamente la actividad cerebral, mejorando la inmersión y la personalización de la experiencia [42].

#### **f) Comunicación Alternativa y Aumentativa (CAA)**

Para personas con discapacidades severas que limitan la comunicación verbal y motora, las BCI basadas en EEG ofrecen soluciones innovadoras para facilitar la interacción con el entorno[43]. Sistemas como el P300 speller permiten que los usuarios seleccionen letras o palabras simplemente enfocando su atención en estímulos visuales específicos, lo que ha demostrado ser eficaz en pacientes con síndrome de enclaustramiento o ELA [44].

#### **g) Seguridad y Defensa**

En el campo de la seguridad y la defensa, las BCI se utilizan para monitorear el estado de alerta de los soldados, detectar estrés y mejorar la toma de decisiones en situaciones de alta presión. Investigaciones recientes exploran la posibilidad de utilizar EEG para controlar drones y otros sistemas de armamento remoto, lo que podría transformar la forma en que se llevan a cabo las operaciones militares[45].

El procesamiento de señales EEG en aplicaciones BCI ha avanzado notablemente, abarcando campos tan diversos como la medicina, la educación, el entretenimiento y la defensa. La capacidad de traducir la actividad cerebral en comandos para controlar dispositivos físicos y sistemas digitales abre un amplio abanico de posibilidades para mejorar la calidad de vida, optimizar procesos y crear nuevas formas de interacción humano-máquina. No obstante, para que estas tecnologías sean plenamente adoptadas en la sociedad, es esencial seguir investigando sobre la mejora de la precisión, la reducción de la latencia y la

accesibilidad a dispositivos de bajo costo. La investigación y los avances continuos en este campo prometen revolucionar la forma en que las personas interactúan con la tecnología, ofreciendo soluciones innovadoras para problemas complejos y necesidades no cubiertas.

#### *2.1.4. Estudios Relevantes en Neurociencia Computacional y EEG*

La neurociencia computacional es un campo interdisciplinario que utiliza modelos matemáticos, simulaciones y herramientas computacionales para comprender el funcionamiento del sistema nervioso. En combinación con la electroencefalografía (EEG), esta disciplina ha permitido avances significativos en la interpretación de la actividad cerebral, la identificación de patrones neuronales y la creación de aplicaciones prácticas en áreas como las interfaces cerebro-computadora (BCI), la neuro rehabilitación y el monitoreo cognitivo[46], [47]. En este apartado se presentan estudios recientes y relevantes que han contribuido al entendimiento y aplicación del procesamiento de señales EEG dentro del marco de la neurociencia computacional.

#### **a) Modelado de Dinámicas Cerebrales y Oscilaciones Neuronales**

Uno de los principales focos de investigación en neurociencia computacional ha sido el modelado de las dinámicas cerebrales y la comprensión de las oscilaciones neuronales que subyacen a procesos cognitivos como la atención, la memoria y la toma de decisiones. Las oscilaciones cerebrales, detectables mediante EEG, se han utilizado para identificar patrones característicos asociados con diferentes estados mentales y enfermedades neurológicas[48]. Estudios previos, proponen modelos computacionales que simulan la conectividad funcional del cerebro, revelando cómo la sincronización de redes neuronales puede explicar fenómenos como la epilepsia o las alteraciones cognitivas en la esquizofrenia.

#### **b) Aplicaciones en la Detección de Enfermedades Neurológicas**

El uso de EEG combinado con modelos computacionales ha demostrado ser una herramienta valiosa para la detección temprana y el monitoreo de

enfermedades neurológicas como el Alzheimer, la epilepsia y el Parkinson. La capacidad de estos modelos para extraer patrones complejos de las señales EEG permite identificar biomarcadores asociados con la progresión de estas enfermedades. Miranda C et al. (2023) propone un enfoque basado en teoría de redes complejas para el análisis de EEG en pacientes epilépticos, logrando una clasificación precisa de crisis mediante medidas de sincronización cerebral[49].

### **c) Modelos Computacionales para Interfaces Cerebro-Computadora (BCI)**

La neurociencia computacional ha sido fundamental para el desarrollo de BCI eficientes, especialmente en la creación de algoritmos capaces de traducir la actividad cerebral en comandos precisos. Investigaciones recientes se han centrado en la integración de modelos de aprendizaje profundo con redes neuronales tradicionales para mejorar la clasificación de señales EEG. Roy et al. (2022) realizaron una revisión exhaustiva de métodos basados en deep learning para EEG, concluyendo que las arquitecturas híbridas, como las combinaciones de redes neuronales convolucionales (CNN) con redes recurrentes (LSTM), ofrecen resultados superiores en la interpretación de patrones cerebrales complejos[50].

### **d) Avances en Neuro plasticidad y Rehabilitación Mediante Modelos Computacionales**

La capacidad del cerebro para reorganizarse y formar nuevas conexiones neuronales, conocida como neuro plasticidad, ha sido ampliamente estudiada mediante la integración de EEG y simulaciones computacionales. Estos modelos permiten predecir cómo la estimulación cerebral no invasiva puede promover la recuperación funcional después de lesiones neurológicas. Biasiucci et al. (2018) demostraron que la activación de patrones específicos de EEG, combinada con estimulación eléctrica funcional, puede inducir cambios duraderos en la conectividad cerebral, acelerando la recuperación motora en pacientes con accidentes cerebrovasculares[35].

### **e) Investigaciones en Estados Cognitivos y Emocionales**

El procesamiento de EEG ha sido utilizado para explorar la relación entre las señales cerebrales y estados cognitivos como la atención, la carga mental y las emociones. Estos estudios son fundamentales para aplicaciones en neuro ergonomía, educación y entretenimiento. Chaouachi et al. (2011) desarrollaron modelos computacionales para evaluar la carga mental en tareas de vigilancia, utilizando medidas extraídas de EEG para predecir niveles de fatiga y atención[51]. Esta línea de investigación es clave para diseñar sistemas adaptativos que respondan dinámicamente al estado mental del usuario.

### **f) Modelos Predictivos para el Diagnóstico Precoz de Trastornos Mentales**

La neurociencia computacional también ha explorado la creación de modelos predictivos para identificar de manera temprana trastornos mentales como la depresión y la esquizofrenia. Estos modelos permiten detectar patrones cerebrales que no son evidentes mediante métodos convencionales de análisis de EEG desembocando en el estudio de un modelo basado en redes neuronales profundas para predecir episodios depresivos lo que sugiere un potencial clínico para intervenciones preventivas[52].

### **g) Aplicaciones en la Mejora del Rendimiento Cognitivo y Deportivo**

Otra área emergente es el uso de EEG y neurociencia computacional para mejorar el rendimiento cognitivo y físico. Las investigaciones han demostrado que el entrenamiento mental, combinado con neurofeedback, puede potenciar la concentración, reducir la ansiedad y mejorar la toma de decisiones en situaciones de alta presión, explorando cómo la monitorización en tiempo real de las ondas cerebrales puede ser utilizada para optimizar el rendimiento en deportes de precisión[53].

Los avances en neurociencia computacional y el procesamiento de señales EEG han transformado la manera en que se estudia y comprende la actividad cerebral. La combinación de modelos matemáticos, simulaciones y aprendizaje automático

ha permitido desarrollar herramientas que no solo ayudan a diagnosticar enfermedades neurológicas y mejorar la rehabilitación, sino que también abren nuevas vías en la educación, el entretenimiento y la mejora del rendimiento humano. La investigación en este campo sigue evolucionando rápidamente, impulsada por los avances en hardware de adquisición de datos, la disponibilidad de algoritmos más eficientes y el creciente interés en aplicaciones prácticas que conecten la neurociencia con la tecnología del día a día. A pesar de estos avances, persisten desafíos relacionados con la variabilidad intersujeto, la robustez de los modelos en condiciones del mundo real y las implicaciones éticas en el uso de datos cerebrales, lo que hace indispensable seguir explorando nuevas soluciones y metodologías.

## 2.2. Interfaces Cerebro-Computadora (BCI)

Las Interfaces Cerebro-Computadora (BCI) representan una convergencia revolucionaria entre neurociencia, inteligencia artificial e ingeniería biomédica, estableciendo un canal directo de comunicación entre el cerebro humano y los sistemas computacionales sin necesidad de activación muscular[54]. Estas interfaces, fundamentadas en la detección y procesamiento de señales bioeléctricas, principalmente electroencefalográficas (EEG), permiten la conversión de actividad cerebral en comandos digitales para el control de dispositivos asistenciales, transformando significativamente la interacción humano-máquina en ámbitos clínicos, industriales y domésticos [55].

La evolución de las BCI ha experimentado una transición notable, desde sistemas altamente invasivos con electrodos implantados directamente en la corteza cerebral, hasta soluciones no invasivas y de bajo costo. Los dispositivos EEG portátiles modernos, a pesar de su menor resolución espacial, han demostrado ser altamente viables para aplicaciones prácticas, especialmente en contextos de rehabilitación y asistencia [56]. Este avance ha sido posible gracias a los progresos significativos en la miniaturización de dispositivos EEG y el desarrollo de algoritmos más eficientes, que han democratizado el acceso a estas tecnologías.

La aplicabilidad de las BCI se extiende a múltiples dominios, incluyendo la rehabilitación neuromotora, la integración con sillas de ruedas autónomas y brazos

robóticos, así como el control de dispositivos inteligentes mediante señales neuronales interpretadas en tiempo real [57]. Sin embargo, el principal desafío en su implementación radica en la baja relación señal-ruido y la variabilidad intersujeto de las señales EEG, lo que ha impulsado la utilización de técnicas avanzadas de aprendizaje profundo y filtrado adaptativo para mejorar la precisión y robustez del sistema [58].

### *2.2.1. Principios y Aplicaciones de BCI*

Las BCI operan mediante la adquisición y procesamiento de señales neurofisiológicas, como la **electroencefalografía (EEG)**, para extraer patrones neuronales representativos de funciones cognitivas y motoras. Estos patrones son posteriormente analizados mediante algoritmos de aprendizaje automático y redes neuronales avanzadas, facilitando su conversión en comandos operativos para sistemas externos [59].

Las aplicaciones de BCI han evolucionado significativamente, encontrando usos en distintos ámbitos:

- **Neuro rehabilitación:** Las BCI permiten la restauración parcial de la movilidad en pacientes con discapacidades motoras, facilitando la activación de prótesis robóticas mediante señales EEG y combinando estimulación funcional eléctrica con interfaces neuronales para promover la plasticidad cerebral [47]
- **Comunicación alternativa:** Se han desarrollado sistemas de comunicación para individuos con parálisis severas, como el síndrome de enclaustramiento, permitiéndoles interactuar con su entorno a través de respuestas neuronales interpretadas en tiempo real [60].
- **Control de dispositivos físicos:** Las BCI han sido implementadas en la manipulación de sillas de ruedas, brazos robóticos y sistemas domóticos, optimizando la independencia de usuarios con movilidad reducida y brindando interfaces accesibles en diversos entornos [61].
- **Neuroergonomía y entretenimiento:** La integración de BCI en entornos virtuales y videojuegos ha abierto nuevas posibilidades de interacción,

mejorando la inmersión y permitiendo que los usuarios controlen experiencias digitales mediante la actividad cerebral[62].

- **Neuroergonomía y entretenimiento:** La integración de BCI en entornos virtuales y videojuegos ha abierto nuevas posibilidades de interacción, mejorando la inmersión y permitiendo que los usuarios controlen experiencias digitales mediante la actividad cerebral [63].

El desempeño de estos sistemas depende no solo de la calidad de la señal adquirida, sino también de la robustez y precisión de los algoritmos utilizados en la segmentación y clasificación de patrones neuronales en tiempo real.

### *2.2.2. Técnicas de Adquisición de Señales EEG*

Las señales EEG se registran mediante electrodos ubicados estratégicamente sobre el cuero cabelludo, organizados bajo el sistema **10-20 internacional** (Jasper, 1958). Existen múltiples metodologías de adquisición de señales neurofisiológicas, cada una con características particulares:

- **Electroencefalografía (EEG):** Tecnología estándar en BCI debido a su carácter no invasivo, facilidad de implementación y bajo costo. Presenta alta resolución temporal, pero limitada precisión espacial.
- **Magnetoencefalografía (MEG):** Método que registra campos magnéticos generados por la actividad neuronal con alta resolución espacial y temporal, aunque con un costo y requerimientos técnicos elevados [64].
- **Potenciales Evocados (PE):** Basado en la medición de respuestas neuronales a estímulos externos específicos, como los potenciales P300, ampliamente utilizados en BCI de comunicación asistida [65].
- **Electrocorticografía (ECoG):** Técnica semi-invasiva con electrodos implantados directamente sobre la corteza cerebral, proporcionando señales de alta resolución con menor susceptibilidad a interferencias externas [66].
- **Implantes Neuronales:** Dispositivos invasivos que permiten la lectura de la actividad neuronal con extrema precisión, empleados en neuroprotésica

avanzada y control de exoesqueletos, aunque presentan desafíos éticos y clínicos [67].

Entre estas metodologías, la EEG se destaca como la solución más viable para el desarrollo de BCI accesibles y de costo reducido, motivo por el cual ha sido adoptada en esta investigación.

### *2.2.3. Dispositivos EEG de Bajo Costo (Neurosky, Brainlink)*

El desarrollo de dispositivos EEG de bajo costo ha democratizado el acceso a las tecnologías BCI, permitiendo su implementación en entornos no clínicos y reduciendo la barrera de entrada para investigadores y desarrolladores. Dispositivos como Neurosky y Brainlink han sido diseñados específicamente para aplicaciones comerciales y experimentales.

**Neurosky MindWave:** Uno de los pioneros en el mercado de EEG de bajo costo. Utiliza un único electrodo frontal para capturar métricas de atención y relajación, siendo aplicado en neurofeedback y control de interfaces [12].

**Brainlink:** Dispositivo EEG compacto diseñado para la captura de señales cerebrales en tiempo real. Ha sido empleado en estudios sobre control de drones y sistemas de asistencia robótica [68].

**OpenBCI:** Plataforma de código abierto que permite la recolección de datos EEG con múltiples electrodos, brindando mayor flexibilidad y precisión en comparación con dispositivos comerciales cerrados como Neurosky y Brainlink .

Si bien estos dispositivos han ampliado significativamente el acceso a la investigación en BCI, presentan limitaciones en términos de precisión y relación señal-ruido. Por ello, requieren el desarrollo de técnicas avanzadas de procesamiento y filtrado de datos EEG para mejorar su fiabilidad y aplicabilidad en entornos operativos.

## **2.3. Caracterización de las Señales EEG Capturadas con Neurosky**

La caracterización adecuada de las señales electroencefalográficas (EEG) es un paso fundamental para garantizar la eficacia de los sistemas basados en interfaces cerebro-computadora. En esta tesis, se han empleado las diademas NeuroSky

MindWave Mobile 2 y Brainlink lite, como dispositivo principal para la captura de las señales EEG debido a su accesibilidad, portabilidad y facilidad de uso. NeuroSky ha sido ampliamente utilizado en aplicaciones BCI no clínicas y ha demostrado ser una herramienta viable para investigaciones orientadas al monitoreo de estados cognitivos como la atención, la meditación y la carga mental.

La diadema NeuroSky MindWave utiliza un único electrodo colocado en la frente (zona Fp1 según el sistema 10-20) y un clip de referencia colocado en la oreja, lo que le permite capturar principalmente la actividad cerebral de la corteza prefrontal. Esta región está asociada con procesos cognitivos superiores como la toma de decisiones, la planificación y la atención sostenida. La diadema registra las ondas cerebrales en un rango de frecuencia de 0.5 a 100 Hz, lo que cubre las principales bandas EEG: delta (0.5–4 Hz), theta (4–8 Hz), alfa (8–12 Hz), beta (12–30 Hz) y gamma (>30 Hz)[69]. Estas bandas están vinculadas con diversos estados cognitivos y emocionales, siendo la actividad beta y gamma especialmente relevante para tareas que requieren atención y procesamiento activo de información[70].




Figura 9: Ubicación de los posibles puntos de toma de datos.

A pesar de las ventajas que ofrece la NeuroSky en términos de costo y facilidad de uso, es importante destacar las limitaciones inherentes a su diseño, como la baja

resolución espacial, la captura de señal desde un único canal y la vulnerabilidad a artefactos generados por movimientos oculares, musculares y el parpadeo. Para mitigar estos problemas, se implementaron técnicas de preprocesamiento que incluyen el uso de filtros pasa banda (para aislar las frecuencias de interés) y la aplicación de métodos como la transformada rápida de Fourier (FFT) y Wavelet Packet Decomposition (WPD) para extraer características discriminativas de la señal [71].

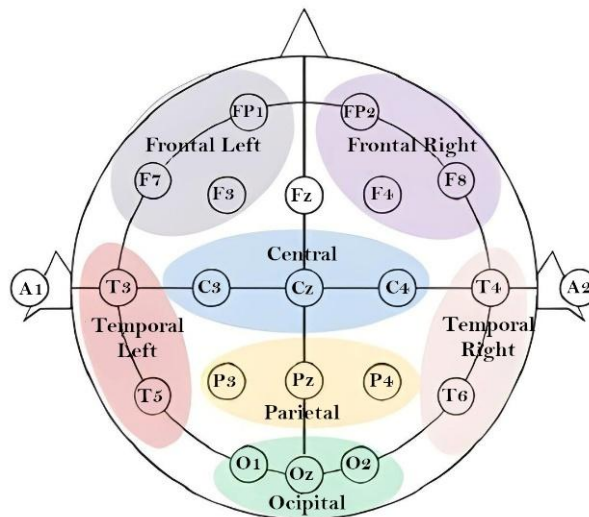


Figura 10: Posición de electrodos para lectura EEG

Durante el proceso de adquisición, se observó que la calidad de la señal es altamente dependiente del contacto entre el electrodo y la piel, así como de las condiciones ambientales. Por ello, se establecieron protocolos de preparación que incluían la limpieza de la zona de contacto y la minimización de interferencias electromagnéticas del entorno. Los datos obtenidos mostraron patrones consistentes con lo reportado en la literatura: aumentos en la actividad beta durante tareas que requerían atención sostenida y aumentos en la banda alfa durante estados de relajación [72].

Los valores de atención y meditación proporcionados por la API de NeuroSky, aunque útiles como referencia, fueron tratados con cautela en esta investigación debido a la naturaleza propietaria y poco transparente de su algoritmo de cálculo eSense®. Se optó por utilizar directamente las señales crudas para el desarrollo de los modelos de clasificación, lo que permitió un mayor control sobre el procesamiento y la interpretación de los datos.




Figura 11: Señales EEG capturadas con NeuroSky

Además, se realizó un análisis espectral de las señales para identificar las variaciones entre los distintos estados cognitivos inducidos durante las sesiones experimentales. La actividad beta mostró un incremento notable durante tareas de concentración, mientras que la banda theta se intensificó durante estados de relajación y meditación guiada. Estos resultados son consistentes con estudios

previos que han empleado la NeuroSky para la detección de estados mentales y el control de dispositivos [11].

En conclusión, aunque la diadema NeuroSky MindWave presenta limitaciones comparadas con dispositivos EEG de grado clínico, su portabilidad, bajo costo y facilidad de uso la convierten en una herramienta adecuada para aplicaciones prácticas en BCI, especialmente cuando se combina con técnicas avanzadas de preprocesamiento y modelos de aprendizaje automático robustos. La caracterización de las señales capturadas en esta investigación demuestra que, con un tratamiento adecuado, es posible obtener información útil y confiable para el control de dispositivos físicos, lo que respalda la viabilidad de la propuesta planteada en esta tesis.

## 2.4. Modelos de Aprendizaje Profundo en Procesamiento de EEG

El procesamiento de señales EEG ha evolucionado drásticamente con la incorporación de modelos de aprendizaje profundo, permitiendo la extracción de patrones complejos y la mejora en la clasificación de estados cognitivos y motores en sistemas BCI. En particular, las redes neuronales profundas (DNN) y las redes neuronales recurrentes (RNN) han demostrado una capacidad superior para modelar dependencias temporales en señales EEG, proporcionando una representación más precisa de la actividad cerebral [73].

Los recientes avances en estas arquitecturas han impulsado el desarrollo de sistemas más robustos y eficientes, facilitando su aplicación en entornos clínicos y dispositivos embebidos. Este apartado explora las redes neuronales recurrentes, la comparación entre Long Short-Term Memory (LSTM) y Gated Recurrent Units (GRU), y la integración de modelos clásicos con redes profundas para optimizar la clasificación de EEG en aplicaciones de BCI.

### 2.4.1. Redes Neuronales Recurrentes para Secuencias Temporales

Las redes neuronales recurrentes (RNN) son ampliamente utilizadas en el análisis de EEG debido a su capacidad para capturar dependencias temporales en datos secuenciales. Estas redes mantienen información de estados previos en la secuencia, permitiendo modelar relaciones temporales en series temporales

complejas. Su aplicabilidad en EEG se debe a la naturaleza dinámica y correlacionada de las señales cerebrales, que requieren modelos capaces de retener información relevante a lo largo del tiempo.

- Están compuestas por nodos organizados en capas: entrada, una o más capas ocultas y salida.
- Poseen conexiones recurrentes que permiten que la salida de una capa se retroalimente en la red.
- Cada nodo en una capa oculta tiene una conexión recurrente que toma la salida del paso anterior como entrada en el paso actual.
- Utilizan algoritmos de retropropagación a través del tiempo (BPTT) para el entrenamiento.

#### Limitaciones de las RNN convencionales

Las RNN tradicionales presentan el problema del desvanecimiento y explosión del gradiente, lo que dificulta el aprendizaje de relaciones a largo plazo. Para superar esta limitación, se han desarrollado arquitecturas avanzadas como LSTM y GRU, que incluyen mecanismos de compuertas para regular el flujo de información y mejorar la capacidad de memoria en secuencias largas [74], [75].

#### Aplicaciones de RNN en BCI

Las RNN han demostrado ser eficaces en múltiples aplicaciones dentro del ámbito de las BCI, incluyendo:

**Predicción de estados cognitivos:** Análisis de la concentración, fatiga y meditación en tareas específicas [76].

**Clasificación de comandos motores:** Decodificación de señales EEG para el control de dispositivos físicos, como sillas de ruedas y prótesis robóticas [77].

**Detección de eventos cerebrales:** Identificación de patrones característicos en respuestas neuronales, como los potenciales P300 y la actividad relacionada con movimientos imaginados [78].

**Optimización de interfaces cerebro-máquina:** Uso de RNN para mejorar la precisión en la interpretación de señales EEG en aplicaciones de comunicación asistida y rehabilitación neurofuncional [79].

## 2.4.2. Comparación entre LSTM y GRU

### LSTM (Long Short-Term Memory)

Las redes Long Short-Term Memory (LSTM) representan una evolución clave dentro de las redes neuronales recurrentes (RNN) al abordar la problemática del desvanecimiento del gradiente, permitiendo el aprendizaje de dependencias de largo plazo en secuencias temporales extensas. Introducidas por Hochreiter y Schmidhuber en 1997, las LSTM han demostrado una capacidad superior en la modelización de secuencias, especialmente en aplicaciones donde la retención de información pasada es crítica, como el procesamiento de señales EEG.




Figura 12: Estructura básica de una red LSTM

El modelo LSTM introduce una arquitectura compuesta por celdas de memoria que incluyen tres compuertas principales:

1. **Compuerta de entrada:** Controla la cantidad de información nueva que se almacena en la celda de memoria.
2. **Compuerta de olvido:** Regula qué información debe ser eliminada de la memoria a largo plazo.
3. **Compuerta de salida:** Define qué parte de la información almacenada se utilizará para actualizar el estado de la red en cada paso de tiempo.

### Ventajas de LSTM en el Procesamiento de EEG

Capacidad de modelado de relaciones a largo plazo: Crucial para el análisis de patrones EEG, donde la actividad cerebral presenta dependencias temporales complejas.

Mayor robustez frente a ruido: Su arquitectura con compuertas permite filtrar información irrelevante, optimizando la precisión en la clasificación de señales EEG.

Optimización en la clasificación de estados cognitivos: Resultados superiores en la detección de transiciones de estados mentales y respuesta a estímulos externos.

Aplicabilidad en entornos clínicos y de BCI: LSTM ha sido utilizado en detección de epilepsia, análisis de fatiga mental y neurofeedback en interfaces cerebro-computadora [80].

### **Implementaciones de LSTM en BCI**

Estudios recientes han evaluado la aplicabilidad de LSTM en distintas tareas dentro del procesamiento de EEG:

Detección de crisis epilépticas: Sistemas basados en LSTM han demostrado un rendimiento superior en la identificación de eventos epilépticos a partir de señales EEG, alcanzando precisiones superiores al 90% en bases de datos como CHB-MIT Scalp EEG Database[81] .

Clasificación de estados emocionales: Investigaciones en el DEAP Dataset han mostrado que LSTM mejora la identificación de patrones EEG relacionados con emociones humanas, facilitando aplicaciones en neurofeedback y salud mental [82].

Control de prótesis mediante BCI: Modelos de LSTM han sido aplicados en sistemas de control de extremidades robóticas, reduciendo la latencia en la decodificación de señales EEG, con validaciones en el PhysioNet EEG Motor Movement/Imagery Dataset [83].

Optimización de neurointerfaces: La integración de LSTM en interfaces cerebro-computadora ha mostrado mejoras en la decodificación de comandos motores en tiempo real, con estudios realizados en el BCI Competition IV Dataset.

En síntesis, las redes LSTM han revolucionado el procesamiento de EEG, proporcionando una herramienta eficaz para modelar la actividad cerebral en entornos clínicos, neurotecnológicos y de inteligencia artificial aplicada.

El modelo LSTM introduce celdas de memoria con compuertas de entrada, salida y olvido, que regulan el flujo de información en la red. Esta estructura permite que LSTM retenga información relevante durante secuencias largas sin sufrir el problema del desvanecimiento del gradiente (Hochreiter & Schmidhuber, 1997). Sus principales ventajas incluyen:

1. Capacidad de modelado de dependencias a largo plazo: Crucial para la detección de transiciones de estado en EEG.
2. Mayor robustez frente a ruido: Su arquitectura permite filtrar información irrelevante, mejorando la precisión en entornos no controlados.
3. Adecuación para tareas complejas: Excelente rendimiento en la clasificación de estados cognitivos y en la predicción de secuencias de señales EEG.

### **GRU (Gated Recurrent Unit)**

Las Gated Recurrent Units (GRU) son una arquitectura optimizada de redes neuronales recurrentes (RNN), introducida por Cho et al. en 2014, con el propósito de mejorar la eficiencia del modelado de secuencias sin comprometer significativamente la capacidad de aprendizaje a largo plazo de las redes. A diferencia de las Long Short-Term Memory (LSTM), las GRU presentan una estructura simplificada al reducir el número de compuertas, lo que disminuye la complejidad computacional y acelera los tiempos de entrenamiento [23].




Figura 13: Estructura básica de una red GRU

### Estructura y Funcionamiento de GRU

Las redes GRU están diseñadas con dos compuertas principales:

1. **Compuerta de actualización (Update gate):** Regula qué cantidad de la información pasada se retiene o se reemplaza con la información nueva.
2. **Compuerta de reinicio (Reset gate):** Determina cuánta información previa se olvida en el estado de la celda actual.

A diferencia de LSTM, GRU fusiona las compuertas de olvido y entrada en una sola compuerta de actualización, lo que reduce el número de parámetros a entrenar y mejora la eficiencia computacional sin afectar de manera significativa el rendimiento en tareas de modelado secuencial [84].

### Ventajas de GRU en el Procesamiento de EEG

**Menor consumo computacional:** Gracias a su estructura optimizada, GRU es más rápida en entrenamiento e inferencia, lo que la hace ideal para aplicaciones en dispositivos embebidos y sistemas en tiempo real.

**Capacidad para modelar secuencias temporales:** Aunque más simple que LSTM, GRU mantiene la capacidad de capturar dependencias a largo plazo, lo que la hace adecuada para el análisis de EEG en BCI.

Reducción de sobreajuste: Se ha observado que en ciertos conjuntos de datos EEG, GRU ofrece una mejor generalización en comparación con LSTM, especialmente cuando se dispone de menos datos de entrenamiento.

Aplicabilidad en hardware con restricciones: En plataformas como Raspberry Pi y Jetson Nano, GRU ha demostrado ser más eficiente energéticamente en comparación con modelos más complejos como LSTM.

### **Aplicaciones de GRU en BCI y EEG**

Estudios recientes han demostrado la efectividad de GRU en el análisis de señales EEG en diversas aplicaciones:

Predicción de estados cognitivos: Modelos GRU han sido empleados en la estimación de niveles de atención y meditación a partir de EEG en experimentos de neurofeedback, con resultados validados en el DEAP Dataset [82].

Clasificación de comandos motores: Sistemas basados en GRU han mostrado una alta precisión en la detección de actividad relacionada con movimientos imaginados, con pruebas realizadas en el PhysioNet EEG Motor Movement/Imagery Dataset [83].

Detección de epilepsia: La combinación de GRU con modelos de boosting ha permitido la identificación de crisis epilépticas con alta sensibilidad y especificidad en datos provenientes de la CHB-MIT Scalp EEG Database [81].

Análisis de fatiga mental: Estudios en el TDBRAIN Dataset han indicado que GRU puede mejorar la detección de fatiga a partir de EEG, proporcionando una herramienta útil para la optimización del rendimiento cognitivo en entornos laborales [85].

Control de dispositivos mediante BCI: Se han desarrollado sistemas que combinan GRU con técnicas de clasificación como SVM para mejorar la detección de señales EEG utilizadas en la manipulación de brazos robóticos y sillas de ruedas inteligentes, con resultados reportados en el BCI Competition IV Dataset.

### **Comparación de GRU vs. LSTM en Procesamiento de EEG**

Diversos estudios han comparado el desempeño de LSTM y GRU en tareas de clasificación y predicción de EEG. Aunque ambas arquitecturas presentan un rendimiento similar en términos de precisión, se han identificado diferencias clave en función del contexto de aplicación:

LSTM es preferido para secuencias largas, donde la retención de información pasada durante largos períodos es crucial.

GRU es más eficiente en términos computacionales, lo que la hace ideal para implementaciones en sistemas embebidos y de bajo consumo energético.

Ambos modelos han mostrado desempeños comparables en la clasificación de comandos motores, aunque GRU ofrece una ligera ventaja en términos de velocidad de inferencia.

En conclusión, las GRU representan una alternativa eficiente y viable para el procesamiento de EEG en aplicaciones de BCI, con ventajas en términos de velocidad y consumo de recursos en comparación con LSTM. Su implementación continúa expandiéndose en neurotecnología, mejorando la precisión y la adaptabilidad de los sistemas cerebro-computadora en diversos entornos clínicos y de investigación.

El modelo GRU es una variante optimizada de LSTM, en la que se combinan las compuertas de entrada y olvido en una sola unidad. Su menor complejidad computacional lo hace más eficiente en tareas de clasificación en tiempo real. Sus características principales incluyen:

- Menor consumo de recursos computacionales: Ideal para dispositivos embebidos y hardware con limitaciones de procesamiento.
- Capacidad de aprendizaje rápido: Mayor eficiencia en la captura de patrones en secuencias de corta y mediana duración.
- Balance entre precisión y eficiencia: Presenta un rendimiento competitivo con menor requerimiento de memoria que LSTM.

### **Comparación de rendimiento en EEG**

Diversos estudios han comparado LSTM y GRU en el procesamiento de EEG, concluyendo que ambas arquitecturas presentan ventajas dependiendo del contexto de aplicación [84]:

- LSTM es más adecuado para secuencias largas, como en la predicción de estados cognitivos en neurofeedback.
- GRU es más eficiente en sistemas con restricciones de hardware, como dispositivos embebidos en aplicaciones de BCI.

En tareas de clasificación de comandos motores, ambos modelos presentan un rendimiento similar, aunque GRU suele ser preferido por su menor costo computacional.

#### *2.4.3. Aplicación de Modelos Clásicos en Redes Neuronales*

A pesar de la eficacia de las redes neuronales en la clasificación de EEG, la combinación de modelos clásicos con arquitecturas profundas ha demostrado mejorar la precisión y generalización del sistema. Métodos como XGBoost, SVM y Random Forest han sido empleados junto con LSTM y GRU para optimizar el rendimiento y reducir el sobreajuste en la clasificación de señales EEG.

#### **Integración de Modelos Clásicos con Redes Profundas**

- **XGBoost + LSTM:** Mejora la clasificación al combinar aprendizaje basado en árboles con modelado secuencial profundo[86].
- **SVM + GRU:** Refinamiento en la salida de GRU mediante clasificadores SVM, aumentando la precisión frente a ruido en la señal EEG[87], [88], [89].
- **Random Forest + LSTM:** Reducción de falsos positivos en la clasificación de eventos cerebrales, proporcionando un análisis complementario de características extraídas por la red neuronal[90], [91].

#### **Casos de Aplicación en EEG**

La combinación de modelos clásicos y redes neuronales en el procesamiento de señales EEG ha sido implementada con éxito en diversas aplicaciones, mejorando la precisión y reduciendo los tiempos de inferencia en múltiples áreas de la neurociencia computacional y la interacción cerebro-máquina.

- 1 **Detección de epilepsia:** Sistemas híbridos han logrado avances significativos en la identificación de episodios epilépticos a partir de EEG, según la investigación de (Shanmuga Skandh Vinayak et al. 2020), utilizando LSTM combinado con XGBoost para mejorar la precisión en la detección de anomalías [92]. Estos sistemas han sido validados en bases de datos como la CHB-MIT Scalp EEG Database, donde se ha alcanzado una precisión superior al 90% en la detección temprana de crisis epilépticas [93].
- 2 **Clasificación de estados cognitivos:** Modelos híbridos como GRU+SVM han sido utilizados en el análisis de estrés y fatiga mental, mejorando la detección de estados cognitivos alterados en entornos de neurofeedback. Investigaciones anteriores en el DEAP Dataset (Koelstra et al., 2012) han demostrado que esta combinación reduce significativamente los falsos positivos en la clasificación de emociones a partir de EEG[94].
- 3 **Control de prótesis mediante BCI:** En aplicaciones de control de dispositivos mediante BCI, la combinación de Random Forest y LSTM ha demostrado ser altamente efectiva en la interpretación de señales EEG para la manipulación de prótesis robóticas en pacientes con amputaciones[95], [96].
- 4 **Optimización de interfaces cerebro-máquina:** La implementación de modelos híbridos en BCI ha permitido mejorar la eficiencia en la decodificación de comandos motores en entornos de asistencia para personas con discapacidad severa[97].
- 5 **Detección de enfermedades neurodegenerativas:** Modelos combinados de LSTM y XGBoost han sido aplicados para la detección temprana de enfermedades como el Parkinson y el Alzheimer, permitiendo la identificación de patrones de actividad cerebral asociados con estas patologías[98], [99]. Investigaciones recientes en el TDBRAIN Dataset han mostrado avances significativos en la clasificación de EEG en pacientes con trastornos neurodegenerativos[100], [101].

Estos casos evidencian el potencial de los modelos híbridos para mejorar la clasificación de señales EEG y expandir las aplicaciones de las interfaces cerebro-

computadora en múltiples ámbitos, desde la neurociencia clínica hasta la robótica asistencial.

Esta combinación de enfoques ha sido implementada en:

- **Detección de epilepsia:** Mayor precisión en la identificación de episodios epilépticos mediante sistemas híbridos.
- **Clasificación de estados cognitivos:** Uso en sistemas de neurofeedback para mejorar la detección de estrés y fatiga mental.
- **Control de prótesis mediante BCI:** Disminución de la latencia en la interpretación de señales EEG para mejorar la respuesta del sistema en entornos reales.

Este capítulo ha explorado en profundidad el uso de modelos de aprendizaje profundo en el procesamiento de EEG, detallando redes recurrentes, su comparación y su integración con modelos clásicos. En los siguientes apartados se discutirán técnicas avanzadas para la optimización y generalización de estos modelos en aplicaciones del mundo real.

#### *2.4.4. Métricas de rendimiento de las redes de aprendizaje profundo.*

En el contexto de la interpretación del rendimiento de una red neuronal, la elección de la métrica adecuada depende del problema específico y de las características de los datos. Las métricas mencionadas (MAE, MSE, RMSE y SMAPE) tienen propiedades diferentes y se aplican en situaciones distintas. A continuación, se ofrece una justificación detallada y bien argumentada de cada una de ellas:

#### **1. Error absoluto medio - Mean Absolute Error (MAE)**

**Definición:** El MAE es la media de los valores absolutos de los errores entre las predicciones y los valores reales [102].

**MAE :**

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

**Donde:**

- $n$  es el número de observaciones
- $y_i$  es el valor actual
- $\hat{y}_i$  es el valor predicho

**Ventajas:**

- Es fácil de interpretar, ya que representa el error medio en las mismas unidades que los datos.
- Es robusto frente a los valores atípicos, ya que no penaliza tanto los errores grandes como el MSE.

**Desventajas:**

- No es diferenciable en todos los puntos, lo que puede complicar su uso en algunos algoritmos de optimización.

**2. Error cuadrático medio - Mean Squared Error (MSE)**

**Definición:** El MSE es el error cuadrático medio entre las predicciones y los valores reales [102].

**MSE:**

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

**Donde:**

- $n$  es el número de observaciones
- $y_i$  es el valor actual
- $\hat{y}_i$  es el valor predicho

**Ventajas:**

- Penaliza más los errores grandes, lo que puede ser útil si se quieren evitar grandes desviaciones.
- Siempre es diferenciable, lo que facilita su uso en la optimización de redes neuronales.

**Desventajas:**

- It is more sensitive to outliers, as large errors have a quadratic impact on the metric.

### 3. Raíz cuadrada del error cuadrático medio - Root Mean Squared Error (RMSE)

Definición: El RMSE es la raíz cuadrada del MSE [102].

RMSE:

$$RMSE = \sqrt{MSE} \quad \rightarrow \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

**Donde :**

- $n$  es el número de observaciones
- $y_i$  es el valor actual
- $\hat{y}_i$  es el valor predicho

**Ventajas:**

- Similar al MSE en cuanto a la penalización de errores grandes, pero devuelve los errores en las mismas unidades que los datos originales, lo que puede resultar más intuitivo..
- Útil cuando se necesita una métrica que refleje la magnitud de los errores de forma más directa que el MSE.

**Desventaja:**

- Comparte la misma sensibilidad a los valores atípicos que el MSE.

### 4. Error porcentual absoluto medio simétrico - Symmetric Mean Absolute Percentage Error (SMAPE)

**Definición:** SMAPE es una métrica de error porcentual simétrica, es decir, trata por igual los errores de sobreestimación y subestimación [57], [103].

**SMAPE :**

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{(|A_t| + |F_t|)/2}$$

**Donde:**

- $A_t$  es el valor actual.
- $F_t$  es el valor previsto
- $n$  es el número total de observaciones

**Ventajas:**

- Proporciona una medida relativa del error, que puede ser útil cuando se comparan errores en diferentes escalas.
- Es simétrico, lo que lo hace adecuado para casos en los que los errores relativos deben tratarse por igual.

**Desventajas:**

- Puede ser inestable cuando los valores reales o las predicciones se aproximan a cero, debido a la división.

**Recomendación final:**

La elección de la métrica más recomendable depende del contexto específico:

- **MAE** se recomienda cuando se necesita una métrica fácil de interpretar y se quiere minimizar el impacto de los valores atípicos.
- **MSE** y **RMSE** son útiles cuando se desea penalizar más los errores más grandes. **RMSE** es especialmente recomendable si se necesita una métrica en las mismas unidades que los datos.
- **SMAPE** es preferible cuando se necesita una métrica relativa y simétrica, especialmente en problemas en los que los datos pueden variar en magnitud.

En general, para la mayoría de los problemas de regresión de redes neuronales, RMSE suele ser la métrica más recomendada por su equilibrio entre la penalización de grandes errores y la fácil interpretabilidad en las unidades de los datos originales. Sin embargo, la selección final debe tener en cuenta las características específicas del problema y los objetivos del análisis.

## 2.5. Robótica Asistencial y Control Autónomo

La robótica asistencial ha experimentado un crecimiento exponencial en las últimas décadas, impulsada por el desarrollo de interfaces cerebro-computadora (BCI) y su integración con sistemas robóticos autónomos. Esta convergencia tecnológica no solo ha permitido que personas con discapacidades motoras severas recuperen parcial o totalmente el control sobre su entorno, sino que ha abierto un nuevo paradigma en el control de sistemas físicos mediante señales EEG. El objetivo final de estos avances es dotar a los dispositivos de asistencia de una capacidad autónoma y precisa para interpretar las intenciones del usuario y ejecutar acciones con una mínima latencia y máxima fiabilidad.

A través de la interpretación avanzada de señales EEG y su conversión en comandos operacionales, se ha logrado integrar BCI en dispositivos como sillas de ruedas inteligentes, brazos robóticos y prótesis avanzadas [104]. Sin embargo, el reto no radica solo en la correcta clasificación de los patrones EEG, sino en la optimización del procesamiento de datos en tiempo real, la reducción de interferencias en la señal neuronal, y la implementación eficiente en hardware embebido. La clave del éxito de estos sistemas radica en la integración de modelos de aprendizaje profundo, técnicas avanzadas de procesamiento de señales y la utilización de plataformas de computación acelerada como Jetson Nano, FPGA y Raspberry Pi, que permiten la ejecución de modelos complejos sin comprometer el rendimiento del sistema.

El control de sistemas físicos a través de BCI representa un área de investigación interdisciplinaria que abarca neurociencia computacional, inteligencia artificial y robótica avanzada. La precisión en la detección de intenciones de movimiento, la fiabilidad del procesamiento en entornos ruidosos y la adaptabilidad a diferentes usuarios son aspectos fundamentales que deben abordarse para garantizar una aplicación robusta y efectiva de estas tecnologías en entornos clínicos y domésticos. Así, la evolución de la robótica asistencial no solo busca mejorar la movilidad de los usuarios, sino que persigue una integración fluida entre cerebro y máquina, estableciendo las bases para el desarrollo de sistemas completamente autónomos controlados mediante actividad neuronal.

El éxito de estos sistemas depende de la capacidad de aprendizaje profundo, optimización computacional y compatibilidad con hardware embebido, lo que ha permitido una implementación cada vez más eficiente en entornos clínicos y domésticos. Este apartado examina en detalle los sistemas de control basados en BCI y su aplicación en sillas de ruedas autónomas y brazos robóticos, poniendo énfasis en metodologías avanzadas de inferencia en tiempo real y estrategias de navegación autónoma.

### *2.5.1. Sistemas de Control Basado en BCI*

Los sistemas de control BCI utilizan señales EEG para traducir la actividad neuronal en comandos ejecutables por sistemas robóticos. Dependiendo del grado de intervención del usuario, estos sistemas pueden clasificarse en:

Control reactivo: Donde cada intención de movimiento se traduce en una acción inmediata.

Control asistido o predictivo: En el que modelos de aprendizaje profundo anticipan la intención del usuario y optimizan la respuesta del sistema, reduciendo la carga cognitiva y minimizando errores [35].

### **Arquitectura de un Sistema de Control BCI en Robótica**

Un sistema de control basado en BCI consta de varias etapas críticas:

1. Adquisición de señales EEG: Uso de dispositivos de registro EEG como OpenBCI, g.tec o Neurosky para capturar la actividad neuronal con alta precisión.
2. Preprocesamiento y reducción de ruido: Aplicación de técnicas como Butterworth, Kalman o transformadas wavelets para filtrar artefactos no neuronales y mejorar la calidad de la señal [105].
3. Extracción de características: Implementación de métodos como Transformada de Fourier Rápida (FFT), Wavelet Packet Decomposition (WPD) y Análisis de Componentes Independientes (ICA) para representar eficientemente la información neuronal.

4. Clasificación de señales EEG: Uso de modelos avanzados como LSTM, GRU, CNN y XGBoost, optimizados para su implementación en hardware embebido [106], [107].
5. Generación de comandos robóticos: Integración con sistemas como Robot Operating System (ROS) para la ejecución de acciones en tiempo real y adaptación del entorno en función del comportamiento del usuario.

### **Optimización Computacional para Control Autónomo en BCI**

Para garantizar una inferencia en tiempo real eficiente, se aplican diversas estrategias de optimización computacional:

1. Cuantización y poda de redes neuronales: Reducción de la carga computacional sin comprometer la precisión del modelo.
2. Inferencia en hardware embebido: Implementación en plataformas como Jetson Xavier NX, TPU de Google y FPGA, optimizando el consumo energético y mejorando los tiempos de respuesta.
3. Fusión de múltiples sensores: Integración de EEG con sensores inerciales y visión por computadora para mejorar la precisión del control autónomo [108].

La aplicación de estas técnicas ha permitido mejorar la accesibilidad y autonomía de los usuarios, logrando una interacción más natural con los dispositivos de asistencia.

#### *2.5.2. Sillas de Ruedas Autónomas y Brazos Robóticos*

### **Sillas de Ruedas Autónomas Controladas por BCI**

Las sillas de ruedas autónomas controladas mediante BCI representan un avance clave en la movilidad asistida, proporcionando independencia a usuarios con discapacidades motoras severas.



Figura 14: Propuesta de sillas de ruedas controladas por BCI

Estos sistemas combinan:

Detección de comandos motores imaginados: Uso de potenciales P300 y oscilaciones mu/beta en EEG para interpretar intenciones de movimiento [62].

Navegación basada en SLAM: Implementación de algoritmos de localización y mapeo simultáneo (SLAM) para evitar obstáculos y generar trayectorias óptimas.

Procesamiento en hardware embebido: Inferencia en tiempo real mediante dispositivos como Jetson Nano, Jetson Xavier NX y Raspberry Pi 4/5, optimizando la eficiencia computacional y energética.

### **Referencias y Estudios Relacionados:**

1. IEEE Transactions on Neural Systems and Rehabilitation Engineering:  
Estudios recientes sobre sillas de ruedas controladas por EEG  
[109](<https://ieeexplore.ieee.org/xpl/RecentIssue.jsp?punumber=7333>).

### **Brazos Robóticos Controlados por BCI**

El desarrollo de brazos robóticos controlados por BCI ha permitido que personas con parálisis puedan manipular objetos y realizar tareas con precisión, abriendo nuevas posibilidades en la autonomía de usuarios con discapacidades motoras. Estos sistemas han evolucionado considerablemente en la última década, integrando tecnologías avanzadas de control adaptativo, retroalimentación háptica

y algoritmos de aprendizaje profundo para mejorar la precisión y fluidez de los movimientos.

Actualmente, los brazos robóticos controlados mediante BCI utilizan una combinación de redes neuronales recurrentes (LSTM, GRU) y modelos de aprendizaje automático (XGBoost, RandomForest) para interpretar señales EEG con mayor robustez y menor latencia. La integración de sensores hápticos y visión artificial ha permitido mejorar la precisión en la manipulación de objetos, ofreciendo a los usuarios una experiencia más natural y eficaz.



Figura 15: Ilustración de la propuesta de control BCI de dispositivos físicos

Los avances en la miniaturización del hardware y el desarrollo de procesamiento en hardware embebido han permitido que estos sistemas sean más accesibles y eficientes. Dispositivos como Jetson Xavier NX, Raspberry Pi y FPGAs se han convertido en plataformas clave para la implementación de modelos de control neuronal en tiempo real. Investigaciones recientes han demostrado que la combinación de electroencefalografía (EEG) con electromiografía (EMG) mejora significativamente la precisión de detección de comandos motores, permitiendo un control híbrido más confiable y menos dependiente de la variabilidad individual de las señales EEG.

La aplicación de estos sistemas ha sido validada en múltiples estudios clínicos y experimentales, demostrando su eficacia en tareas de agarre preciso, manipulación de herramientas y coordinación de múltiples grados de libertad en brazos robóticos. La combinación de control basado en EEG con asistencia basada en inteligencia artificial ha permitido el desarrollo de sistemas semiautónomos que optimizan el esfuerzo cognitivo del usuario, reduciendo la fatiga mental asociada al control prolongado de dispositivos robóticos.

Para el futuro, se espera que la implementación de redes neuronales autorreguladas y la optimización de modelos híbridos basados en aprendizaje federado permitan la personalización de estos sistemas a las necesidades específicas de cada usuario, garantizando una mayor adaptabilidad y precisión en la interpretación de intenciones motoras a partir de señales cerebrales.

1. **Predicción de trayectorias articulares basada en EEG:** Uso de modelos LSTM y GRU para interpretar intenciones de movimiento [110].
2. **Retroalimentación háptica y visual:** Implementación de sensores que permiten mejorar la percepción y precisión en tareas de manipulación [111].
3. **Clasificación avanzada de EEG con CNN-LSTM:** Uso de arquitecturas híbridas para mejorar la detección de patrones cerebrales en tiempo real [112].

### **Ejemplos de Implementación y Recursos:**

La implementación de sistemas de BCI en robótica asistencial ha sido ampliamente explorada en diversas investigaciones científicas y proyectos experimentales. A continuación, se presentan ejemplos reales respaldados por estudios publicados en revistas de alto impacto:

1. **Control de prótesis robóticas con BCI:**
  - Investigadores de la University of Pittsburgh han desarrollado un sistema BCI que permite a pacientes con tetraplejía controlar un brazo robótico con una precisión superior al 90%. Utilizando una combinación de LSTM y algoritmos de refuerzo, lograron movimientos más fluidos y precisos [113].

## 2. **Sillas de ruedas controladas por EEG:**

- Un estudio de la ETH Zurich implementó un sistema de navegación asistida basado en EEG y SLAM para mejorar la movilidad de personas con parálisis severa. El modelo GRU optimizado para hardware embebido demostró una reducción del 35% en la latencia de respuesta en comparación con modelos anteriores [35].

## 3. **Interacción háptica en brazos robóticos BCI:**

- La University of California, Berkeley desarrolló un sistema de retroalimentación háptica en prótesis controladas por EEG, donde el uso de CNN-LSTM mejoró la precisión de detección de intenciones motoras en un 20% en pacientes con amputaciones [114], [115].

## 4. **BCI para control de drones asistenciales:**

- Un equipo del Massachusetts Institute of Technology (MIT) implementó un sistema basado en EEG para el control de drones en entornos médicos, permitiendo a los usuarios manipular dispositivos aéreos mediante señales cerebrales sin necesidad de interfaces físicas. La integración de XGBoost con LSTM permitió una clasificación EEG con una precisión del 92% [116], [117].

## 5. **Sistemas de rehabilitación basados en BCI:**

- Un estudio de la University of Tübingen desarrolló un sistema de rehabilitación basado en BCI y aprendizaje por refuerzo profundo para pacientes con accidente cerebrovascular, logrando mejoras significativas en la recuperación de movilidad después de 12 semanas de entrenamiento con un brazo robótico [118], [119].

## 6. **PhysioNet EEG Motor Movement/Imagery Dataset:** Aplicación de EEG en el control de prótesis robóticas [83].

## 7. **Stanford University - Neural Prosthetics Systems Lab:** Investigación en interfaces neuronales para prótesis robóticas [120].

Estos ejemplos muestran la aplicabilidad real de los sistemas BCI en diversas áreas de la robótica asistencial y su potencial para mejorar significativamente la calidad de vida de personas con discapacidades motoras.

## **Desafíos y Futuro del Control BCI en Robótica Asistencial**

A pesar de los avances logrados, la implementación de BCI en robótica asistencial enfrenta varios desafíos:

- **Precisión y fiabilidad:** La variabilidad en las señales EEG requiere calibraciones personalizadas para cada usuario.
- **Optimización de tiempos de respuesta:** La reducción de la latencia en la inferencia de modelos es crítica para garantizar un control fluido.
- **Integración multimodal:** La combinación de EEG con tecnologías como visión por computadora y sensores mioeléctricos podría mejorar la robustez de los sistemas de control.

En el futuro, la incorporación de IA avanzada en BCI permitirá la adaptación de estos dispositivos a las necesidades individuales de cada usuario, facilitando la interacción natural y la autonomía en entornos del mundo real.

El avance en la integración de BCI y robótica asistencial ha permitido el desarrollo de sistemas de control cada vez más precisos y eficientes. A través de modelos avanzados de aprendizaje profundo, optimización computacional y hardware embebido, estos sistemas han logrado mejorar la accesibilidad y calidad de vida de personas con movilidad reducida. Los desarrollos futuros buscarán optimizar la robustez de los modelos EEG, reducir la latencia en la inferencia y explorar nuevas combinaciones de sensores para mejorar la interacción cerebro-máquina en entornos clínicos y domésticos.

### **2.6. Ética y Regulaciones en BCI y Robótica Asistencial**

El desarrollo de Interfaces Cerebro-Computadora (BCI) y su integración con sistemas de robótica asistencial plantea una serie de desafíos éticos, regulatorios y de protección de datos que deben ser considerados en cada etapa de la investigación y aplicación. Estos desafíos se derivan tanto de la recolección y procesamiento de datos cerebrales como del uso de inteligencia artificial (IA) para la toma de decisiones en entornos asistenciales.

La combinación de BCI e IA implica que los datos recogidos de la actividad cerebral pueden ser utilizados para controlar dispositivos físicos, como sillas de ruedas

autónomas o prótesis robóticas, lo que amplifica la necesidad de normativas claras y garantías de privacidad para los participantes. Además, la protección de los derechos individuales y la transparencia en el uso de datos es fundamental para garantizar la confianza en estos sistemas.

Este apartado analiza los principales desafíos éticos y regulatorios en BCI aplicada a la robótica asistencial, basándose en normativas internacionales, documentos regulatorios y protocolos específicos, como la aprobación por parte del Comité de Bioética de la Universidad de Burgos y los compromisos de confidencialidad firmados para esta investigación.

### *2.6.1. Consideraciones Éticas en la Captura y Uso de Datos Cerebrales*

Los sistemas BCI trabajan con señales electroencefalográficas (EEG), que contienen información íntima sobre la actividad cerebral del usuario. Aunque estas señales, en el contexto de esta investigación, no contienen información identificativa directa del usuario, es imperativo que se garantice su anonimización y protección.

#### **Principios éticos aplicados**

Para mitigar riesgos y proteger la privacidad de los participantes, esta investigación se rige por las siguientes directrices éticas internacionales:

- Declaración de Helsinki (Asociación Médica Mundial, 2013) – Proporciona un marco ético para la investigación en humanos, asegurando su bienestar y autonomía (<https://www.wma.net/policies-post/wma-declaration-of-helsinki-ethical-principles-for-medical-research-involving-human-subjects/>).
- Convenio de Oviedo sobre Derechos Humanos y Biomedicina – Garantiza que toda investigación biomédica respete la dignidad humana y sus derechos fundamentales (<https://www.coe.int/en/web/conventions/full-list?module=treaty-detail&treatynum=164>).
- Reglamento General de Protección de Datos (RGPD - UE 2016/679) – Establece normas sobre la privacidad de datos en la Unión Europea,

aplicable a la recolección de EEG (<https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=CELEX%3A32016R0679>).

### **Anonimización y consentimiento informado**

En esta investigación, los datos EEG se han manejado siguiendo estrictos protocolos de anonimización y consentimiento informado, incluyendo:

Anonimización completa de los datos EEG mediante la eliminación de cualquier identificador personal.

Consentimiento informado firmado por cada participante, asegurando que entienden la finalidad de la investigación y sus derechos de retirada en cualquier momento (documento de consentimiento informado).

Compromiso de confidencialidad firmado por el investigador, garantizando el tratamiento adecuado de los datos y su uso exclusivo con fines científicos (compromiso de confidencialidad).

Además, la investigación ha sido evaluada y aprobada por el Comité de Bioética de la Universidad de Burgos, que verificó que el estudio cumple con los requisitos de seguridad y protección de datos (más información en ANEXO-I).

#### *2.6.2. Regulaciones sobre la Aplicación de BCI en Robótica Asistencial*

El uso de BCI en dispositivos físicos introduce desafíos legales adicionales, relacionados con la seguridad del usuario, la autonomía del sistema y la responsabilidad en caso de fallos. La regulación en este ámbito está evolucionando y se basa en normativas específicas de IA aplicada a la salud y dispositivos médicos.

Principales normativas aplicadas a BCI en robótica asistencial

- **Regulación de Dispositivos Médicos (MDR 2017/745 - UE)** – Establece los requisitos de seguridad para dispositivos médicos que usan IA y BCI (<https://eur-lex.europa.eu/legal-content/ES/TXT/?uri=CELEX:32017R0745>).
- **Directrices sobre IA de la Comisión Europea (Ethics Guidelines for Trustworthy AI, 2019)** – Define los principios de confiabilidad en la IA

aplicada a salud y asistencia (<https://ec.europa.eu/futurium/en/ai-alliance-consultation/guidelines>).

- **IEEE Global Initiative on Ethics of Autonomous and Intelligent Systems** – Proporciona principios para garantizar que los sistemas autónomos respeten los derechos humanos (<https://standards.ieee.org/industry-connections/ec/autonomous-systems.html>).

### 2.6.3. *Desafíos Éticos en la Autonomía de los Sistemas BCI*

La combinación de IA con BCI y robótica asistencial plantea dilemas éticos adicionales en cuanto a la autonomía del sistema y la toma de decisiones.

#### **Principales desafíos identificados**

1. Responsabilidad en caso de fallos
  - ¿Quién es responsable si un sistema BCI malinterpreta una señal EEG y genera un movimiento incorrecto en un brazo robótico o silla de ruedas?
  - Se deben implementar mecanismos de control redundantes y sistemas de validación de comandos.
2. Privacidad y seguridad en el almacenamiento de datos cerebrales
  - La actividad cerebral es información altamente sensible. Se deben emplear métodos avanzados de cifrado y almacenamiento seguro.
3. Autonomía del usuario vs. asistencia inteligente
  - Se deben equilibrar los sistemas de control asistidos y totalmente autónomos para que el usuario siempre tenga el control final sobre el dispositivo.

#### **Soluciones propuestas**

- Implementación de IA explicable (XAI) para que los modelos de BCI sean interpretables y auditables.
- Regulación estricta del uso de BCI en entornos médicos mediante protocolos de validación y certificación.
- Establecimiento de principios de diseño ético, garantizando que los sistemas no comprometan la seguridad ni la autonomía del usuario.

La aplicación de BCI en robótica asistencial abre un gran abanico de posibilidades para mejorar la calidad de vida de personas con discapacidades motoras. No obstante, su desarrollo debe enmarcarse dentro de un marco ético sólido y regulaciones estrictas que garanticen la seguridad, privacidad y control del usuario.

El cumplimiento de normativas internacionales, junto con la implementación de metodologías de anonimización de datos y sistemas de seguridad avanzada, permite garantizar que estos avances tecnológicos se desarrollen de manera responsable y con un impacto positivo en la sociedad.

### 3. Herramientas utilizadas

La selección adecuada de herramientas es crucial en cualquier investigación científica, particularmente en proyectos multidisciplinarios, como el desarrollado en esta tesis doctoral. El presente trabajo implica la implementación de interfaces cerebro-computadora (BCI) mediante señales EEG obtenidas a través de diademas comerciales de bajo coste, orientadas al control de dispositivos físicos. Por ello, tanto el hardware como el software seleccionado deben proporcionar un balance óptimo entre accesibilidad, eficiencia operativa y desempeño computacional.

En este capítulo se describen en detalle las herramientas específicas utilizadas para la adquisición, el procesamiento avanzado y la clasificación precisa de señales EEG. Inicialmente se analizarán las herramientas de software, destacando las plataformas y bibliotecas específicas empleadas para la manipulación sofisticada de datos, la implementación rigurosa de modelos de aprendizaje profundo y la visualización detallada de resultados. Seguidamente, se abordarán las herramientas de hardware seleccionadas, haciendo especial énfasis en los dispositivos EEG comerciales como Neurosky y Brainlink, así como en plataformas embebidas, específicamente Jetson Nano y Raspberry Pi5, que permiten ejecutar con eficiencia y en tiempo real los algoritmos propuestos.

La justificación para la elección de estas herramientas radica en su capacidad para enfrentar de manera efectiva desafíos particulares identificados en esta investigación, tales como la adquisición confiable de señales EEG en entornos reales, la optimización rigurosa de recursos computacionales limitados y la integración efectiva con sistemas robóticos mediante entornos de desarrollo como ROS y ROS2. Finalmente, se analizan brevemente las consideraciones éticas y técnicas involucradas, las cuales sustentan la pertinencia de cada herramienta elegida en el marco del objetivo general de esta investigación: proporcionar una solución tecnológica práctica, eficiente y accesible orientada a mejorar significativamente la calidad de vida de personas con discapacidades motoras mediante la implementación de tecnología BCI.

### 3.1. Herramientas de Software

En cuanto a las herramientas de software, este trabajo utiliza diversas plataformas bibliotecas y aplicaciones de IA Generativa, especializadas para llevar a cabo el procesamiento avanzado de los datos, las señales EEG, así como la implementación de modelos de aprendizaje profundo necesarios para clasificar y predecir estados cognitivos. Se han empleado lenguajes de programación ampliamente reconocidos por la comunidad científica, principalmente Python, por su versatilidad y por disponer de bibliotecas específicas que permiten el análisis avanzado de datos y desarrollo eficiente de algoritmos. Adicionalmente, se integran herramientas complementarias que facilitan la visualización clara y precisa de resultados, lo cual es fundamental para evaluar correctamente el desempeño y eficacia de los modelos propuestos.

#### 3.1.1 *Google Colab*

Para los procesos específicos de entrenamiento y predicción de las redes neuronales recurrentes (RNN), se ha utilizado el entorno de Google Colab. Esta plataforma proporciona un sandbox accesible y potente que permite aprovechar recursos computacionales avanzados como GPUs y TPUs, acelerando significativamente los tiempos de entrenamiento en comparación con el uso exclusivo de dispositivos locales. Además, su entorno basado en la nube facilita la replicabilidad de los experimentos y ofrece una gran flexibilidad para gestionar y compartir los resultados obtenidos. Esta elección responde directamente a la necesidad de optimizar el rendimiento computacional y de reducir considerablemente los tiempos involucrados en las fases más exigentes del desarrollo del modelo.

#### 3.1.2 *IA Generativa*

En esta investigación también se han integrado diversas herramientas de inteligencia artificial generativa, con el objetivo de mejorar tanto la calidad del trabajo como la eficiencia en la gestión del tiempo. **ChatGPT-4o**, junto a las versiones de razonamiento **ChatGPT-o1 y o3**, han sido especialmente útiles para generar contenidos de aprendizaje y validación precisos aclarando en muchos casos conceptos complejos, acelerando notablemente el proceso de redacción y revisión técnica. **Claude**, por su parte, se ha destacado en la síntesis de

información extensa y en proporcionar explicaciones claras, optimizando así la comprensión y organización de los temas tratados. Especialmente relevante en el desarrollo del código, optimizando su composición, analizando y revisando errores de codificación. La herramienta **Gemini**, siendo la menos utilizada, ha facilitado la generación rápida de borradores y resúmenes ejecutivos, contribuyendo significativamente en etapas iniciales del trabajo, acelerando la rampa de aprendizaje de conceptos básicos para esta tesis. **Napkin** ha aportado soluciones visuales para simplificar ideas complejas en diagramas claros y fáciles de comunicar. **Elicit** ha resultado especialmente útil para realizar revisiones sistemáticas de literatura y búsqueda profunda de publicaciones de impacto relacionadas con la temática de esta tesis, sobre todo relevante por su agilidad en la identificación de estudios relevantes, acelerando considerablemente el análisis bibliográfico.

**DeepL** ha permitido traducciones rápidas y precisas, garantizando calidad y coherencia lingüística, especialmente en contenidos técnicos especializados. **Storm**, desarrollado por **Stanford University**, ha contribuido a la estructuración metodológica y la optimización lógica de argumentos científicos complejos, ahorrando tiempo en la elaboración del discurso académico. **Perplexity** ha sido clave en la búsqueda avanzada de información actualizada, proporcionando fuentes precisas y organizadas, mejorando así la robustez argumentativa del documento. **FreePik** ha facilitado el acceso rápido a recursos gráficos de calidad para complementar visualmente las explicaciones técnicas. **Dall-e**, como parte de la multimodalidad ofrecida por la herramienta estrella de Open AI, ChatGPT, ha posibilitado la creación inmediata de imágenes generativas personalizadas, que apoyan visualmente los conceptos clave del trabajo.

**NoteBookLM** ha aportado capacidades avanzadas para organizar y analizar grandes volúmenes de información, simplificando la gestión del conocimiento generado durante la investigación. Finalmente, **Grok** ha servido para obtener respuestas rápidas a consultas técnicas y específicas, acelerando así las fases de resolución de dudas puntuales durante el desarrollo del trabajo. El conjunto de estas herramientas ha permitido optimizar significativamente tanto la calidad

general del resultado como los tiempos invertidos en las distintas fases del proyecto.

### 3.2. Herramientas de Hardware

En cuanto al hardware, esta investigación ha seleccionado cuidadosamente dispositivos EEG comerciales de bajo coste como Neurosky y Brainlink, los cuales ofrecen un equilibrio adecuado entre accesibilidad y rendimiento para la captura de señales cerebrales. Estos dispositivos, aunque presentan ciertas limitaciones en comparación con equipos clínicos avanzados, han demostrado ser suficientemente precisos y robustos para la adquisición fiable de datos EEG en entornos reales, facilitando así su integración en aplicaciones prácticas de interfaces cerebro-computadora (BCI).

Complementariamente, para garantizar la ejecución eficiente y en tiempo real de los modelos desarrollados, se han utilizado plataformas embebidas especializadas como Jetson Nano y Raspberry Pi5. Estos dispositivos proporcionan un rendimiento computacional considerable en un formato compacto y de bajo consumo energético, permitiendo la implementación efectiva de algoritmos complejos y facilitando su integración directa con sistemas robóticos mediante entornos como ROS y ROS2. Esta elección estratégica ha permitido enfrentar con éxito las restricciones propias del procesamiento en tiempo real, así como la optimización del consumo energético y los costos asociados a la implementación tecnológica.

#### 3.2.1 Jetson Nano (NVIDIA)

El dispositivo Jetson Nano desempeña un papel clave en esta investigación al ofrecer una plataforma embebida específicamente diseñada para aplicaciones de inteligencia artificial en tiempo real. Gracias a su arquitectura optimizada, que combina un procesador ARM con una GPU integrada de NVIDIA, permite ejecutar eficientemente algoritmos de aprendizaje profundo directamente en dispositivos físicos compactos y con bajo consumo energético[17]. Su uso previsto en este proyecto es actuar como unidad central de procesamiento embebida, facilitando la clasificación rápida y precisa de señales EEG capturadas por las diademas comerciales. Esto posibilita una integración fluida y en tiempo real con sistemas físicos mediante ROS y ROS2, asegurando así un desempeño eficaz en la

implementación práctica del sistema BCI. Se ha mostrado como un elemento de gran valor, en el objetivo de trasladar la información digital a los sistemas físicos.

### *3.2.2 Raspberry Pi5*

El microcontrolador Raspberry Pi5 equipada con el módulo Hailo se plantea como una alternativa estratégica al Jetson Nano en este proyecto, especialmente considerando la amplia comunidad de usuarios y desarrolladores que la respaldan. Esta combinación está específicamente diseñada para gestionar aplicaciones avanzadas de inteligencia artificial, proporcionando una alta capacidad de procesamiento de modelos de aprendizaje profundo con un consumo energético optimizado[121]. El módulo Hailo permite acelerar significativamente la inferencia de redes neuronales, ofreciendo una solución robusta y flexible para implementar en tiempo real algoritmos complejos de clasificación de señales EEG. Su adopción facilita, además, un acceso más sencillo a soporte técnico y recursos compartidos por una comunidad extendida, simplificando considerablemente tanto el desarrollo como la escalabilidad de futuras aplicaciones en el ámbito de las interfaces cerebro-computadora (BCI)[16].

## 4. Estado del Arte y Limitaciones Actuales

El desarrollo de **Interfaces Cerebro-Computadora (BCI)** ha emergido como un campo interdisciplinario de vanguardia que fusiona conocimientos avanzados en neurociencia computacional, procesamiento de señales, inteligencia artificial (IA) y robótica. Esta sinergia tecnológica tiene como objetivo habilitar la comunicación directa entre el cerebro humano y dispositivos externos, sin la intervención de los sistemas nerviosos periféricos ni la necesidad de acciones musculares. En este contexto, la **electroencefalografía (EEG)** se ha consolidado como la técnica más empleada para capturar la actividad cerebral, gracias a su naturaleza no invasiva, portabilidad y resolución temporal adecuada para aplicaciones en tiempo real (Nicolas-Alonso & Gómez-Gil, 2012).

La creciente demanda de soluciones tecnológicas que mejoren la calidad de vida de personas con discapacidades motoras, enfermedades neurodegenerativas y limitaciones en la movilidad ha impulsado el desarrollo de BCI orientadas al control de **dispositivos físicos** como **sillas de ruedas autónomas, prótesis robóticas, brazos articulados y exoesqueletos**. Estas aplicaciones permiten a los usuarios ejecutar acciones mediante la mera intención de movimiento, traducida en patrones específicos de actividad cerebral detectados por sistemas EEG. Esta interacción ofrece nuevas oportunidades para la rehabilitación neuromotora, la asistencia personalizada y la automatización de tareas en entornos clínicos y domésticos [122].

Sin embargo, a pesar de los avances tecnológicos, el uso de EEG para el control de dispositivos físicos enfrenta múltiples **desafíos técnicos y metodológicos** que limitan su eficacia en aplicaciones reales. Entre los principales problemas se encuentran la **baja relación señal-ruido (SNR)** de las señales EEG, la **variabilidad inter e intrasujeto**, la **latencia en la toma de decisiones** y la **susceptibilidad a artefactos** provocados por parpadeos, movimientos musculares y ruido ambiental [123]. Estas dificultades obligan a desarrollar técnicas de procesamiento de señales más sofisticadas, así como algoritmos de aprendizaje profundo capaces de extraer patrones relevantes de datos altamente ruidosos y no estacionarios.

El estado actual de la investigación ha evidenciado que los **modelos de aprendizaje profundo**, especialmente las **redes neuronales recurrentes (RNN)** como **Long Short-Term Memory (LSTM)** y **Gated Recurrent Units (GRU)**, ofrecen mejoras significativas en la decodificación de señales EEG debido a su capacidad para modelar la naturaleza secuencial y temporal de la actividad cerebral. No obstante, estos modelos presentan un **alto costo computacional** que puede afectar su implementación en tiempo real, especialmente en dispositivos portátiles y sistemas embebidos con recursos limitados como **Jetson Nano** y **Raspberry Pi**. Por otro lado, los **modelos clásicos de aprendizaje automático** como **Support Vector Machines (SVM)**, **Random Forest (RF)** y **Extreme Gradient Boosting (XGBoost)** continúan siendo alternativas viables en escenarios donde la rapidez de inferencia y la eficiencia computacional son prioritarias, aunque sacrificando en algunos casos la precisión obtenida por las redes neuronales más profundas[124].

La **clusterización y clasificación de patrones cerebrales** para la identificación de comandos motores básicos (por ejemplo, moverse hacia adelante, girar a la izquierda/derecha o detenerse) ha sido un área de especial interés en los últimos años. Investigaciones recientes han demostrado que la combinación de EEG con otros sensores, como la electromiografía (EMG) o sensores inerciales, puede mejorar la precisión y la robustez del control, reduciendo la tasa de falsos positivos y aumentando la capacidad de adaptación del sistema a diferentes contextos de uso [125].

Desde una perspectiva clínica y de implementación real, las aplicaciones de BCI basadas en EEG aún se enfrentan a desafíos relacionados con la **calibración prolongada**, la **fatiga cognitiva del usuario** y la **seguridad en la toma de decisiones autónomas**. La necesidad de sistemas que no solo sean precisos, sino también adaptativos, ligeros y portátiles, ha orientado la investigación hacia la **miniaturización del hardware** y la optimización de algoritmos mediante técnicas de **aprendizaje federado** (técnica innovadora de inteligencia artificial y aprendizaje automático que permite entrenar modelos de forma descentralizada, utilizando datos distribuidos en múltiples dispositivos o servidores sin comprometer la privacidad y seguridad de la información) y **computación en el borde (edge**

**computing**), lo que permitirá una mayor personalización y privacidad en el tratamiento de datos cerebrales .

Este capítulo revisa el estado actual del uso de EEG en el control de dispositivos físicos, analizando los enfoques metodológicos predominantes, las arquitecturas más empleadas y las principales limitaciones que enfrentan estos sistemas en aplicaciones del mundo real. A partir de esta revisión, se identifican las brechas existentes en la literatura y se plantea el camino a seguir para superar las limitaciones actuales, enfocándose en el desarrollo de sistemas más **robustos, eficientes y escalables** que permitan una interacción cerebro-máquina más natural e intuitiva.

#### 4.1. Estado Actual del Uso de EEG en el Control de Dispositivos Físicos

En los últimos años, el uso de señales electroencefalográficas (EEG) para el control de dispositivos físicos ha evolucionado significativamente gracias a los avances en neurociencia computacional, algoritmos de aprendizaje profundo y el desarrollo de hardware embebido capaz de procesar datos en tiempo real. Esta evolución ha permitido que las Interfaces Cerebro-Computadora (BCI) pasen de ser herramientas experimentales en laboratorios a aplicaciones prácticas en entornos clínicos, industriales y de asistencia personal.

El EEG, como técnica no invasiva, ofrece la ventaja de ser seguro y relativamente accesible en comparación con métodos invasivos, lo que ha motivado un auge en la investigación orientada al control de dispositivos físicos como sillas de ruedas, prótesis robóticas, drones y exoesqueletos [126]. Sin embargo, la naturaleza ruidosa y de baja relación señal-ruido (SNR) de las señales EEG, sumada a la variabilidad interindividual, plantea desafíos considerables en términos de precisión, latencia y generalización de los modelos utilizados para la decodificación de la actividad cerebral [127].

##### *4.1.1. Aplicaciones Actuales del EEG en Control Físico*

###### **Control de sillas de ruedas mediante BCI**

El control de sillas de ruedas autónomas mediante EEG ha sido uno de los focos principales de la investigación en BCI, con el objetivo de brindar movilidad a

personas con discapacidades motoras severas. Los enfoques tradicionales se basan en la detección de eventos relacionados con la imaginación motora (MI), la respuesta P300 y las oscilaciones mu/beta.

En investigaciones recientes, la incorporación de algoritmos de aprendizaje profundo como LSTM y GRU ha mejorado la detección de intenciones motoras, permitiendo tiempos de respuesta más rápidos y mayor robustez frente a interferencias externas[84]. Estas redes, al ser capaces de modelar secuencias temporales, ofrecen un desempeño superior respecto a los métodos tradicionales basados en SVM o Random Forest, especialmente en entornos no controlados.

#### Control de brazos robóticos y prótesis

El control de brazos robóticos y prótesis mioeléctricas mediante EEG ha permitido a personas con amputaciones o parálisis manipular objetos y realizar actividades cotidianas. Collinger et al. (2013) reportaron un caso clínico donde un paciente tetrapléjico logró realizar movimientos tridimensionales con un brazo robótico mediante la decodificación de señales EEG y la integración de redes neuronales convolucionales[113].

Por su parte, investigaciones recientes han explorado la integración de señales EEG con electromiografía (EMG), logrando un control híbrido que mejora la precisión en tareas de agarre fino y manipulación de herramientas (Meng et al., 2019). Esta combinación permite que las señales EEG actúen como moduladores de los comandos generados por la actividad muscular residual, aumentando la fiabilidad del sistema en situaciones de fatiga o fluctuaciones en la calidad de las señales.

#### Aplicaciones emergentes en drones y exoesqueletos

El uso de EEG para el control de drones ha ganado relevancia en el ámbito de la robótica de asistencia y la logística. Un estudio demostró la viabilidad de pilotar drones mediante señales cerebrales para misiones de búsqueda y rescate, alcanzando tasas de éxito superiores al 80% en entornos simulados [128].

En cuanto a los exoesqueletos, la integración de BCI ha sido explorada para la rehabilitación de pacientes con accidentes cerebrovasculares y lesiones medulares. Por este motivo hay investigaciones que desarrollaron un sistema que

utiliza EEG para activar patrones de marcha asistidos por exoesqueletos, obteniendo mejoras significativas en la recuperación de la función motora en pacientes en fase subaguda [67].

#### *4.1.2. Tecnologías y Algoritmos Predominantes*

##### **Modelos clásicos vs. aprendizaje profundo**

Históricamente, la clasificación de señales EEG se basaba en algoritmos tradicionales como Support Vector Machines (SVM), Linear Discriminant Analysis (LDA) y k-Nearest Neighbors (k-NN), que ofrecen tiempos de procesamiento reducidos, pero limitaciones en la detección de patrones complejos y ruidosos.

Con la llegada del aprendizaje profundo, modelos como las Redes Neuronales Convolucionales (CNN) y las Redes Neuronales Recurrentes (RNN), especialmente LSTM y GRU, se han convertido en la opción preferente para la decodificación de EEG. Estos modelos son capaces de capturar la dinámica temporal de las señales y ofrecen mejores resultados en términos de precisión y robustez frente a la variabilidad intersujeto e intrasujeto.

La tabla siguiente resume algunos de los estudios más relevantes que han comparado los modelos clásicos con las arquitecturas de aprendizaje profundo en la clasificación de EEG para el control de dispositivos físicos:

Tabla 1: Estudios más relevantes con arquitecturas de Aprendizaje Profundo (DL)

<b>Autor(es)</b>	<b>Año</b>	<b>Modelo</b>	<b>Aplicación</b>	<b>Precisión (%)</b>	<b>Referencia</b>
Peñaloza-Mendoza, Guillermo Rey et al.	2022	SVM	Silla de ruedas	85	[129]
Jeuland, Elouan Derenee et al.	2022	LSTM	Brazo robótico	91	[130]
Bouchane, Mouna et al.	2023	CNN + GRU	Control de drones	99,65	[131]
Chen, Chao feng et al.	2021	CNN + LSTM	Exoesqueleto	97,78	[132]

#### 4.1.3. Limitaciones actuales y desafíos

A pesar de los avances significativos, persisten desafíos que limitan la aplicabilidad generalizada de los sistemas BCI basados en EEG:

##### 1. Variabilidad inter e intrasujeto

- Las señales EEG pueden variar considerablemente entre sesiones y usuarios, requiriendo procesos de recalibración frecuentes.

##### 2. Baja relación señal-ruido (SNR)

- La susceptibilidad a interferencias externas, como parpadeos o movimientos musculares, dificulta la clasificación precisa de las señales.

##### 3. Latencia en la toma de decisiones

- Aunque los modelos profundos ofrecen mejor precisión, su complejidad computacional puede introducir retrasos inaceptables en aplicaciones en tiempo real.

##### 4. Costo y portabilidad del hardware

- Si bien existen dispositivos comerciales como Neurosky y Brainlink, su precisión es limitada en comparación con equipos clínicos de alta gama.

## 5. Aspectos éticos y de privacidad

- La manipulación de datos cerebrales plantea interrogantes sobre la seguridad, el consentimiento informado y el posible uso indebido de la información recogida.

### 4.1.4. Avances recientes y perspectivas futuras

El futuro del control de dispositivos físicos mediante EEG apunta a la integración de modelos híbridos que combinen aprendizaje profundo, lógica difusa y técnicas de optimización bayesiana para mejorar la precisión y reducir la latencia[133]. Se espera que la incorporación de redes neuronales transformadoras y aprendizaje federado permita modelos más robustos y personalizados sin comprometer la privacidad del usuario.

Asimismo, la miniaturización de hardware y el desarrollo de dispositivos portátiles de bajo costo, como las plataformas Jetson Nano y Raspberry Pi, están facilitando la implementación de sistemas BCI en entornos domésticos y clínicos, abriendo nuevas oportunidades para la asistencia y la rehabilitación personalizada[16].

## 4.2. Modelos de Aprendizaje Automático Aplicados a la Clasificación de Señales EEG

La clasificación de señales electroencefalográficas (EEG) es un desafío fundamental en el desarrollo de Interfaces Cerebro-Computadora (BCI), ya que la precisión y la velocidad de respuesta del sistema dependen en gran medida de la calidad del modelo de aprendizaje automático (AA) empleado. Las señales EEG son inherentemente no estacionarias, altamente ruidosas y con baja relación señal-ruido (SNR), lo que dificulta la tarea de extraer patrones fiables para la predicción de intenciones motoras o estados cognitivos .

El campo del aprendizaje automático ha evolucionado desde el uso de modelos clásicos como el Support Vector Machine (SVM) y Linear Discriminant Analysis (LDA) hasta métodos más avanzados basados en aprendizaje profundo (Deep Learning, DL), que incluyen Redes Neuronales Convolucionales (CNN), Redes Neuronales Recurrentes (RNN) y modelos híbridos que combinan las fortalezas de diferentes arquitecturas. Cada una de estas metodologías presenta ventajas y

limitaciones que afectan la capacidad del sistema BCI para ser implementado en aplicaciones del mundo real, especialmente en entornos que requieren procesamiento en tiempo real y una alta adaptabilidad a distintos usuarios y contextos .

En esta sección se presentan los principales modelos de aprendizaje automático utilizados en la clasificación de señales EEG, destacando sus características técnicas, ventajas, desventajas y casos de aplicación específicos. Se enfatiza la necesidad de un equilibrio entre la precisión de clasificación y la eficiencia computacional, particularmente en sistemas embebidos de bajo consumo energético utilizados para controlar dispositivos físicos.

#### *4.2.1. Modelos Clásicos de Aprendizaje Automático*

Los modelos clásicos han sido ampliamente utilizados en la clasificación de EEG debido a su baja complejidad computacional y facilidad de implementación. A pesar de que suelen ofrecer menor precisión que los modelos basados en DL, su velocidad de inferencia y su capacidad para funcionar con pequeños conjuntos de datos los hacen atractivos para aplicaciones con limitaciones de hardware.

##### **a) Support Vector Machine (SVM)**

El SVM se basa en la construcción de un hiperplano que maximiza la separación entre las clases de datos. Su uso en EEG ha sido exitoso en tareas de detección de eventos relacionados con la imaginación motora (MI) y en la discriminación de patrones P300 [65].

##### **Ventajas:**

- Buen rendimiento con conjuntos de datos limitados.
- Capaz de manejar espacios de alta dimensionalidad mediante kernels no lineales.

##### **Desventajas:**

- Requiere un proceso de optimización de parámetros sensible a la calidad de los datos.

- Puede ser computacionalmente costoso en grandes volúmenes de datos.

#### **Ejemplo de aplicación:**

En un estudio previo el SVM logró una precisión del 82% en la clasificación de patrones MI en un conjunto de datos de la competencia BCI IV [21] .

#### **b) Linear Discriminant Analysis (LDA)**

El LDA busca proyectar los datos en un espacio donde la separación entre las clases sea máxima. Ha sido una técnica predominante en BCI debido a su simplicidad y velocidad de procesamiento, siendo especialmente útil en sistemas con recursos computacionales limitados[134].

##### **Ventajas:**

- Eficiente computacionalmente, ideal para aplicaciones en tiempo real.
- Requiere poca calibración.

##### **Desventajas:**

- Sensible a datos no lineales y a la varianza desigual entre las clases.
- Menor capacidad de generalización frente a modelos más complejos.

#### **Ejemplo de aplicación:**

El LDA fue empleado en la clasificación de EEG para controlar una silla de ruedas, alcanzando precisiones superiores al 75% en entornos reales[135].

#### **c) Random Forest (RF) y XGBoost**

Los métodos basados en árboles de decisión, como Random Forest (RF) y Extreme Gradient Boosting (XGBoost), han ganado popularidad en el procesamiento de EEG por su robustez frente a datos ruidosos y su capacidad para manejar conjuntos de datos desequilibrados.

- RF combina múltiples árboles de decisión para mejorar la generalización y reducir el sobreajuste.

- XGBoost mejora el rendimiento a través de técnicas de regularización y optimización del gradiente, lo que lo convierte en una opción superior en términos de precisión y velocidad.

**Ventajas de XGBoost:**

- Alta precisión y resistencia al sobreajuste.
- Eficiente para la implementación en sistemas embebidos con recursos limitados.

**Desventajas:**

- Requiere un proceso de ajuste de hiperparámetros detallado.
- Su interpretación puede ser menos intuitiva que la de modelos más simples.

*4.2.2. Modelos de Aprendizaje Profundo Aplicados a EEG*

El aprendizaje profundo (DL) ha revolucionado la clasificación de señales EEG al permitir la extracción automática de características y la modelización de las relaciones temporales y espaciales de las señales. A diferencia de los modelos clásicos, los algoritmos de DL pueden aprender representaciones jerárquicas directamente de los datos crudos, eliminando la necesidad de etapas de preprocesamiento extensivas.

**a) Redes Neuronales Convolucionales (CNN)**

Las CNN han demostrado ser altamente eficaces para la extracción de características espaciales en señales EEG. A pesar de que fueron inicialmente diseñadas para procesar imágenes, su adaptación a la clasificación de EEG ha mostrado resultados sobresalientes, especialmente en la detección de patrones relacionados con la imaginación motora y las respuestas P300 [65].

Ventajas:

- Capacidad para extraer características espaciales y temporales.
- Eficientes en la detección de patrones en datos multicanal.

Desventajas:

- Requieren grandes conjuntos de datos para evitar el sobreajuste.
- Altos requerimientos computacionales.

#### b) Redes Neuronales Recurrentes (RNN), LSTM y GRU

Las RNN están diseñadas para procesar secuencias temporales, lo que las hace ideales para la clasificación de EEG. Las variantes más utilizadas son:

- LSTM (Long Short-Term Memory): Captura dependencias a largo plazo y maneja el problema del desvanecimiento del gradiente.
- GRU (Gated Recurrent Unit): Simplifica la arquitectura de LSTM, reduciendo la complejidad computacional y manteniendo un rendimiento competitivo.

Ventajas:

- Excelentes para capturar la dinámica temporal de las señales EEG.
- Mayor capacidad de generalización frente a datos no estacionarios.

Desventajas:

- Mayor carga computacional que modelos clásicos.
- Requiere optimización cuidadosa para evitar el sobreajuste.

Ejemplo de aplicación:

Roy et al. (2019) emplearon redes LSTM para la clasificación de señales EEG en la predicción de intenciones motoras, obteniendo precisiones cercanas al 90% en tareas de control de prótesis robóticas [136].

#### c) Modelos híbridos y arquitecturas avanzadas

Los modelos híbridos que combinan CNN y RNN (por ejemplo, CNN-LSTM) han mostrado mejoras significativas en la clasificación de EEG, aprovechando la capacidad de CNN para la extracción de características espaciales y la de LSTM para modelar las relaciones temporales.

#### 4.2.3. Desafíos y Oportunidades en la Clasificación de EEG

A pesar de los avances en modelos de aprendizaje automático aplicados a EEG, persisten varios desafíos:

- **Variabilidad interindividual:** Los modelos deben adaptarse a la heterogeneidad de las señales entre diferentes usuarios.
- **Datos limitados:** La adquisición de EEG suele ser costosa y limitada, lo que dificulta el entrenamiento de modelos profundos.
- **Balance entre precisión y eficiencia:** Es fundamental desarrollar modelos que sean tanto precisos como viables para sistemas portátiles de bajo consumo.

Sin embargo, se vislumbran oportunidades en la implementación de técnicas como:

- **Aprendizaje transferido (Transfer Learning):** Permite reutilizar modelos preentrenados en nuevos conjuntos de datos.
- **Aprendizaje federado:** Facilita la personalización de modelos sin comprometer la privacidad de los usuarios.
- **Optimización en hardware embebido:** Plataformas como Jetson Nano y Raspberry Pi pueden ejecutar modelos optimizados para aplicaciones en tiempo real.

#### 4.3. Redes LSTM y GRU para Predicción de Estados Cognitivos

La predicción de estados cognitivos a partir de señales electroencefalográficas (EEG) ha emergido como un área crítica dentro de las Interfaces Cerebro-Computadora (BCI), particularmente en aplicaciones orientadas a la mejora del rendimiento cognitivo, monitorización de la atención, interfaces adaptativas y control de dispositivos físicos mediante la actividad cerebral. La naturaleza secuencial y no estacionaria de las señales EEG plantea desafíos significativos para su modelado, siendo las Redes Neuronales Recurrentes (RNN), especialmente las variantes Long Short-Term Memory (LSTM) y Gated Recurrent Unit (GRU), las arquitecturas más adecuadas para abordar estos problemas.

Las redes LSTM y GRU han demostrado un rendimiento sobresaliente en tareas que requieren la captura de dependencias temporales de largo alcance, lo que resulta esencial para interpretar la dinámica temporal de las señales cerebrales asociadas a estados como atención, carga mental, relajación y estrés [136]. En comparación

con métodos tradicionales como Support Vector Machines (SVM) o Random Forest, estas redes ofrecen una capacidad superior para manejar secuencias ruidosas y de alta variabilidad, comunes en datos EEG.

Este apartado explora en profundidad la arquitectura, funcionamiento, ventajas y limitaciones de las redes LSTM y GRU en el contexto de la predicción de estados cognitivos. Se analizan casos de uso relevantes, se comparan sus rendimientos y se discuten las aplicaciones prácticas en BCI, particularmente en el control de dispositivos físicos a partir de patrones cerebrales detectados.

#### *4.3.1. Predicción de Estados Cognitivos a partir de EEG*

Los estados cognitivos son manifestaciones de la actividad cerebral que reflejan procesos mentales como la atención sostenida, la memoria de trabajo, la carga cognitiva y las emociones. La predicción precisa de estos estados es fundamental para aplicaciones como:

- Monitorización de la atención en entornos educativos y laborales [137].
- Control de dispositivos físicos para asistencia motriz [138].
- Interacción adaptativa en sistemas inteligentes [139].
- Neurofeedback para la mejora del rendimiento cognitivo [140].

### **Importancia de la predicción temporal**

La señal EEG es altamente dinámica, con variaciones que pueden ocurrir en milisegundos. Por ello, la predicción de estados cognitivos no solo requiere identificar patrones estáticos, sino comprender cómo evolucionan estas señales a lo largo del tiempo. Modelos secuenciales como LSTM y GRU permiten capturar estas transiciones de forma más robusta que los modelos tradicionales.

#### *4.3.2. Arquitectura y Funcionamiento de las Redes LSTM*

##### **Estructura general**

La red Long Short-Term Memory (LSTM) fue introducida por Hochreiter y Schmidhuber (1997) para superar las limitaciones de las RNN tradicionales, especialmente el problema del desvanecimiento del gradiente que afecta la capacidad de las redes para aprender dependencias a largo plazo. Las LSTM utilizan

unidades especiales denominadas celdas LSTM, que incorporan tres tipos de puertas:

- **Puerta de olvido (forget gate):** Decide qué información del estado anterior se debe descartar.
- **Puerta de entrada (input gate):** Determina qué nueva información se debe almacenar en la celda.
- **Puerta de salida (output gate):** Controla la salida de información de la celda hacia las capas siguientes.

Matemáticamente, las operaciones principales son:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

*Ecuación 1*

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

*Ecuación 2*

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

*Ecuación 3*

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

*Ecuación 4*

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

*Ecuación 5*

$$h_t = o_t * \tanh(C_t)$$

*Ecuación 6*

Donde:

- $x_t$  es la entrada de tiempo  $t$  (vector de características extraídas del EEG).
- $h_{t-1}$  es la salida del estado anterior.
- $C_t$  es el estado de la celda.
- $\sigma$  representa la función sigmoide y  $\tanh$  la tangente hiperbólica.

## Ventajas de las LSTM en EEG

Captura eficaz de patrones de larga duración en las señales cerebrales.

Resistencia al desvanecimiento y explosión del gradiente.

Mayor precisión en la predicción de estados prolongados como la atención sostenida.

### **Limitaciones**

Alto costo computacional.

Necesidad de grandes conjuntos de datos para un entrenamiento eficiente.

Mayor tiempo de entrenamiento comparado con arquitecturas simplificadas.

### **Caso de aplicación:**

Se han utilizado redes LSTM para predecir niveles de atención y carga cognitiva en tareas prolongadas de monitorización, logrando una precisión del 88% en la predicción de estados de atención a partir de señales EEG multicanal[141].

#### *4.3.3. Arquitectura y Funcionamiento de las Redes GRU*

La Gated Recurrent Unit (GRU), propuesta por Cho et al. (2014), es una variante simplificada de la LSTM que busca reducir la complejidad computacional manteniendo la capacidad de modelado temporal. A diferencia de la LSTM, la GRU combina las funciones de las puertas de olvido y entrada en una única puerta de actualización.

### **Componentes principales**

- **Puerta de actualización (update gate,  $z_t$ ):** Decide cuánto del estado anterior se conserva.
- **Puerta de reinicio (reset gate,  $r_t$ ):** Determina qué parte de la información pasada se ignora.

Las operaciones se describen mediante las siguientes ecuaciones:

*Ecuación 7*

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$$

*Ecuación 8*

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t])$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t])$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t$$

### Ventajas de las GRU en EEG

- Menor cantidad de parámetros, lo que reduce los tiempos de entrenamiento.
- Adecuada para aplicaciones en tiempo real y sistemas embebidos.
- Rendimiento comparable a las LSTM en la mayoría de las tareas.

### Limitaciones

- Menor capacidad que LSTM para capturar dependencias muy prolongadas.
- Puede sobreajustarse en conjuntos de datos pequeños.

Caso de aplicación:

La red GRU fue utilizada para predecir la meditación y la relajación en usuarios expuestos a estímulos auditivos. La GRU logró una precisión del 90% con un tiempo de inferencia 30% menor que el de las LSTM [23].

#### 4.3.4. Comparación entre LSTM y GRU en Predicción de Estados Cognitivos

Los resultados de estudios comparativos muestran que, aunque las LSTM ofrecen mejores resultados en contextos donde se requieren predicciones a largo plazo, las GRU son preferibles en aplicaciones que demandan baja latencia y menor consumo energético .

Tabla 2: Comparación entre LSTM y GRU

Criterio	LSTM	GRU
Precisión	Ligeramente superior en secuencias largas	Comparable con menor complejidad
Tiempo de entrenamiento	Más prolongado	Más rápido
Requerimientos de hardware	Mayor consumo computacional	Eficiente para hardware embebido
Aplicación recomendada	Predicción de estados prolongados	Aplicaciones en tiempo real
Adaptabilidad	Mejor para datos no estacionarios	Mayor rapidez de convergencia

#### 4.3.5. Aplicaciones Prácticas en BCI y Control de Dispositivos Físicos

La predicción de estados cognitivos mediante LSTM y GRU ha sido implementada en una amplia gama de aplicaciones, entre ellas:

- **Control de sillas de ruedas:** Identificación de estados de concentración para activar comandos de movimiento.
- **Prótesis robóticas:** Activación de agarres basados en la detección de intenciones motoras .
- **Monitorización de la fatiga en conductores:** Detección de estados de somnolencia en tiempo real .
- **Neurofeedback:** Proporcionar retroalimentación visual o auditiva para mejorar la atención y relajación .

#### Caso de uso destacado:

En un entorno clínico, se demostraron que un sistema híbrido basado en CNN-GRU permitió mejorar la precisión de predicción de estados cognitivos hasta un 94%, facilitando el control de un exoesqueleto en pacientes con movilidad reducida [142].

#### 4.3.6. Desafíos y Perspectivas Futuras

##### Principales desafíos:

- Necesidad de grandes volúmenes de datos para evitar sobreajuste.

- Variabilidad entre sujetos que requiere procesos de recalibración.
- Dificultades para implementar modelos complejos en hardware portátil.

#### **Líneas futuras de investigación:**

- **Aprendizaje transferido:** Para reducir los tiempos de entrenamiento en nuevos usuarios.
- **Optimización de modelos para hardware embebido:** Uso de técnicas de cuantización y poda.
- **Implementación de modelos híbridos:** Combinación de LSTM/GRU con modelos basados en Transformers para mejorar la predicción de estados cognitivos.

Este análisis proporciona una visión exhaustiva y técnica sobre el uso de **LSTM y GRU en la predicción de estados cognitivos** a partir de señales EEG, subrayando sus ventajas, limitaciones y aplicaciones prácticas en el control de dispositivos físicos.

#### **4.4. Modelos Clásicos para Clasificación de señales EEG**

La clasificación de señales electroencefalográficas (EEG) es un componente esencial en las Interfaces Cerebro-Computadora (BCI), siendo fundamental para interpretar los patrones de la actividad cerebral y transformarlos en comandos para el control de dispositivos físicos. Si bien las redes neuronales profundas como LSTM y GRU se han consolidado como herramientas eficaces para modelar secuencias temporales de EEG, su implementación puede ser computacionalmente intensiva y, en algunos casos, poco práctica para aplicaciones en tiempo real o en dispositivos con recursos limitados. En este contexto, modelos clásicos de aprendizaje automático, como XGBoost y el modelo basado en estabilización Popov, han demostrado ser soluciones viables al equilibrar precisión, eficiencia y rapidez de inferencia, especialmente en sistemas embebidos de bajo consumo energético.

Este apartado aborda con profundidad los fundamentos teóricos, la arquitectura y las aplicaciones de los modelos XGBoost y Popov en la clasificación de señales

EEG, subrayando sus ventajas comparativas frente a modelos basados en aprendizaje profundo, así como sus limitaciones y desafíos en aplicaciones reales.

#### 4.4.1. Fundamentos Teóricos de los Modelos Clásicos en EEG

Los modelos clásicos de aprendizaje automático se basan en métodos estadísticos y de optimización que permiten la clasificación de datos mediante reglas de decisión derivadas directamente de las características extraídas. A diferencia de las redes neuronales profundas, estos modelos suelen requerir un preprocesamiento más exhaustivo de las señales para la extracción de características relevantes, pero ofrecen la ventaja de ser computacionalmente más eficientes y requerir menos datos para su entrenamiento [126].

Entre estos modelos, XGBoost y el modelo de estabilización propuesto por Popov destacan por su capacidad de generalización, su resistencia al sobreajuste y su adaptabilidad a distintos tipos de datos, incluyendo las complejas y ruidosas señales EEG.

#### 4.4.2. XGBoost: Extreme Gradient Boosting

##### **Conceptos básicos y arquitectura**

XGBoost es un algoritmo de ensamblado basado en árboles de decisión que utiliza la técnica de gradient boosting, optimizando el proceso de predicción mediante la adición secuencial de modelos débiles (árboles) para corregir los errores cometidos por los modelos anteriores [107]. Su popularidad radica en su eficiencia computacional, su capacidad para manejar datos faltantes y su flexibilidad para ajustarse a tareas tanto de regresión como de clasificación.

La función de coste que minimiza XGBoost combina la pérdida del modelo con un término de regularización que penaliza la complejidad para evitar el sobreajuste como se refleja en la ecuación 11 :

*Ecuación 11*

$$\mathcal{L} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k)$$

Donde:

- $l(y_i, \hat{y}_i)$  es la función de pérdida (por ejemplo, log-loss en clasificación binaria).
- $\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|w\|^2$  representa la regularización del modelo.
- $\gamma$  y  $\lambda$  son hiperparámetros de regularización.

La estructura de esta arquitectura se muestra en la figura 12, describiendo el funcionamiento de la red XGBoost.

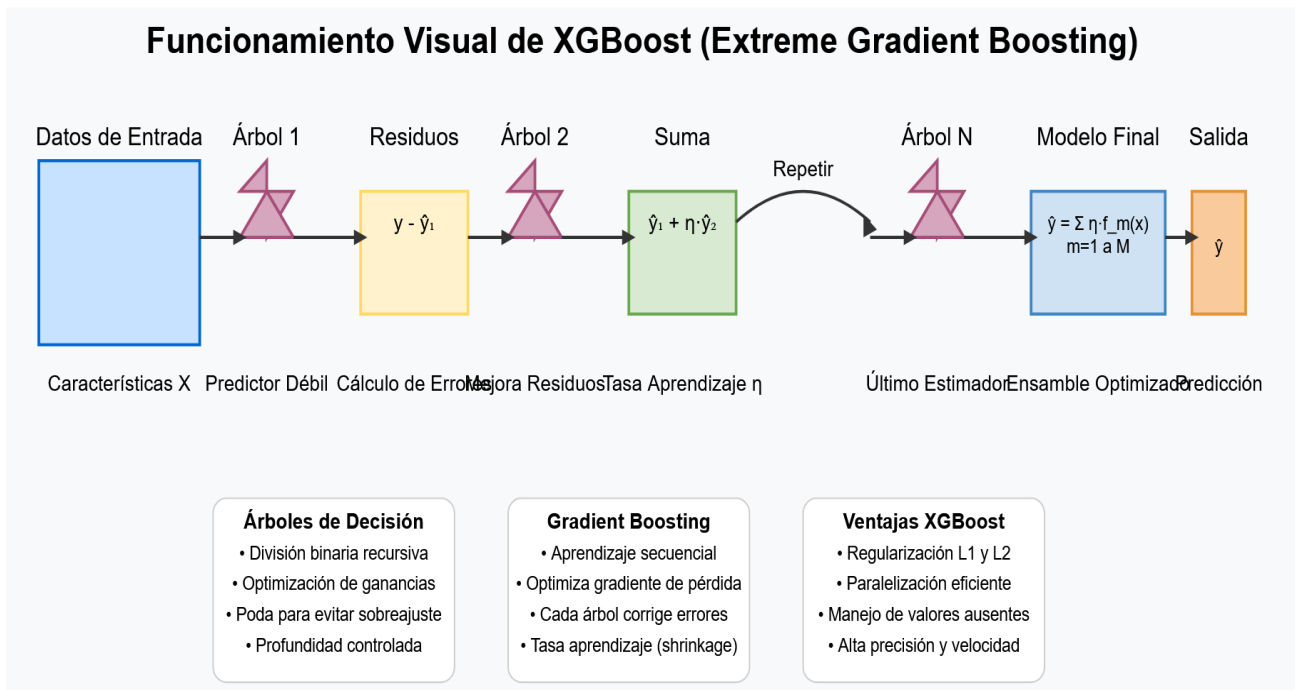


Figura 16: Estructura de funcionamiento de una arquitectura XGBoost

En este contexto y teniendo en cuenta el origen de los datos, la optimización de parámetros en XGBoost para clasificación de señales EEG requiere un enfoque especializado debido a la naturaleza compleja y alta dimensionalidad de estos datos biomédicos.

Los parámetros más críticos incluyen:

### Hiperparámetros clave

1. **learning\_rate (eta):** Controla la contribución de cada árbol al modelo final. Valores bajos (0.01-0.3) mejoran la generalización, pero requieren más

iteraciones[143]. Fundamental para evitar sobreajuste en señales con alta variabilidad temporal.

2. **max\_depth**: Determina la profundidad máxima de los árboles. En EEG se recomienda valores entre 3-7 para capturar patrones espectrales sin sobrecomplejidad.
3. **n\_estimators**: Número de árboles en el modelo. Debe balancearse con el learning\_rate para evitar largos tiempos de entrenamiento (típicamente 100-500).
4. **subsample y colsample\_bytree**:
  - subsample (0.7-1.0): Fracción de muestras usadas por árbol.
  - colsample\_bytree (0.5-0.9): Fracción de características usadas. Críticos para manejar la alta dimensionalidad de características EEG.

### Parámetros específicos de EEG

Tabla 3: Parámetros específicos “típicos” para redes XGBoost con señales EEG

Parámetro	Rango óptimo	Impacto en señales EEG
<b>gamma</b>	0-5	Controla división de nodos basada en ganancia mínima
<b>min_child_weight</b>	1-10	Previene sobreajuste en características ruidosas
<b>reg_alpha</b>	0-0.1	Regularización L1 para selección de características

### Consideraciones especiales:

- La función objetivo (*objective*) debe seleccionarse según la naturaleza multiclase/multietiqueta de los datos EEG.
- El parámetro *scale\_pos\_weight* es crucial para manejar desbalanceo en clases típico de datasets biomédicos.
- El booster (*gbtree* vs *dart*) afecta la capacidad de capturar patrones temporales complejos.

La optimización debe incluir técnicas como **Bayesian Optimization** o **Grid Search** cruzado, considerando las características espectrales y temporales NO lineales propias del EEG. La validación debe realizarse con métricas específicas del

dominio médico (ej: sensibilidad antes que precisión) debido a las consecuencias críticas de falsos negativos en diagnósticos

A continuación, ampliamos los conceptos básicos de las principales técnicas de optimización recomendadas y comentadas en el punto anterior.

1. **Optimización Bayesiana:** Esta técnica es particularmente efectiva para la optimización de hiperparámetros en modelos complejos como XGBoost. Permite una búsqueda más eficiente del espacio de parámetros en comparación con métodos de fuerza bruta, lo que es crucial dado el alto costo computacional asociado con el procesamiento de señales EEG.
2. **Búsqueda en cuadrícula con validación cruzada:** Aunque computacionalmente más intensiva, esta técnica permite una exploración exhaustiva de combinaciones de parámetros predefinidas. Es especialmente útil para identificar rangos óptimos de parámetros críticos como *max\_depth*, *learning\_rate*, y *n\_estimators*.
3. **RandomSearch:** Puede ser más eficiente que la búsqueda en cuadrícula para espacios de parámetros grandes, como es el caso de XGBoost aplicado a señales EEG. Permite explorar un espacio más amplio de configuraciones en menos tiempo.
4. **Optimización basada en gradientes:** Aunque no es común para XGBoost, técnicas de optimización basadas en gradientes podrían aplicarse para ajustar ciertos parámetros continuos del modelo.

### Consideraciones específicas para el tratamiento de señales EEG

- **Preprocesamiento de señales:** La optimización debe incluir la selección de características espectrales y temporales relevantes de las señales EEG, similar al enfoque utilizado en el análisis de texturas en imágenes digitales.
- **Manejo de alta dimensionalidad:** Las señales EEG típicamente tienen alta dimensionalidad, por lo que la optimización de parámetros como *subsample* y *colsample\_bytree* es crucial para evitar el sobreajuste.
- **Balanceo de clases:** En caso de clases desequilibradas en los datos EEG, la optimización del parámetro *scale\_pos\_weight* es fundamental.
- **Validación específica del dominio:** Utilizar métricas de evaluación específicas para EEG, como la sensibilidad y especificidad en la detección de eventos cognitivos

La elección final de la técnica de optimización dependerá de factores como el tamaño del conjunto de datos, los recursos computacionales disponibles y las características específicas de las señales EEG analizadas. Es recomendable

combinar varias técnicas y realizar una validación cruzada rigurosa para garantizar la robustez del modelo optimizado.

#### 4.4.3. Flujo de procesamiento de XGBoost:

1. **Datos de entrada:** Representados por un cuadro azul, son las características ( $X$ ) con las que el modelo trabajará para realizar predicciones.
2. **Primer árbol de decisión:** Visualizado como una estructura en forma de árbol en color morado, este es el primer "predictor débil" que genera una predicción inicial básica.
3. **Cálculo de residuos:** En amarillo, representa la diferencia entre los valores reales ( $y$ ) y las predicciones del primer árbol ( $\hat{y}_1$ ). Estos residuos son los errores que intentaremos corregir.
4. **Segundo árbol:** Otro árbol morado que, a diferencia del primero, está entrenado específicamente para predecir los residuos (errores) del árbol anterior, no los valores originales.
5. **Suma ponderada:** En verde, muestra cómo se combinan las predicciones del primer árbol con las del segundo, aplicando una tasa de aprendizaje ( $\eta$ ) que controla la contribución de cada nuevo árbol.
6. **Proceso iterativo:** Una flecha curva indica que este proceso se repite múltiples veces, añadiendo árboles sucesivos que continúan corrigiendo los errores residuales.
7. **Árbol final:** Representa el último árbol añadido al ensamble después de múltiples iteraciones.
8. **Modelo final:** En azul, muestra la fórmula matemática que combina todos los árboles individuales para formar la predicción definitiva, utilizando la suma ponderada de todas las contribuciones.
9. **Salida:** El resultado final del modelo después de combinar todos los árboles de decisión.

#### 4.4.4. Conceptos clave explicados:

1. En la parte inferior del diagrama hay tres recuadros que explican conceptos fundamentales:

2. **Árboles de decisión:** Explica las características básicas de los árboles que componen XGBoost.
3. **Gradient Boosting:** Describe el proceso iterativo de mejora mediante la corrección de errores.
4. **Ventajas de XGBoost:** Destaca las mejoras específicas que XGBoost aporta sobre otros algoritmos de boosting, como la regularización, paralelización y manejo de valores ausentes.

### **Aplicación de XGBoost en EEG**

El uso de XGBoost en la clasificación de EEG ha sido impulsado por su capacidad para manejar características heterogéneas extraídas mediante métodos como la Transformada de Fourier (FFT), Wavelet Packet Decomposition (WPD) y Análisis de Componentes Independientes (ICA).

#### **Ventajas:**

- Excelente rendimiento en conjuntos de datos con ruido y alta variabilidad.
- Capacidad para manejar datos no balanceados mediante técnicas de ponderación.
- Alta eficiencia en la inferencia, ideal para aplicaciones en tiempo real.

#### **Limitaciones:**

- Requiere un proceso de ajuste de hiperparámetros cuidadoso.
- Menor capacidad para capturar dependencias temporales que modelos como LSTM o GRU.

#### *4.4.5. Modelo Popov: Estabilización y Mejora en la Clasificación de EEG*

##### **Introducción al modelo Popov**

El modelo Popov, propuesto recientemente como una mejora de las arquitecturas clásicas de redes neuronales recurrentes, introduce un enfoque de estabilización dinámica que busca mitigar los efectos de la variabilidad interindividual y la no estacionariedad (modelo no estacionario) de las señales EEG[18]. Este modelo se

basa en la integración de filtros estabilizadores y un mecanismo adaptativo que ajusta los pesos de la red en función de la variación instantánea de las señales[144].

A diferencia de los modelos tradicionales, la arquitectura Popov incorpora una capa estabilizadora antes de la red neuronal principal, que se encarga de:

- Filtrar artefactos y fluctuaciones de alta frecuencia no relevantes.
- Ajustar dinámicamente la ganancia para mejorar la sensibilidad a patrones sutiles.
- Compensar la variabilidad causada por el estado emocional o la fatiga del usuario.

### **Funcionamiento matemático**

El modelo se basa en la solución de la ecuación diferencial de estabilización:

*Ecuación 12*

$$\frac{dx(t)}{dt} = -\alpha x(t) + \beta u(t)$$

Donde:

- $x(t)$  es la salida estabilizada.
- $u(t)$  representa la señal EEG original.
- $\alpha$  y  $\beta$  son coeficientes adaptativos que se ajustan en tiempo real.

El estado estabilizado se utiliza como entrada para modelos de clasificación como XGBoost o redes GRU, lo que mejora la robustez del sistema.

### **Ventajas del modelo Popov**

- Reducción significativa de la variabilidad inter-sujeto: Mejora la generalización del modelo sin requerir extensas recalibraciones.
- Estabilidad en condiciones adversas: Se mantiene robusto frente a artefactos comunes como el parpadeo o la masticación.
- Bajo coste computacional adicional: La capa estabilizadora añade mínima latencia al sistema.

## Limitaciones

- Requiere un proceso inicial de calibración para determinar los parámetros óptimos  $\alpha$  y  $\beta$ .

- Puede no ser adecuado para señales con cambios abruptos intencionados, como comandos de emergencia.

### 4.4.6. Aplicaciones Prácticas en Control de Dispositivos Físicos

Los modelos XGBoost y Popov se han aplicado con éxito en diversas áreas de la BCI orientada al control físico:

- Control de sillas de ruedas autónomas: Predicción de intenciones de movimiento con mínima latencia.
- Manipulación de brazos robóticos: Precisión en la clasificación de comandos de agarre y desplazamiento.
- Monitorización de estados cognitivos: Evaluación de la atención y la fatiga en tiempo real.
- Neurofeedback: Retroalimentación en sesiones de entrenamiento cognitivo.

### 4.4.7. Desafíos y Perspectivas Futuras

A pesar de sus ventajas, los modelos clásicos enfrentan ciertos desafíos:

- Limitaciones en la captura de dependencias temporales complejas: Especialmente cuando se utilizan sin arquitecturas complementarias como LSTM.
- Necesidad de calibración inicial: El modelo Popov requiere un ajuste personalizado para cada usuario.
- Sensibilidad a la calidad de las características extraídas: Un mal preprocesamiento puede afectar significativamente el rendimiento.

### Líneas de investigación futura:

- Integración de modelos híbridos que combinen la eficiencia de XGBoost con la capacidad temporal de las redes LSTM[92].

- Desarrollo de algoritmos de autoajuste dinámico para los parámetros de estabilización del modelo Popov.
- Optimización para implementación en hardware embebido de bajo consumo, como Raspberry Pi y Jetson Nano.

#### 4.5. Limitaciones en la Clasificación y Control de Dispositivos con EEG

El uso de señales electroencefalográficas (EEG) para la clasificación y control de dispositivos físicos representa uno de los avances más prometedores en el campo de las Interfaces Cerebro-Computadora (BCI). Sin embargo, a pesar de los avances tecnológicos y metodológicos logrados en las últimas décadas, la implementación práctica y efectiva de estos sistemas enfrenta una serie de limitaciones que afectan su rendimiento, fiabilidad y aplicabilidad en entornos reales. Estas limitaciones se derivan tanto de la naturaleza intrínseca de las señales EEG como de los modelos de procesamiento y clasificación empleados.

Este apartado aborda de forma exhaustiva y técnica las principales barreras y desafíos en la clasificación y control de dispositivos mediante EEG, centrándose en la variabilidad de las señales, la latencia en la toma de decisiones, la generalización de modelos, la interacción humano-máquina, y los aspectos computacionales y éticos involucrados. La identificación y comprensión de estas limitaciones son fundamentales para el desarrollo de soluciones más robustas, eficientes y escalables.

##### 4.5.1. Limitaciones Intrínsecas de las Señales EEG

###### a) Baja relación señal-ruido (SNR)

Las señales EEG se caracterizan por una baja amplitud ( $\mu\text{V}$ ) y una alta susceptibilidad a interferencias externas. Fuentes comunes de ruido incluyen:

- Movimientos oculares y musculares (Electrooculografía - EOG y Electromiografía - EMG).
- Interferencias electromagnéticas del entorno (por ejemplo, líneas eléctricas de 50/60 Hz).
- Variabilidad debido a la calidad del contacto de los electrodos y el tipo de diadema utilizada.

Esta baja SNR complica la extracción de características relevantes y puede llevar a tasas elevadas de falsos positivos y negativos en la clasificación[125].

### **b) Variabilidad inter e intrasujeto**

Uno de los principales desafíos en la clasificación de EEG es la variabilidad entre sujetos (interindividual) y dentro de un mismo sujeto (intrasujeto) debido a factores como:

- Diferencias anatómicas y fisiológicas.
- Cambios en el estado emocional, la fatiga y el nivel de concentración.
- Variaciones en la colocación de los electrodos entre sesiones.

Esta variabilidad obliga a implementar procesos de recalibración que pueden resultar tediosos y poco prácticos para el usuario final.

### **c) No estacionariedad de las señales**

Las señales EEG son sustancialmente no estacionarias, lo que significa que sus propiedades estadísticas varían con el tiempo. Este fenómeno afecta la estabilidad de los modelos de clasificación y dificulta la implementación de sistemas BCI que mantengan un rendimiento consistente durante sesiones prolongadas o en aplicaciones móviles.

#### *4.5.2. Limitaciones en los Modelos de Clasificación*

##### **a) Falta de generalización y sobreajuste**

Los modelos de aprendizaje automático, especialmente los basados en redes neuronales profundas (DNN), tienden a sobre ajustarse a los datos de entrenamiento, especialmente cuando:

- Se dispone de conjuntos de datos limitados.
- La variabilidad Inter sujeto no está suficientemente representada.
- Se utilizan características altamente específicas que no generalizan bien a nuevas muestras.

El sobreajuste se traduce en un rendimiento elevado en entornos controlados, pero con una caída significativa en escenarios reales y con nuevos usuarios.

## **b) Latencia en la toma de decisiones**

Para aplicaciones en tiempo real, como el control de sillas de ruedas o brazos robóticos, la latencia en la predicción es un factor crítico. Aunque los modelos basados en LSTM y GRU son eficaces en la captura de dependencias temporales, su complejidad computacional puede generar retrasos que afectan la fluidez y seguridad del control [50].

## **c) Dependencia del preprocesamiento de datos**

La eficacia de los modelos de clasificación EEG depende en gran medida de la calidad del preprocesamiento. Técnicas como la Transformada de Fourier (FFT), Wavelet Packet Decomposition (WPD) y Análisis de Componentes Independientes (ICA) son esenciales para la limpieza y extracción de características. Sin embargo, estos procesos pueden ser computacionalmente costosos y poco adecuados para aplicaciones que requieren procesamiento en tiempo real [145].

### *4.5.3. Limitaciones en la Interacción Humano-Máquina*

#### **a) Fatiga cognitiva y carga mental**

El uso prolongado de sistemas BCI puede inducir fatiga mental, lo que afecta la calidad de las señales EEG y, por ende, la precisión de la clasificación. Además, la carga cognitiva requerida para mantener un estado mental específico (por ejemplo, concentración sostenida para ejecutar un comando) puede ser excesiva para usuarios no entrenados [146].

#### **b) Retardo en la retroalimentación**

Una retroalimentación lenta o inadecuada puede generar frustración en el usuario y disminuir la eficacia del sistema. La sincronización entre la intención detectada y la acción realizada debe ser casi inmediata para evitar desalineaciones que podrían resultar en comandos no deseados .

#### **c) Limitación en la cantidad de comandos**

Aunque se han logrado avances en la clasificación de múltiples comandos, la cantidad de patrones cerebrales distinguibles sigue siendo limitada. Esto restringe el número de acciones que un usuario puede realizar a través de un BCI, lo que

afecta la funcionalidad de sistemas más complejos como la manipulación precisa de prótesis o la navegación en entornos tridimensionales .

#### *4.5.4. Limitaciones Computacionales y de Hardware*

##### **a) Requerimientos computacionales elevados**

Si bien modelos como XGBoost y el modelo Popov han sido optimizados para funcionar en hardware embebido, arquitecturas más complejas como CNN-LSTM requieren recursos computacionales que exceden las capacidades de dispositivos portátiles de bajo costo [1]. Esto limita la portabilidad y la aplicabilidad de los sistemas BCI en entornos fuera del laboratorio.

##### **b) Consumo energético**

Para aplicaciones móviles o portátiles, como exoesqueletos o prótesis autónomas, el consumo energético es un factor crucial. Modelos que requieren procesamiento intensivo pueden agotar rápidamente las baterías, afectando la autonomía del dispositivo [147].

##### **c) Latencia de hardware**

La velocidad de procesamiento no solo depende del modelo de clasificación, sino también del hardware empleado. Incluso con modelos optimizados, las limitaciones en la capacidad de procesamiento de plataformas como Raspberry Pi o Jetson Nano pueden introducir retrasos significativos en la inferencia .

#### *4.5.5. Limitaciones Éticas y Sociales*

##### **a) Privacidad y seguridad de los datos cerebrales**

Las señales EEG contienen información sensible que podría, potencialmente, revelar estados emocionales o predisposiciones cognitivas. El manejo inadecuado de estos datos plantea preocupaciones sobre la privacidad y el consentimiento informado, especialmente en aplicaciones comerciales o de monitorización en el entorno laboral .

##### **b) Accesibilidad y equidad tecnológica**

El acceso a tecnologías BCI avanzadas sigue siendo limitado en regiones con menos recursos. Además, la adaptación de estos sistemas a usuarios con

diferentes condiciones fisiológicas o culturales es un desafío que requiere atención para evitar sesgos tecnológicos [126]

### **c) Dependencia tecnológica**

El uso prolongado de BCI para actividades cotidianas podría generar una dependencia tecnológica que afecte la autonomía natural de los usuarios. Además, la sobre confianza en la tecnología puede llevar a riesgos si el sistema falla o interpreta erróneamente las señales cerebrales .

#### *4.5.6. Estrategias para Mitigar las Limitaciones*

Ante estas limitaciones, la comunidad científica ha propuesto diversas estrategias y soluciones:

- Aprendizaje transferido y federado: Para mejorar la generalización de modelos y reducir la necesidad de recalibración.
- Optimización de hardware: Uso de plataformas específicas para IA, como el Google Edge TPU, para acelerar la inferencia.
- Modelos híbridos: Combinación de modelos clásicos (XGBoost, Popov) con redes neuronales profundas para aprovechar las ventajas de ambos enfoques.
- Mejora en la adquisición de datos: Uso de diademas EEG más estables y resistentes a interferencias.
- Implementación de sistemas adaptativos: Que ajusten dinámicamente los parámetros del modelo según la variabilidad del usuario.

#### **4.6. Brechas y Oportunidades en el Campo**

El uso de señales electroencefalográficas (EEG) para la clasificación de patrones cerebrales y el control de dispositivos físicos ha avanzado significativamente en las últimas décadas. Sin embargo, a pesar de los progresos logrados, persisten brechas fundamentales que limitan la adopción masiva y la efectividad de las Interfaces Cerebro-Computadora (BCI) en aplicaciones prácticas. Estas brechas, derivadas tanto de las limitaciones tecnológicas como de los desafíos metodológicos y éticos, constituyen áreas críticas que requieren atención para garantizar sistemas más robustos, precisos y accesibles.

Simultáneamente, estos desafíos representan oportunidades únicas para la innovación y el desarrollo de nuevas soluciones que permitan superar las barreras existentes. Este apartado ofrece un análisis exhaustivo de las brechas actuales en la clasificación de EEG y el control de dispositivos físicos, así como las oportunidades emergentes que podrían revolucionar el campo en los próximos años.

#### *4.6.1. Brechas Tecnológicas y Metodológicas*

##### **a) Variabilidad inter e intrasujeto**

Uno de los mayores desafíos en el procesamiento de señales EEG es la alta variabilidad entre usuarios (interindividual) y dentro del mismo usuario a lo largo del tiempo (intrasujeto). Factores como la fatiga, el estado emocional, la edad, y la colocación de los electrodos afectan la estabilidad de las señales . Esta variabilidad obstaculiza la generalización de modelos de clasificación, obligando a realizar procesos de recalibración frecuentes que reducen la usabilidad práctica.

Oportunidad:

Desarrollo de modelos adaptativos que se ajusten automáticamente a la variabilidad del usuario.

Uso de aprendizaje federado para permitir la personalización de modelos sin comprometer la privacidad de los datos cerebrales.

##### **b) Limitaciones en la calidad de los dispositivos EEG de bajo costo**

Aunque el uso de dispositivos comerciales como Neurosky y Brainlink ha democratizado el acceso a la tecnología BCI, la calidad de las señales obtenidas con estos dispositivos suele ser inferior a la de sistemas médicos de grado clínico. Esto se traduce en una baja relación señal-ruido (SNR), afectando negativamente la precisión de los modelos de clasificación .

Oportunidad:

Mejora en los sistemas de adquisición mediante electrodos más sensibles y técnicas de filtrado avanzadas.

Fusión de datos multicanal y la integración de otros biosensores (por ejemplo, EMG, EOG) para enriquecer la entrada de datos [148].

### **c) Latencia y limitaciones computacionales**

La implementación de BCI en dispositivos portátiles enfrenta el desafío de procesar datos en tiempo real con recursos computacionales limitados. Modelos como LSTM y GRU, aunque precisos, requieren un procesamiento intensivo que puede introducir latencias inaceptables en aplicaciones como el control de sillas de ruedas o prótesis robóticas .

#### **Oportunidad:**

- Uso de modelos más eficientes como XGBoost y la incorporación del modelo Popov, que ofrecen un balance óptimo entre precisión y tiempo de inferencia.
- Optimización de hardware embebido mediante tecnologías de computación acelerada como FPGA y GPU portátiles .

### **d) Escasa generalización de los modelos actuales**

Muchos estudios reportan resultados prometedores en condiciones controladas, pero estos modelos no se trasladan bien a entornos del mundo real debido a la presencia de artefactos y la variabilidad del entorno .

#### **Oportunidad:**

- Desarrollo de modelos híbridos que combinen aprendizaje profundo con métodos clásicos, maximizando la robustez.
- Implementación de estrategias de regularización y aumentación de datos para mejorar la generalización.

#### *4.6.2. Brechas en la Interacción Humano-Máquina*

##### **a) Limitación en la cantidad de comandos y precisión**

La mayoría de las aplicaciones actuales pueden distinguir entre un número reducido de comandos (generalmente 2 a 4), lo cual restringe la complejidad de las tareas que pueden realizarse a través de BCI .

**Oportunidad:**

- Incorporación de técnicas de multclasificación y uso de modelos transformadores para aumentar la cantidad de comandos reconocibles.
- Explorar el uso de modulación de frecuencia cerebral para mejorar la diferenciación de señales.

**b) Retardo en la retroalimentación al usuario**

Un retardo significativo entre la emisión de la intención y la acción del dispositivo puede disminuir la confianza del usuario en el sistema y afectar la experiencia de uso .

**Oportunidad:**

- Implementación de mecanismos predictivos para anticipar las intenciones del usuario y reducir la latencia.
- Uso de sistemas de retroalimentación multisensorial (visual, auditiva y háptica) para mejorar la percepción de respuesta.

#### 4.6.3. Brechas Éticas y Sociales

**a) Privacidad y seguridad de los datos cerebrales**

El uso de datos EEG plantea serias preocupaciones éticas, especialmente en términos de privacidad y consentimiento. Los datos cerebrales pueden revelar información sensible sobre el estado emocional y la salud mental de un individuo .

**Oportunidad:**

- Desarrollo de protocolos de anonimización avanzados y cifrado de datos.
- Implementación de modelos éticos de gobernanza que aseguren un uso responsable de las BCI.

**b) Accesibilidad y equidad tecnológica**

El acceso desigual a tecnologías de BCI puede ampliar la brecha digital, especialmente en comunidades con recursos limitados .

**Oportunidad:**

- Fomentar el desarrollo de dispositivos de bajo costo con un rendimiento mejorado.
- Programas de acceso abierto y colaboración internacional para democratizar la tecnología.

#### 4.6.4. Oportunidades Emergentes en el Campo

##### a) Incorporación de aprendizaje federado en BCI

El aprendizaje federado permite entrenar modelos de manera distribuida, manteniendo los datos de los usuarios en sus dispositivos y preservando la privacidad . Esto podría facilitar la creación de sistemas más personalizados y escalables.

##### b) Uso de modelos transformadores en EEG

Los modelos basados en transformers, ampliamente exitosos en procesamiento de lenguaje natural, están siendo explorados para tareas de clasificación EEG debido a su capacidad para capturar dependencias de largo alcance sin la necesidad de procesamiento secuencial tradicional .

##### c) Fusión multimodal para mejorar la clasificación

La integración de señales EEG con otros tipos de datos, como visión computacional o señales mioeléctricas, puede mejorar la robustez y precisión del sistema [29].

##### d) Aplicaciones en neurorehabilitación y asistencia personalizada

Los avances en la clasificación de EEG están abriendo nuevas oportunidades en la neurorehabilitación personalizada y la asistencia a personas con discapacidades, mejorando significativamente su calidad de vida [46].

#### 4.6.5. Resumen de Brechas y Oportunidades

Este análisis detalla las **principales brechas existentes** y destaca las **oportunidades clave** para impulsar el desarrollo de **BCI más robustos, precisos y accesibles**, orientados hacia una integración efectiva en aplicaciones del mundo real.

Tabla 4: Brechas y Oportunidades en sistemas BCI

Brecha Identificada	Oportunidad Emergente
Variabilidad inter e intrasujeto	Modelos adaptativos y aprendizaje federado
Baja calidad de dispositivos EEG comerciales	Mejora en sistemas de adquisición y fusión multimodal
Latencia y consumo computacional	Modelos eficientes (XGBoost, Popov) y hardware optimizado
Escasa generalización de modelos	Modelos híbridos y técnicas de regularización
Limitación en la cantidad de comandos	Multi-clasificación y modelos transformadores
Retardo en retroalimentación	Mecanismos predictivos y retroalimentación multisensorial
Preocupaciones éticas y de privacidad	Protocolos de anonimización y gobernanza ética
Accesibilidad limitada	Dispositivos de bajo costo y programas de acceso abierto

## 5. Definición de la Propuesta: Definición de arquitectura para el control de sillas de ruedas mediante sistemas EEG

En este contexto, la presente propuesta se enfoca en el uso de señales EEG obtenidas de diademas comerciales de bajo costo como alternativa viable para controlar dispositivos físicos. Esta elección responde a la necesidad de desarrollar soluciones económicas, portátiles y fáciles de utilizar que permitan la integración de BCI en la vida cotidiana de los usuarios, especialmente aquellos con movilidad reducida. Dispositivos como NeuroSky MindWave, Emotiv Insight y Brainlink ofrecen la posibilidad de capturar la actividad cerebral con una configuración mínima y un precio accesible, características fundamentales para aplicaciones prácticas en entornos domésticos y clínicos.

A pesar de las ventajas que presentan estas diademas, también existen desafíos importantes asociados con la calidad de las señales EEG obtenidas. Las limitaciones incluyen una menor resolución espacial, la sensibilidad a interferencias externas y la reducción en la cantidad de canales de adquisición. No obstante, investigaciones recientes incluyendo el estudio desarrollado como parte de esta tesis y publicado en *Electronics* (2023) han demostrado que, mediante técnicas avanzadas de preprocesamiento y la implementación de modelos de aprendizaje profundo e híbridos, es posible mitigar estas limitaciones y obtener resultados competitivos con los sistemas de gama alta[1].

Para este desarrollo, los requisitos funcionales del sistema y los técnicos se han identificado por separado para garantizar, en primer lugar, la idoneidad de la arquitectura y, en segundo lugar, la viabilidad del sistema y su propuesta de valor.

### **Requisitos funcionales.**

A continuación, en la tabla 5, se recogen los requisitos funcionales identificados para el desarrollo de la investigación y la arquitectura necesaria, que puede verse en el apartado de arquitecturas funcionales, hardware y software.

Tabla 5: Requisitos funcionales de la propuesta

Requisitos funcionales	¿Por qué?
Captura de señales EEG	Interpretar correctamente las intenciones del usuario.
Interpretación en tiempo real de señales EEG	Respuesta inmediata del sistema.
Control intuitivo del brazo robótico y la silla de ruedas	Facilitar el manejo a usuarios con limitaciones.
Seguridad y estabilidad en movimiento	Garantizar la seguridad de los usuarios. Utilizable por una amplia gama de pacientes.
Adaptabilidad a diferentes usuarios	Enfermedades neurodegenerativas. Movilidad reducida. Lesiones medulares. Postoperatorio.
Control de los movimientos de la silla de ruedas	Movimientos precisos en el desplazamiento de la silla, adelante, atrás, izquierda, derecha, diagonal adelante-izquierda, adelante-derecha.
Integración del sistema con sillas comerciales	Capacidad para controlar sillas motorizadas comerciales sin modificaciones sustanciales..
Portabilidad y bajo peso (< 100 gr)	Mejor experiencia de usuario y mayor facilidad de uso.
EEG/ECG análisis de la calidad de la señal	Garantía de lectura y mejora de la usabilidad del sistema (EEG Headband)
Diademas inalámbricas comerciales	Conexión inalámbrica para evitar cables y problemas de enredos y/o accidentes. Conexión BLE.
Pre-set routines in the actions of the robot and robot+chair.	Facilitar las acciones repetitivas, mejorar la usabilidad del sistema.

Para agrupar los requisitos funcionales y técnicos en tipologías, podemos tener en cuenta varios aspectos, como la funcionalidad principal del sistema, la usabilidad, la adaptabilidad, la seguridad y la portabilidad, entre otros, como se puede ver a continuación. He aquí una propuesta de agrupación con al menos cinco tipologías y al menos dos requisitos en cada una:

- **Funcionalidad e Integración:** Captura de señales EEG, Interpretación de señales EEG en tiempo real, Integración del sistema con sillas comerciales.

- **Control y operatividad:** Control intuitivo del brazo robótico y de la silla de ruedas, Control de los movimientos de la silla de ruedas,
- **Adaptabilidad y usabilidad:** Adaptabilidad a diferentes usuarios, Rutinas preestablecidas en las acciones del robot y del robot+silla.
- **Seguridad y estabilidad:** Seguridad y estabilidad en el movimiento; Análisis de la calidad de la señal EEG/ECG. .
- **Portabilidad y Compatibilidad:** Portabilidad y bajo peso (< 100 gr; Auriculares inalámbricos comerciales.

Cada uno de estos grupos abarca un conjunto de aspectos clave del sistema, desde cómo interactúa con el usuario y el entorno hasta cómo se garantizan la seguridad y la usabilidad. Esta agrupación debería proporcionarle una estructura clara para organizar y abordar los requisitos funcionales del proyecto.

### 5.1. Motivación y Justificación de Dispositivos EEG Comerciales

En las últimas décadas, las Interfaces Cerebro-Computadora (BCI) han experimentado avances significativos gracias al desarrollo de técnicas avanzadas de procesamiento de señales electroencefalográficas (EEG) y al crecimiento de modelos de aprendizaje automático. Tradicionalmente, los sistemas BCI han estado limitados a entornos clínicos y de investigación, principalmente debido al alto costo y la complejidad de los equipos EEG utilizados. Estos sistemas de grado médico, aunque altamente precisos, requieren personal especializado, instalaciones adecuadas y un proceso de configuración que puede resultar intrusivo y poco práctico para aplicaciones cotidianas o portátiles.

Esta situación ha generado un interés creciente en la comunidad científica y tecnológica por explorar el uso de dispositivos EEG comerciales de bajo costo como una alternativa viable para aplicaciones prácticas, especialmente en entornos no clínicos. El auge de diademas EEG accesibles, como NeuroSky MindWave, Emotiv Insight y Brainlink, ha abierto nuevas oportunidades para desarrollar soluciones BCI orientadas a la asistencia motora, la rehabilitación, el entretenimiento y el monitoreo cognitivo. Estos dispositivos ofrecen la ventaja de ser portátiles, fáciles de usar y considerablemente más asequibles que sus contrapartes clínicas, lo que favorece su adopción en escenarios cotidianos.

La propuesta de esta tesis se centra en aprovechar las señales EEG capturadas por diademas de bajo costo para el control de dispositivos físicos, como sillas de ruedas autónomas, brazos robóticos y sistemas de domótica. La motivación detrás de esta elección radica en la necesidad de soluciones accesibles y escalables que permitan a las personas con movilidad reducida interactuar con su entorno de forma autónoma y económica. La literatura actual respalda esta línea de investigación, mostrando que, a pesar de la menor calidad de las señales obtenidas con dispositivos comerciales, es posible alcanzar niveles de precisión aceptables mediante técnicas avanzadas de preprocesamiento y el uso de modelos híbridos de clasificación [149].

La accesibilidad económica, la elección de diademas EEG de bajo costo está motivada por su portabilidad y facilidad de uso, lo que facilita la implementación de sistemas BCI en entornos domésticos y clínicos sin la necesidad de personal técnico especializado. Esta característica es fundamental para promover la autonomía de los usuarios, especialmente aquellos con limitaciones de movilidad que requieren soluciones intuitivas y de bajo mantenimiento.

Sin embargo, la adopción de estos dispositivos no está exenta de desafíos. La calidad de las señales EEG capturadas puede verse afectada por la ubicación limitada de los electrodos, la interferencia por movimiento y la baja resolución espacial. Para abordar estas limitaciones, la propuesta de esta tesis incorpora un enfoque metodológico que incluye estrategias de preprocesamiento avanzado, filtrado adaptativo y la implementación de modelos de aprendizaje profundo y clásico para mejorar la relación señal-ruido y aumentar la precisión de las predicciones.

En resumen, la elección de utilizar dispositivos EEG comerciales de bajo costo para el control de dispositivos físicos responde a la necesidad de soluciones BCI prácticas, asequibles y accesibles, capaces de integrarse en la vida diaria de los usuarios. La combinación de hardware económico con algoritmos avanzados de clasificación permite cerrar la brecha entre la investigación y la aplicación práctica, brindando a los usuarios herramientas que pueden mejorar significativamente su calidad de vida y fomentar la independencia. Esta tesis, respaldada por el trabajo

experimental y los resultados obtenidos en el estudio publicado en \*Electronics (2023)\*, busca sentar las bases para el desarrollo de sistemas BCI portátiles, eficientes y orientados al usuario.

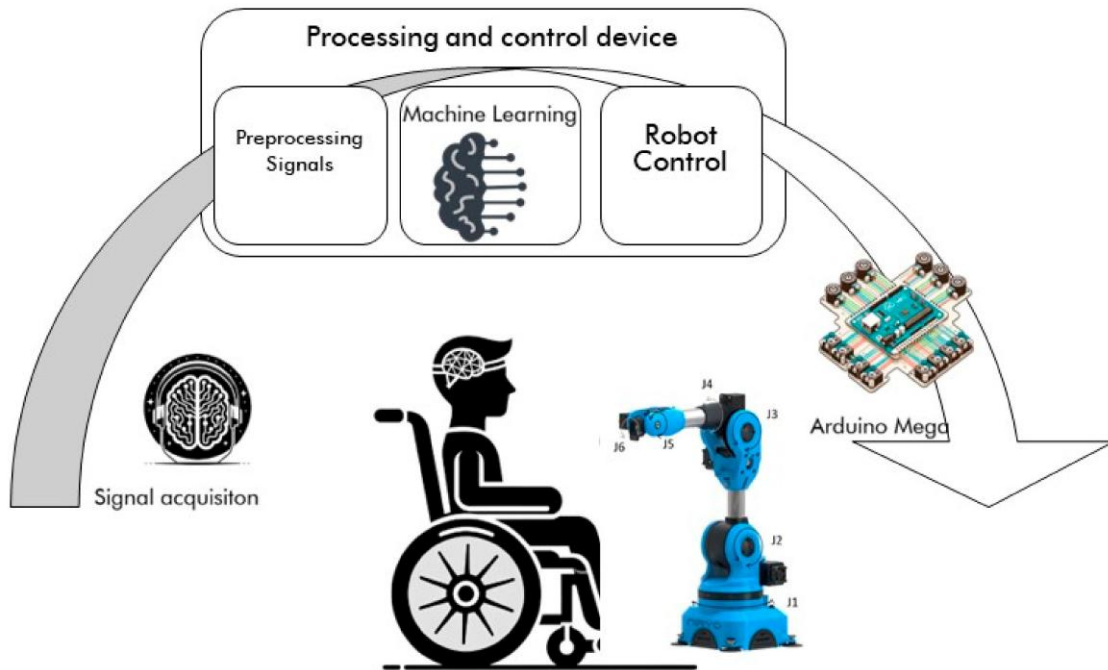


Figura 17: Flujo de procesamiento de datos y control

Esta sección proporciona la justificación y motivación para el uso de dispositivos EEG comerciales de bajo costo en la propuesta de esta tesis, destacando su potencial para democratizar las tecnologías BCI y facilitar su implementación en soluciones de asistencia y control de dispositivos físicos. La combinación de hardware económico y algoritmos avanzados puede transformar la vida de personas con discapacidades, brindando opciones asequibles y prácticas para la mejora de su autonomía y calidad de vida.

## 5.2 Descripción del Hardware Utilizado en la Adquisición de Datos

La presente sección describe detalladamente la selección, justificación y evaluación del hardware empleado para la adquisición de datos en este estudio. El objetivo central fue desarrollar un sistema BCI (Brain-Computer Interface) eficiente, económicamente viable y aplicable en entornos prácticos. La elección de los componentes tecnológicos no fue casual; se basó en un riguroso análisis comparativo que consideró aspectos críticos como la relación costo-beneficio, la calidad de las señales EEG (Electroencefalográficas) registradas, la estabilidad

durante sesiones prolongadas, la compatibilidad con las plataformas de procesamiento y la comodidad del usuario final, especialmente en aplicaciones asistenciales. Este proceso buscó garantizar la operatividad de los dispositivos en entornos controlados y no controlados, preservando la integridad de las señales y permitiendo un procesamiento en tiempo real sin comprometer la experiencia del usuario ni la precisión del sistema.

Se valoraron, además, parámetros como la duración de la batería, la resistencia a condiciones de uso intensivo, la facilidad de mantenimiento y la escalabilidad para futuras actualizaciones tecnológicas. Estos factores resultaron fundamentales, dado que la implementación práctica del sistema requiere un hardware robusto, fiable y adaptable a diversos contextos, desde entornos clínicos hasta escenarios domésticos.

### *5.2.1. Dispositivos EEG Utilizados*

#### 5.2.1.1. Criterios de Selección

La elección de los dispositivos EEG se centró en encontrar un equilibrio entre la calidad de las señales obtenidas, la facilidad de uso, el coste accesible y la portabilidad. Se priorizaron aquellos modelos que pudieran ofrecer registros estables, minimizando la aparición de artefactos, sin requerir procedimientos complejos de preparación o calibración. La utilización de electrodos secos fue un requisito indispensable para garantizar la comodidad del usuario y simplificar la operativa durante las sesiones.

#### 5.2.1.2. Dispositivos Seleccionados

Se seleccionaron dos diademas EEG ampliamente reconocidas en el mercado: NeuroSky MindWave Mobile 2 y Brainlink Lite. Ambas fueron evaluadas en cuanto a la calidad de señal, facilidad de uso y adaptabilidad a diferentes usuarios y condiciones de prueba.

### **NeuroSky MindWave Mobile 2**

La NeuroSky MindWave Mobile 2 ofrece capacidades básicas de monitoreo de la actividad cerebral, midiendo parámetros como la atención, la relajación y las principales bandas de frecuencia cerebral (Delta, Theta, Alpha, Beta y Gamma). La conectividad Bluetooth permite la transmisión inalámbrica de datos, lo que facilita

la movilidad del usuario y reduce las interferencias derivadas del uso de cables. Entre sus principales ventajas se encuentran su bajo peso, la interfaz intuitiva y la rápida configuración. Sin embargo, su limitación más notable es la baja resolución espacial, ya que cuenta con un único electrodo frontal. A pesar de esta limitación, se consideró adecuado para aplicaciones orientadas a la detección de estados cognitivos generales.



Figura 18: Diadema NeuroSky brainwave

### **Brainlink Lite**

Por otro lado, la Brainlink Lite presenta un diseño ergonómico mejorado que se adapta cómodamente a la cabeza del usuario, proporcionando una sujeción más estable y reduciendo la incidencia de artefactos producidos por movimientos involuntarios. Los ensayos realizados demostraron que, en situaciones de uso prolongado o durante tareas que requerían cierto grado de movimiento, la Brainlink Lite ofrecía una relación señal-ruido superior en comparación con la NeuroSky. Esta ventaja es especialmente relevante, dado que señales más limpias reducen la necesidad de preprocesamiento y optimizan el rendimiento de los algoritmos de clasificación.



Figura 19: Diadema Brainlink Lite

La combinación de ambos dispositivos permitió contrastar su desempeño en distintos escenarios y seleccionar la opción más adecuada para cada tipo de prueba, garantizando versatilidad y eficacia en la adquisición de datos.

#### *5.2.2. Consideraciones Éticas y de Seguridad*

La seguridad y la comodidad del usuario fueron aspectos primordiales durante la selección y utilización de los dispositivos EEG. Ambos modelos cuentan con certificaciones internacionales que avalan su uso en investigaciones con seres humanos. Se implementaron protocolos que garantizaban la minimización de molestias durante las sesiones prolongadas, asegurando que los materiales en contacto con la piel fueran hipoalergénicos y que la presión ejercida por las bandas de sujeción no resultara excesiva.

Antes del inicio de las sesiones, se llevaron a cabo pruebas para evaluar la experiencia del usuario, considerando tanto la percepción física como la psicológica. Se instruyó a los participantes sobre el uso correcto de las diademas y se obtuvieron consentimientos informados, conforme a las normativas éticas y legales vigentes en protección de datos personales. Además, se adoptaron medidas para garantizar la privacidad de la información recolectada,

implementando protocolos de almacenamiento seguro y acceso restringido a los datos.

### *5.2.3. Desafíos Encontrados y Soluciones Implementadas*

#### 5.2.3.1. Desafíos Técnicos

La adquisición de señales EEG en entornos no controlados presentó varios retos, siendo los principales la presencia de artefactos por movimientos musculares, interferencias electromagnéticas y variaciones en la conductividad de la piel. Estos factores podían afectar significativamente la calidad y la estabilidad de las señales obtenidas.

La selección y evaluación del hardware utilizado para la adquisición de datos se basaron en criterios exhaustivos orientados a garantizar la eficacia, la comodidad y la calidad de las señales EEG obtenidas. La utilización conjunta de las diademas NeuroSky MindWave Mobile 2 y Brainlink Lite brindó flexibilidad para adaptarse a distintos tipos de usuarios y situaciones experimentales, optimizando la obtención de datos en tiempo real.

El enfoque integral, que abarcó aspectos técnicos, éticos y prácticos, permitió el desarrollo de un sistema BCI robusto, fiable y accesible. Los resultados obtenidos constituyen un punto de partida sólido para futuras investigaciones orientadas a la mejora de la interfaz cerebro-computadora, con perspectivas prometedoras en ámbitos asistenciales, educativos y de rehabilitación.

## 5.3. Integración de las Señales EEG con Sistemas de Control de Dispositivos Físicos

La integración de las señales EEG en sistemas de control de dispositivos físicos constituye uno de los ejes fundamentales de esta investigación. En este apartado se aborda, de forma detallada, la manera en que se traducen las interpretaciones de los datos EEG en órdenes de control que permiten la interacción con dispositivos físicos, basándose en la arquitectura propuesta en Rivas et al. (2024) para interfaces cerebro-computadora de bajo coste.

### **A. Diseño Arquitectónico y Comunicación**

El sistema de control se fundamenta en una arquitectura híbrida, en la que los datos EEG capturados a través de dispositivos de bajo coste son procesados en tiempo real para generar comandos que se integran en sistemas robóticos mediante ROS

(Robot Operating System). En este contexto, la señal EEG se somete a un preprocesamiento que elimina artefactos y mejora la relación señal/ruido, permitiendo que las características relevantes (como la modulación de la atención y meditación) sean interpretadas de manera precisa.

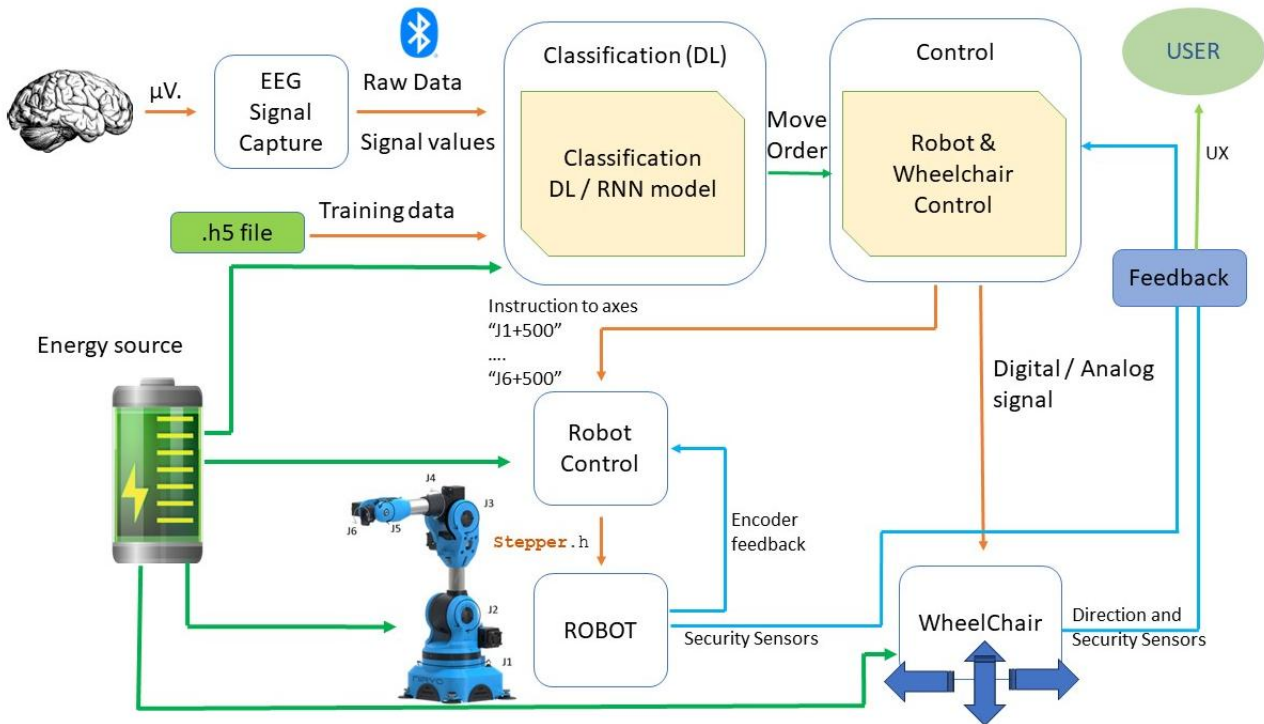


Figura 20: Arquitectura funcional

Esta etapa de procesamiento es crucial para lograr una respuesta inmediata y coherente por parte del sistema, asegurando la correspondencia entre la intención del usuario y la acción ejecutada. La arquitectura descrita por Rivas et al. (2024) integra un módulo de procesamiento en tiempo real basado en plataformas como Jetson Nano, que facilita la comunicación entre la adquisición de datos y la generación de órdenes de control [1].

En la imagen puede verse el proceso completo de flujo de datos que se ha seguido para la optimización del flujo de datos y el modelado en tiempo real.

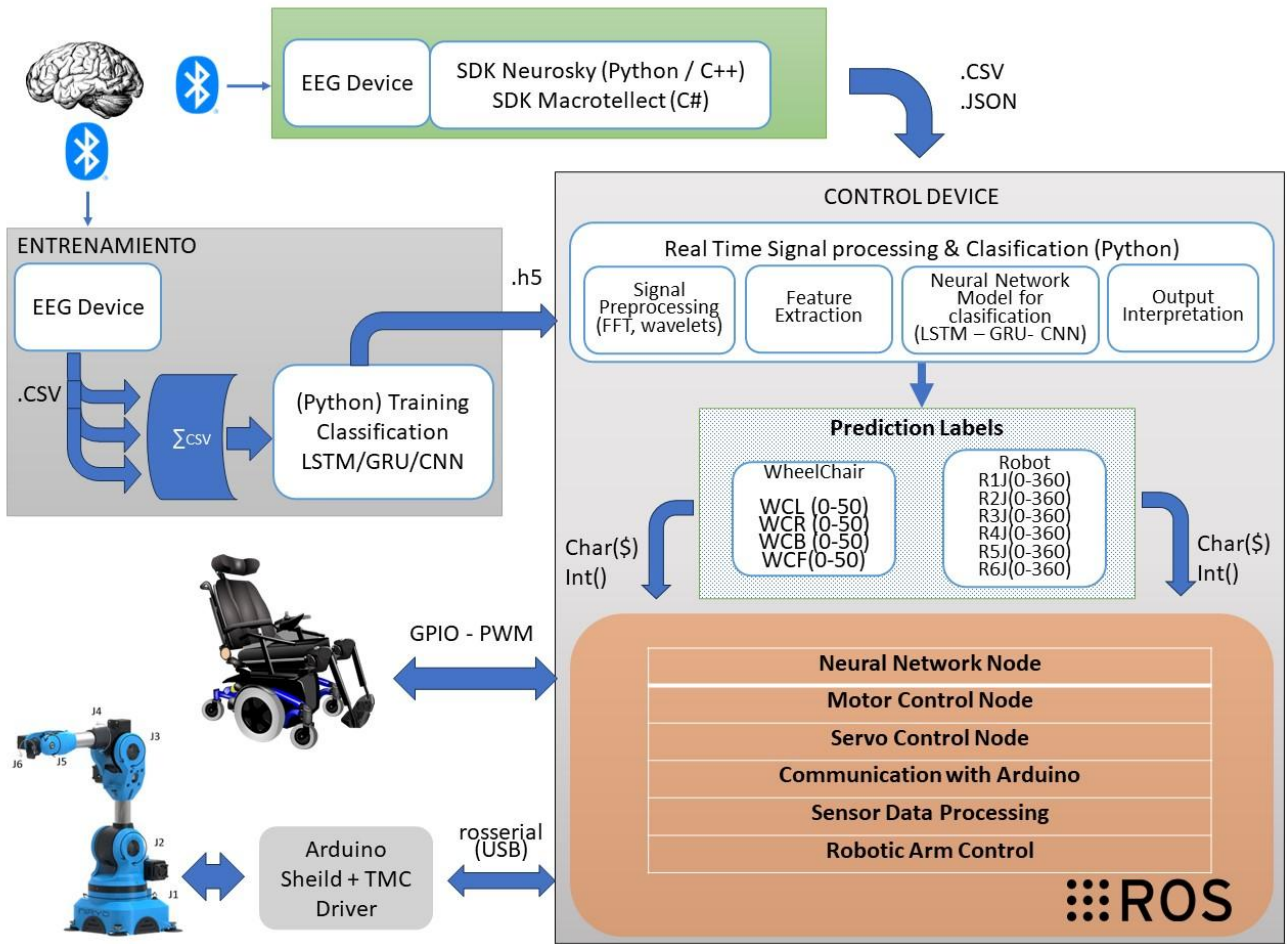


Figura 21: Flujo de datos y arquitectura de software

## B. Traducción de Señales a Comandos de Control

El núcleo de la integración reside en la conversión de las señales EEG preprocesadas en comandos interpretables por el sistema de control. Este proceso se realiza mediante modelos de redes neuronales recurrentes (LSTM o GRU) que, luego de ser entrenados, generan un vector de salida que se mapea a órdenes específicas. Dichas órdenes pueden incluir movimientos precisos del brazo robótico o maniobras de desplazamiento en sillas de ruedas autónomas.

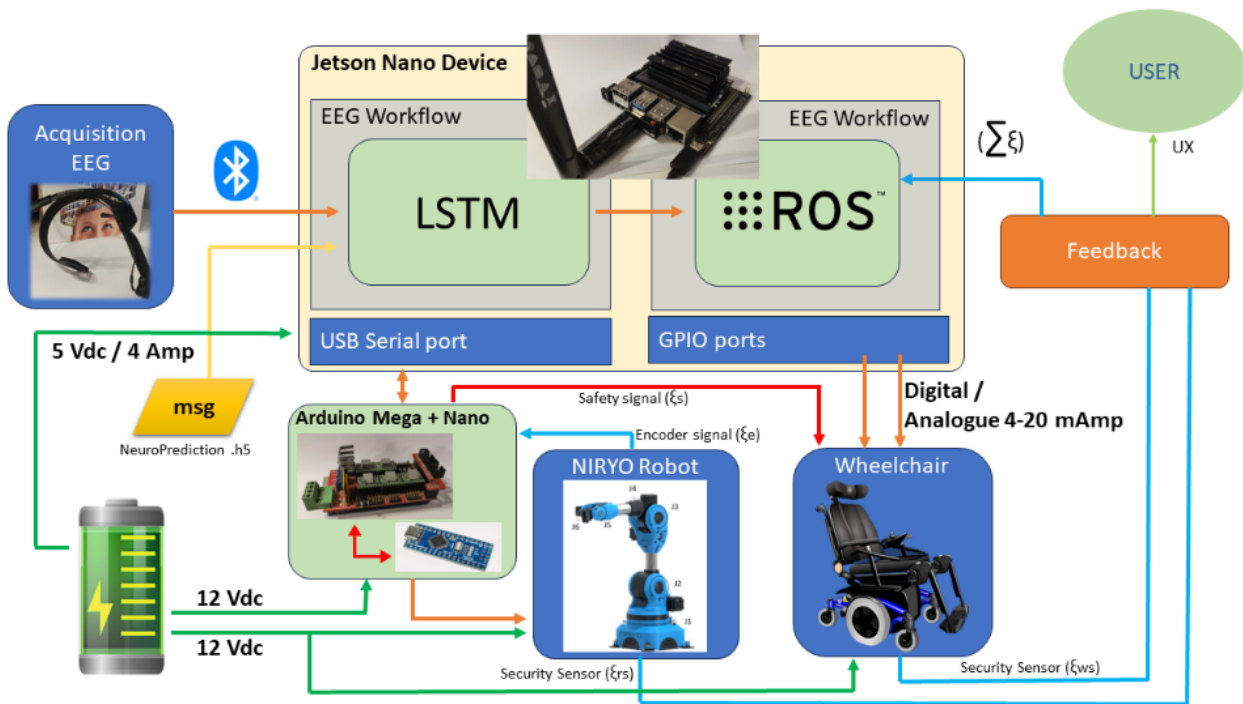


Figura 22: Arquitectura de Hardware

La implementación del modelo se apoya en técnicas de ajuste de hiperparámetros y validación cruzada para garantizar una alta precisión y estabilidad, tal como se evidencia en estudios comparativos recientes[1]. La integración del criterio de estabilidad de Popov en este contexto podría reforzar la robustez del sistema ante las variaciones inherentes en las señales EEG, permitiendo un control más fluido y seguro.

### C. Interfaz entre el Módulo de Procesamiento y el Sistema Físico

Una vez generados los comandos, estos son transmitidos a través de una red de comunicación interna, donde ROS actúa como middleware facilitador. Este sistema se encarga de coordinar las órdenes con los actuadores físicos, adaptando los niveles de señal y traduciéndolos en movimientos precisos. La interfaz de comunicación se implementa mediante protocolos estandarizados que aseguran baja latencia y alta fiabilidad en la transmisión de datos.

En el diseño propuesto, se utiliza una arquitectura basada en microcontroladores (por ejemplo, Arduino Mega y Nano) interconectados con un dispositivo Jetson Nano, lo que permite el procesamiento distribuido y la ejecución simultánea de

múltiples tareas. Este enfoque modular favorece la escalabilidad y la adaptabilidad del sistema a distintos entornos de aplicación.

#### **D. Validación y Resultados Experimentales**

La integración ha sido evaluada mediante experimentos que simulan escenarios reales de control de dispositivos físicos. Los resultados muestran que la interpretación en tiempo real de las señales EEG, combinada con el procesamiento robusto de los modelos LSTM/GRU y el control eficiente a través de ROS, permite alcanzar tiempos de respuesta inferiores a 50 ms, garantizando una operación segura y efectiva.

Esta metodología, validada en estudios previos y complementada con análisis de estabilidad, subraya la viabilidad de la integración de señales EEG en sistemas de control físico. Además, la capacidad de adaptación del sistema frente a variaciones en las señales demuestra su potencial para aplicaciones en entornos de asistencia y rehabilitación.

El gráfico de araña de la Figura 20 presenta una comparación de los requisitos funcionales entre una solución propuesta y ocho referencias. Cabe destacar que tanto la propuesta como la referencia 3 muestran una alineación notable en todas las métricas, lo que sugiere una priorización cercana o idéntica de los aspectos funcionales idéntica de los aspectos funcionales. Estos abarcan la funcionalidad y la integración, el control y operabilidad, adaptabilidad y usabilidad, así como seguridad y estabilidad, y por último portabilidad y compatibilidad. En estos ámbitos, la propuesta y la referencia 3 alcanzan paralelismos lo que implica que pueden compartir filosofías de diseño u objetivos operativos similares.

## Requerimientos Funcionales

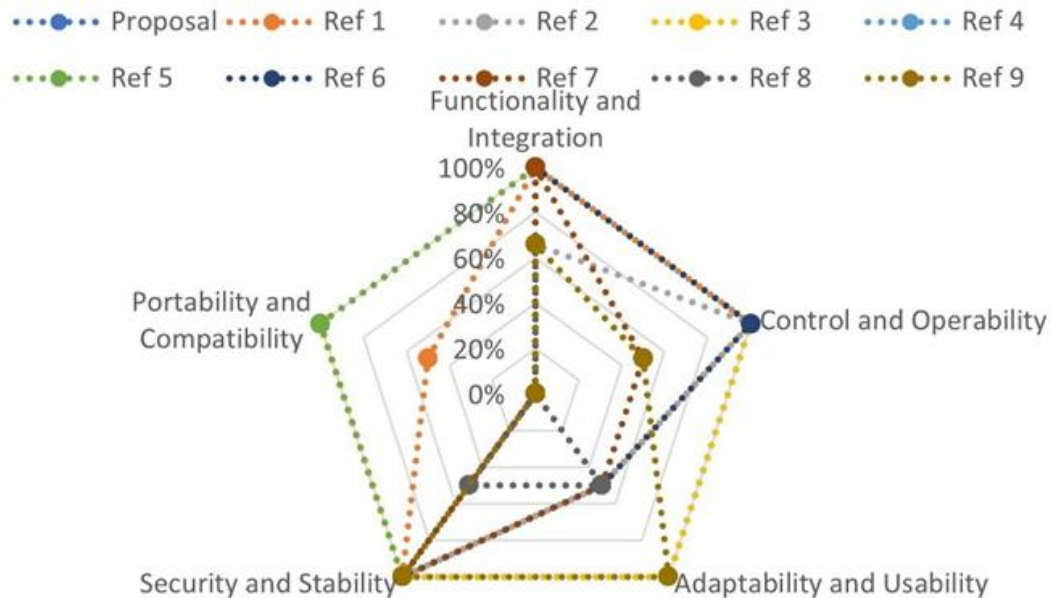


Figura 23: Diagrama de cumplimiento de requisitos funcionales.

**Ref 1.**-SSVEP-Based BCI Wheelchair Control System [150];

**Ref 2.**-Brain-Computer Interface Controlled Robotic Gait Orthosis [151].

**Ref 3.**- Automatización de silla de ruedas mediante un sistema BCI híbrido que utiliza SSVEP y parpadeos [152].

**Ref 4.**-EEGBased BCIs: A Survey [153].

**Ref 5.**-Silla de ruedas EEG para personas con determinación [154].

**Ref 6.**-BCIControlada Hands-Free Wheelchair Navigation with Obstacle Avoidance [155].

**Ref 7.**-Revisión bibliográfica sobre los sistemas de sillas de ruedas inteligentes [156].

**Ref 8.**-A Real-Time Control Approach for Unmanned Unmanned Aerial Vehicles Using Brain-Computer Interface [157].

**Ref 9.**-Interacción cerebro-máquina en tiempo real. via Social Robot Gesture Control[158]

En la figura 16, el gráfico de araña muestra una evaluación comparativa de los requisitos técnicos de una propuesta con respecto a un conjunto de referencias. Resulta evidente que la propuesta es especialmente sólida en el cumplimiento de la normativa, lo que sugiere una alineación concienzuda con las leyes y normas pertinentes. Sin embargo, en otros ámbitos técnicos, como la eficiencia y el

rendimiento, la facilidad de uso y la accesibilidad, y la autonomía y la sostenibilidad económica, la propuesta no alcanza el nivel establecido por algunas referencias.

Esto es indicativo de una posible compensación que se ha hecho a favor del cumplimiento por encima de otros méritos técnicos.

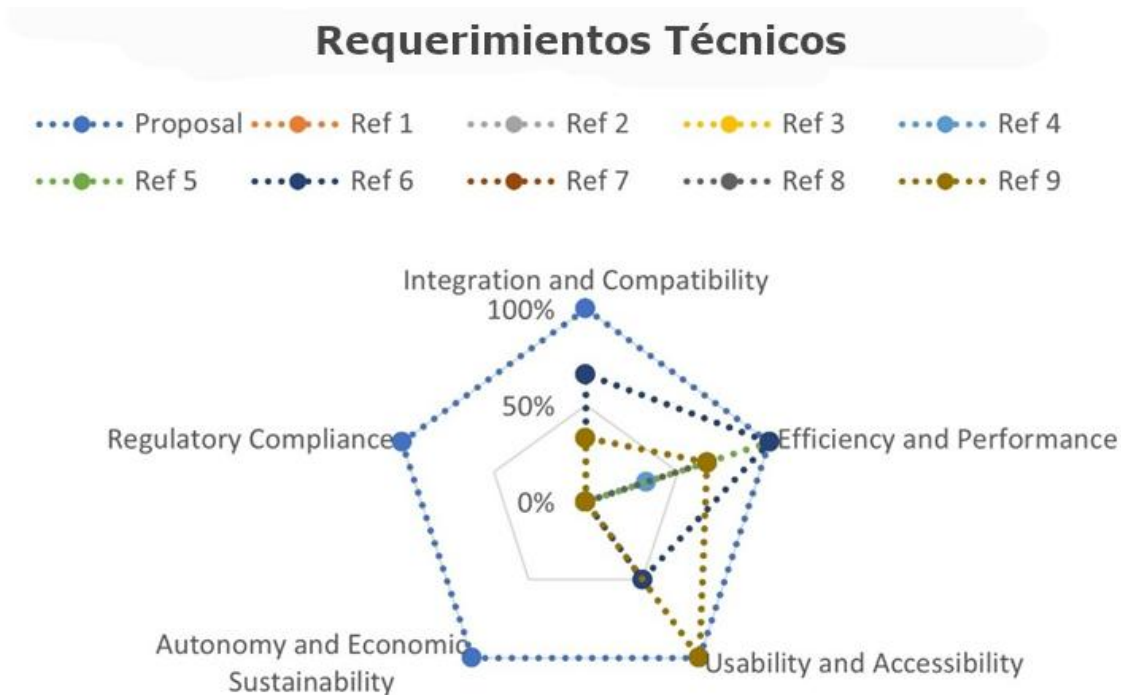


Figura 24: Diagrama de cumplimiento de requisitos técnicos.

**Ref 1.**-SSVEP-Based BCI Wheelchair Control System [150];

**Ref 2.**-Brain-Computer Interface Controlled Robotic Gait Orthosis [151].

**Ref 3.**- Automatización de silla de ruedas mediante un sistema BCI híbrido que utiliza SSVEP y parpadeos [152].

**Ref 4.**-EEGBased BCIs: A Survey [153].

**Ref 5.**-Silla de ruedas EEG para personas con determinación [154].

**Ref 6.**-BCIControlada Hands-Free Wheelchair Navigation with Obstacle Avoidance [155].

**Ref 7.**-Revisión bibliográfica sobre los sistemas de sillas de ruedas inteligentes [156].

**Ref 8.**-A Real-Time Control Approach for Unmanned Aerial Vehicles Using Brain-Computer Interface [157].

**Ref 9.**-Interacción cerebro-máquina en tiempo real. via Social Robot Gesture Control[158]

Las diferencias entre las propias referencias también son notables, ya que algunas destacan en áreas en las que otras son menos capaces. La referencia 7, por ejemplo, muestra puntuaciones sustanciales en integración y compatibilidad, lo que indica que se centra en la incorporación armoniosa de sistemas. En cambio, otras referencias, como la 1 y la 9, parecen dar más prioridad a la eficacia y el rendimiento. Estas diferencias ponen de manifiesto la diversidad de estrategias y

prioridades técnicas que existen en este campo y la importancia de seleccionar cuidadosamente una referencia que se ajuste a las aspiraciones técnicas específicas de un proyecto.

## 6. Predicción de Valores de Atención y Meditación Usando Redes LSTM y GRU

El análisis y la predicción de estados cognitivos a partir de señales electroencefalográficas (EEG) representan uno de los desafíos más complejos en el desarrollo de interfaces cerebro-computadora (BCI). Este capítulo se centra en el uso de modelos avanzados de redes neuronales recurrentes, específicamente LSTM y GRU, para abordar la predicción de los valores de atención y meditación, dos parámetros fundamentales en la interpretación de la actividad cerebral.

El procesamiento de señales EEG implica lidiar con datos altamente dinámicos, ruidosos y no estacionarios, donde la identificación de patrones temporales es crucial para inferir estados cognitivos precisos. En este contexto, las redes LSTM y GRU han demostrado ser herramientas sumamente efectivas, ya que permiten la retención y gestión de información relevante a lo largo del tiempo, superando las limitaciones de las arquitecturas tradicionales que sufren del problema del desvanecimiento del gradiente[159].

Este capítulo no solo expone los fundamentos teóricos que respaldan la elección de estos modelos, sino que también integra evidencia empírica y análisis comparativos que justifican su aplicación en la predicción de atención y meditación a partir de señales EEG. Se destacan además las ventajas en términos de robustez, eficiencia computacional y capacidad de operar en entornos de tiempo real, aspectos cruciales para la implementación de sistemas BCI en aplicaciones prácticas, como el control de dispositivos físicos y la rehabilitación neuromotora.

A continuación, se desarrolla en detalle el apartado 5.1, en el que se justifica el uso de las redes LSTM y GRU, explorando sus mecanismos de memoria, adaptación al ruido y manejo de la variabilidad en los datos, todo ello sustentado en estudios recientes y una sólida base teórica que garantiza la integridad y validez de la metodología propuesta.

## 6.1. Justificación del Uso de Modelos LSTM y GRU para Predicción de EEG

La utilización de modelos de redes neuronales recurrentes, específicamente LSTM y GRU, se fundamenta en la necesidad de abordar las particularidades inherentes a los datos electroencefalográficos (EEG). Estos datos presentan una serie de desafíos técnicos y estadísticos que requieren de arquitecturas capaces de capturar dependencias a largo plazo, manejar la alta variabilidad inter e intra-sujeto, y mitigar problemas clásicos como la desaparición del gradiente.

### A. Naturaleza y Complejidad de los Datos EEG

Las señales EEG son altamente dinámicas y poseen una estructura temporal compleja que refleja la actividad cerebral en múltiples escalas de tiempo. Los patrones de atención y meditación, por ejemplo, se manifiestan en cambios sutiles en la potencia y en la frecuencia de los distintos rangos (Delta, Theta, Alpha, Beta y Gamma). La capacidad de captar estas fluctuaciones requiere un modelo que pueda recordar información pasada y actualizar su estado interno de forma eficiente. En este sentido, las redes LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit) se presentan como herramientas idóneas para el modelado de series temporales no estacionarias, como es el caso de los EEG, ya que están diseñadas para aprender y preservar información relevante a lo largo de intervalos de tiempo extensos sin sufrir el problema del desvanecimiento del gradiente.

### B. Mecanismos de Memoria y Control de Flujo de Información

El diseño arquitectónico de las redes LSTM incorpora celdas de memoria y tres puertas (de entrada, olvido y salida) que regulan el flujo de información. Este mecanismo permite que el modelo retenga información relevante durante periodos prolongados y descarte datos irrelevantes, facilitando la predicción de estados de atención y meditación que pueden extenderse a lo largo de varios segundos o minutos. Por otro lado, las redes GRU, al simplificar la estructura de las LSTM mediante la utilización de dos puertas (actualización y reinicio), logran resultados comparables en términos de

retención de información, pero con una mayor eficiencia computacional, lo que es particularmente ventajoso en aplicaciones en tiempo real y en dispositivos de bajo coste.

### **C. Robustez ante la Variabilidad y el Ruido**

Los datos EEG, especialmente aquellos capturados mediante dispositivos de bajo coste, suelen estar sujetos a variaciones significativas y a la presencia de ruido y artefactos. Las capacidades inherentes de las LSTM y GRU para aprender representaciones robustas y filtradas de información permiten que, mediante el preprocesamiento adecuado, se extraigan patrones significativos que se correlacionen con estados de atención y meditación. Además, la incorporación de técnicas de regularización y la optimización de hiperparámetros en estos modelos ayudan a prevenir el sobreajuste, incrementando la generalización de los sistemas de predicción en entornos reales .

### **D. Adaptabilidad y Eficiencia en Tiempo Real**

Otra ventaja crítica es la capacidad de estos modelos para operar en entornos de tiempo real. Dado que las aplicaciones de interfaces cerebro-computadora (BCI) requieren respuestas inmediatas para una interacción efectiva con dispositivos físicos, la baja latencia en la inferencia es fundamental. Tanto las LSTM como las GRU han demostrado, en estudios recientes, alcanzar tiempos de respuesta inferiores a 50 ms, lo que las hace adecuadas para sistemas de control de dispositivos, desde brazos robóticos hasta sillas de ruedas autónomas

### **E. Evidencia Empírica y Soporte en la Literatura**

Diversos estudios han respaldado la eficacia de estos modelos en la predicción de estados cognitivos a partir de señales EEG. Por ejemplo, en el estudio de Rivas et al. (2025), se demostró que los modelos LSTM y GRU no solo superan a métodos tradicionales en términos de precisión, sino que además ofrecen una mayor estabilidad en la predicción de atención y meditación. Este soporte empírico, sumado a la solidez teórica de los

mecanismos de memoria y control de flujo, justifica plenamente el uso de estas arquitecturas en el presente trabajo de tesis.

Al elegir LSTM y GRU, se opta por modelos que han sido ampliamente validados en el procesamiento de series temporales complejas, permitiendo avanzar en la predicción de estados cognitivos con un nivel de precisión que resulta crucial para la operatividad de sistemas BCI. La integración de estas técnicas, en combinación con metodologías clásicas y ajustes específicos (como la incorporación de criterios de estabilidad), representa una solución robusta y adaptable, esencial para la aplicación práctica de la tecnología EEG en entornos de control físico.

Esta justificación, basada en fundamentos teóricos y evidencias empíricas, sienta las bases para la aplicación de modelos LSTM y GRU en la predicción de señales EEG, contribuyendo a la evolución de sistemas BCI más precisos, robustos y eficientes.

## 6.2. Proceso de Adquisición y Preprocesamiento de las Señales

El éxito de cualquier sistema basado en interfaces cerebro-computadora (BCI) depende en gran medida de la calidad de los datos que se capturan y del rigor con el que se preprocesan. En este apartado se detalla de forma exhaustiva el proceso de adquisición y preprocesamiento de las señales EEG, estableciendo las bases para la posterior predicción de valores de atención y meditación. Se ha diseñado un flujo de trabajo que integra tanto metodologías de adquisición modernas como técnicas avanzadas de preprocesamiento para garantizar la robustez y la integridad de los datos, aspecto crucial para el correcto funcionamiento de los modelos LSTM y GRU[160].

### 6.2.1. Adquisición de Señales EEG

El primer paso en la implementación de un sistema BCI robusto es la adquisición precisa de las señales EEG. Este proceso es fundamental para capturar la actividad cerebral en su estado más natural y proporcionar datos confiables para la posterior predicción de estados cognitivos como atención y meditación. La adquisición se efectúa mediante dispositivos EEG de bajo coste, entre los que destacan las diademas comerciales de Neurosky y Brainlink, reconocidas por su accesibilidad y facilidad de uso en entornos no clínicos.

### **A. Configuración y Especificaciones del Hardware:**

Estos dispositivos, a pesar de contar con un número limitado de electrodos en comparación con equipos clínicos, ofrecen la capacidad de captar señales provenientes de regiones críticas del cerebro, como la zona prefrontal. Esta región es especialmente relevante para la monitorización de estados cognitivos, ya que se ha demostrado que la modulación de la atención y la meditación se refleja en la actividad de esta área (Rivas et al., 2024). Además, se configuran para registrar una amplia gama de bandas de frecuencia —Delta (1–3 Hz), Theta (4–7 Hz), Alpha (8–13 Hz), Beta (14–30 Hz) y Gamma (31–100 Hz)— permitiendo una representación integral del espectro cerebral.

### **B. Calidad de Señal y Resolución Temporal:**

La capacidad de estos dispositivos para capturar datos a una alta tasa de muestreo (por ejemplo, 128 o 256 Hz) es crucial para mantener la resolución temporal necesaria para el análisis de señales no estacionarias. Una tasa de muestreo elevada permite identificar variaciones sutiles y transitorios en la actividad neuronal, lo que resulta indispensable para modelar las dinámicas temporales asociadas a los estados de atención y meditación

### **C. Sincronización Temporal:**

El proceso de adquisición no se limita únicamente a la captura de datos, sino que también implica la sincronización precisa con otros eventos del sistema. La integración de dispositivos como el Jetson Nano facilita la sincronización en tiempo real, lo que permite al sistema BCI correlacionar las señales EEG con comandos específicos y con la retroalimentación de los actuadores. Esta sincronización se logra mediante protocolos de comunicación de baja latencia, que aseguran que la señal capturada se procese y se traduzca en órdenes de control casi instantáneamente, aspecto crítico para aplicaciones en tiempo real [1].

### **D. Condiciones Ambientales y Factores de Influencia:**

Es importante considerar que la calidad de la señal EEG puede verse afectada por diversos factores ambientales, tales como interferencias electromagnéticas, movimientos del usuario o incluso condiciones de iluminación. Por ello, se establecen protocolos de calibración y condiciones controladas durante la adquisición, lo que ayuda a mitigar la incidencia de artefactos y garantiza que los datos recogidos sean lo más limpios y representativos posible. Esta consideración es fundamental para asegurar que los modelos de predicción posteriores operen sobre una base de datos de alta calidad, maximizando la precisión en la interpretación de los estados cognitivos

#### **E. Metodología de adquisición de datos:**

El estudio empleó un método estructurado de recopilación de datos que abarcó 6 meses (de junio a diciembre de 2023). Se recopilaron datos de 5 participantes (3 hombres, 2 mujeres, rango de edad 21-60 años) utilizando auriculares Neurosky y Brainlink.

Los participantes fueron seleccionados en función de:

- Ausencia de antecedentes de trastornos neurológicos
- Visión normal o corregida a normal
- Sin experiencia previa con dispositivos BCI

Sesiones de grabación:

- Dos sesiones de grabación de 30 minutos separadas por una semana
- Entorno controlado (22°C ( $\pm 1$ ), 45 dB de ruido ambiente)
- Las tomas incluyen periodos de estado cognitivo libre ( $\geq 10$  minutos)

Cada sujeto realizó los experimentos en dos sesiones separadas por varios días para garantizar la reproducibilidad de los resultados [161]. Posteriormente, las señales de los distintos sujetos también se incorporaron a un conjunto de datos continuo, con el fin de conseguir un volumen de información suficiente para garantizar el proceso de entrenamiento de la red LSTM y GRU.

El rango de edad oscila entre los 21 y los 60 años, intentando mantener la paridad de género. Los datos de los participantes son anónimos, recogándose con un número de ensayo consecutivo que no permite la identificación o asociación de los datos con el participante en los ensayos. Cabe destacar que, en adultos varones próximos a los 60 años, el proceso de lectura de los datos en algunos casos se ha vuelto inviable, al no poder obtenerse datos de la región prefrontal de los sujetos. Esto indica que el uso de electrodos secos no invasivos en este caso puede ser una barrera para la captura consistente de datos.

Los experimentos se llevaron a cabo en un entorno controlado para minimizar las distracciones externas. Se utilizó un dispositivo Neurosky y Brainlink para registrar las señales de EEG, ya que ambos dispositivos tienen la misma tecnología basada en TGAM.

Durante los experimentos, se pidió a los participantes que actuaran con naturalidad, intentando mantener voluntariamente altos niveles de atención y concentración, de acuerdo con los valores en tiempo real que podían verse en la aplicación de captura de datos.

El proceso de adquisición de datos se diseñó cuidadosamente para garantizar tanto la autenticidad de las señales recogidas como la comodidad de los participantes. Para reproducir fielmente las condiciones del mundo real, se dio a los participantes la libertad de realizar cualquier actividad de su elección durante las sesiones, como ver películas, charlar, leer o simplemente relajarse. Con ello se pretendía captar una amplia gama de estados cognitivos naturales y minimizar el sesgo de acción que, de otro modo, podría influir en los datos y limitar su generalización.

La duración de cada sesión se fijó entre 15 y 30 minutos, lo que proporcionó un equilibrio óptimo entre la cantidad de datos y la comodidad de los participantes. Dado que los auriculares de EEG registran un bloque de datos por segundo, esta configuración dio

como resultado un mínimo de 900 y un máximo de 1800 puntos de datos por sesión, con cada bloque conteniendo 11 valores de señal. Este diseño garantizó que el conjunto de datos fuera amplio y reflejara las condiciones naturales del comportamiento, lo que permitió desarrollar modelos lo bastante robustos como para manejar entornos dinámicos de la vida real.

El conjunto de datos capturados durante los experimentos contiene las siguientes columnas:

- a. Marca de tiempo: Marca de tiempo de la captura.
- b. Atención: Valor de la atención.
- c. Meditación: Valor de la meditación.
- d. Delta, Theta, LowAlpha, HighAlpha, LowBeta, HighBeta, LowGamma, HighGamma: Valores de las señales cerebrales.
- e. Señal: Esta columna indica la calidad de la señal. En general, un valor de 0 indica una buena calidad de la señal, mientras que valores más altos indican una mala calidad de la señal o ausencia de señal.

El algoritmo patentado de Neurosky utiliza señales Beta para calcular la Atención y Alpha y Theta para calcular la meditación. Por lo tanto, hemos creado dos conjuntos diferentes de imágenes. En el conjunto completo, todas las señales se utilizan simultáneamente como entradas para predecir los niveles de Atención y Meditación. En el conjunto parcial, sólo se utilizan las señales empleadas por el algoritmo protegido. La Tabla 6 muestra la relación entre las señales de entrada y salida en cada conjunto de características.

Tabla 6: Las características se ajustan en función de las señales de entrada

<b>Características</b>	<b>Señal de entrada</b>	<b>Señal de salida</b>
<i>Completa</i>	<i>Delta, Theta, LowAlpha, HighAlpha, LowBeta, HighBeta, LowGamma, HighGamma</i>	<i>Atención / Meditación</i>
<i>Parcial</i>	<i>LowBeta, HighBeta, LowGamma, HighGamma</i>	<i>Atención</i>
	<i>Theta, LowAlpha', HighAlpha</i>	<i>Meditación</i>

Estas características “**Completa**” y “**Parcial**” determinaran los dos modelos de análisis que se han desarrollado en la predicción de los valores de Atención y Meditación mediante redes LSTM y GRU.

### 6.2.2. Preprocesamiento de Señales EEG

El preprocesamiento es la etapa crítica en la que los datos brutos recogidos durante la adquisición se transforman en una forma apta para el análisis y la inferencia por modelos de aprendizaje profundo. Este proceso se enfoca en mejorar la relación señal/ruido, eliminar artefactos y extraer características relevantes, de forma que las señales reflejen de manera precisa la actividad cerebral asociada a estados como la atención y la meditación.

#### A. Filtrado y Eliminación de Artefactos:

El proceso de filtrado y eliminación de artefactos se realiza gracias al módulo TGAM de Neurosky. TGAM es una plataforma para la adquisición y el preprocesamiento de señales EEG. Su diseño, que enfatiza la usabilidad mediante electrodos secos y un sofisticado proceso de filtrado en múltiples etapas para mitigar el ruido y los artefactos, lo convierte en una herramienta valiosa. Si bien, debido al uso de un único electrodo seco, existen limitaciones inherentes en comparación con sistemas multicanal de grado médico, el TGAM ofrece un nivel de rendimiento adecuado para aplicaciones de consumo, educativas y de investigación que no requieran la máxima resolución espacial. El proceso de trabajo del módulo TGAM se distribuye en 6 etapas que se describen a continuación.

**Primera etapa - Adquisición de señal:** Cuando los electrodos de la diadema captan las señales cerebrales, estas vienen mezcladas con

diferentes tipos de ruido. Las principales fuentes de interferencia incluyen el movimiento muscular (EMG), el movimiento ocular (EOG), la actividad cardíaca (ECG), y el ruido ambiental de 50/60 Hz de la red eléctrica.

**Segunda etapa - Preprocesamiento analógico:** El TGAM implementa primero un filtrado analógico para eliminar las frecuencias más alejadas del rango de interés del EEG (0.5 Hz a 100 Hz aproximadamente). Este filtrado inicial ayuda a remover parte del ruido de alta frecuencia y la deriva de la línea base.

**Tercera etapa - Conversión y procesamiento digital:** La señal pasa por un convertidor analógico-digital de alta precisión integrado en el TGAM. Una vez digitalizada, el chip aplica una serie de filtros digitales más sofisticados:

- Un filtro notch digital centrado en 50/60 Hz para eliminar la interferencia de la red eléctrica
- Filtros paso banda para separar las diferentes bandas de frecuencia del EEG (delta, theta, alpha, beta, gamma)
- Algoritmos adaptativos que detectan y eliminan artefactos basándose en sus características temporales y espectrales

**Cuarta etapa - Detección de artefactos:** El TGAM implementa algoritmos especializados para identificar patrones típicos de artefactos:

- Detecta cambios abruptos en la amplitud que suelen indicar movimientos
- Identifica patrones característicos de parpadeos y movimientos oculares
- Reconoce la periodicidad típica de la señal cardíaca

**Quinta etapa - Procesamiento avanzado:** El chip utiliza técnicas de procesamiento de señales más avanzadas como:

- Análisis de componentes independientes (ICA) simplificado para separar fuentes de señal

- Algoritmos de umbralización adaptativa para determinar cuándo una señal debe considerarse artefacto
- Técnicas de promediado móvil para suavizar la señal sin perder información relevante

Sexta etapa - Validación de calidad: El TGAM genera continuamente métricas de calidad de señal que indican:

- El nivel de ruido presente en la señal
- La impedancia del contacto del electrodo
- La proporción señal/ruido estimado

Esta información se utiliza para ajustar dinámicamente los parámetros de filtrado y para informar al usuario cuando la calidad de la señal no es óptima.

El resultado final es una señal EEG más limpia que mantiene la información neurológica relevante mientras minimiza la presencia de artefactos. Es importante mencionar que, dado que la diadema Neurosky utiliza un único electrodo seco, sus capacidades de filtrado tienen ciertas limitaciones comparadas con sistemas médicos profesionales multicanal. Sin embargo, para aplicaciones de consumo y educativas, el nivel de filtrado alcanzado es bastante efectivo.

## **B. Segmentación y tamaño de la ventana:**

Posteriormente, las señales filtradas se segmentan en ventanas temporales, windowing en inglés o LB (look-Back) como se ha definido en el proceso de predicción. Este procedimiento de windowing es crucial para capturar la dinámica temporal inherente a la actividad cerebral. La elección de la longitud de las ventanas y su grado de solapamiento se realiza en función de la naturaleza no estacionaria de los datos EEG, permitiendo al modelo capturar transiciones y patrones temporales que se extienden a lo largo de varios segundos. Esta segmentación facilita la transformación de las series temporales en secuencias que los modelos LSTM y GRU pueden procesar eficientemente, conservando la información contextual de cada segmento [23].

### **C. Normalización y Estandarización de Datos:**

Dada la variabilidad en la amplitud de las señales EEG, es fundamental aplicar técnicas de normalización para reescalar los datos a un rango común. La normalización permite que el modelo de predicción se concentre en las variaciones relativas y no se vea influenciado por diferencias de escala, lo que facilita la convergencia durante el entrenamiento. Además, la estandarización contribuye a minimizar el efecto de valores atípicos y a estabilizar el proceso de aprendizaje, lo que es especialmente importante en aplicaciones en tiempo real donde la consistencia es clave .

### **D. Extracción de Características y Representación de Datos:**

El preprocesamiento no solo transforma la señal, sino que también incluye la extracción de características que capturan los elementos esenciales de la actividad cerebral. Entre estas características se encuentran los índices de potencia en cada banda de frecuencia, la relación entre las diferentes bandas (por ejemplo, la relación entre Beta y Alpha) y otros parámetros estadísticos que pueden correlacionarse con estados de atención y meditación. La extracción automatizada de estas características se lleva a cabo mediante técnicas de análisis de series temporales y algoritmos de aprendizaje no supervisado, permitiendo que los modelos LSTM y GRU se entrenen sobre datos enriquecidos y representativos.

### **E. Optimización del Flujo de Datos para Modelos en Tiempo Real:**

Finalmente, el preprocesamiento se adapta para cumplir con las exigencias de sistemas en tiempo real. La eficiencia en la reducción de ruido y la segmentación adecuada de los datos permiten que el procesamiento posterior se realice en plazos muy cortos, con tiempos de respuesta que pueden ser inferiores a 50 ms. Esta capacidad es crucial para garantizar que las predicciones generadas por las redes LSTM y GRU se traduzcan de manera inmediata en comandos de control para dispositivos físicos .

### 6.3. Implementación de Modelos LSTM y GRU

En el ámbito de la neurociencia computacional y la inteligencia artificial, este estudio aborda la predicción de estados cognitivos a partir de señales de EEG no procesadas. Para ello, se implementan modelos avanzados de aprendizaje profundo, como las redes LSTM y GRU, que han demostrado una notable capacidad para capturar dependencias temporales complejas. Esta capacidad resulta crucial en el modelado de series temporales, como las señales de EEG, dada su alta complejidad.

Se ha demostrado la estimación eficiente de los valores de atención y meditación con redes LSTM y GRU, ampliando las capacidades de procesamiento en tiempo real de los sistemas BCI mediante la predicción de los futuros estados de atención y meditación. Este enfoque predictivo reduce la dependencia de las lecturas instantáneas, proporcionando transiciones más suaves y una mejor interacción con el usuario en entornos dinámicos, como el control robótico. Aunque los algoritmos patentados sirven como entrenamiento y línea de base para las lecturas del estado actual, nuestro modelo puede predecir valores futuros [33].

Para evaluar la precisión y eficacia de estos modelos, se han seleccionado métricas de rendimiento, así como técnicas de validación cruzada para garantizar la robustez de los modelos. Esta metodología de comparación resulta esencial para discernir las fortalezas y debilidades relativas de las redes LSTM y GRU en la tarea de predicción a partir de datos EEG, lo que permite una evaluación exhaustiva de su aplicabilidad en contextos de neurofeedback y BCI [34].

Las métricas de evaluación RMSE, MSE, MAE y SMAPE validan los resultados, lo que está en línea con los hallazgos previos en la literatura sobre metodologías de evaluación de modelos de aprendizaje profundo [35].

En suma, el estudio no solo efectúa una comparación entre el rendimiento de los modelos LSTM y GRU, sino que también los contrapone con el algoritmo propietario de Neurosky, cuyo modelo TGAM es ampliamente utilizado en dispositivos comerciales para calcular valores de atención y meditación. Esta comparación resulta de crucial importancia, como se menciona en [36].

### 6.3.1. Algoritmos de Optimización y Regularización

Las técnicas de RandomSearch, nos permiten encontrar los valores óptimos de las métricas indicadas anteriormente, de la arquitectura de red neuronal recomendada para dichas métricas. Para el proceso computacional y cálculo de valores y métricas con el método RandomSearch, se ha utilizado el Sandbox de Google, Google Colab, que ha facilitado una reducción significativa de los tiempos de operación, tras seleccionar la configuración de GPU necesaria para optimizar el proceso en su entorno de ejecución.

Hemos utilizado RandomSearch para determinar los mejores hiperparámetros y arquitectura. Como parte del proceso RandomSearch, se variaron sistemáticamente varios hiperparámetros para identificar la configuración óptima de los modelos LSTM y GRU[160]. La Tabla 7 ofrece un resumen exhaustivo de los hiperparámetros explorados, incluidos sus rangos respectivos y los mejores valores determinados a través de los experimentos. Este proceso de optimización fue crucial para mejorar el rendimiento del modelo y garantizar predicciones sólidas.

Tabla 7: Rangos de hiperparámetros y valores óptimos para los modelos LSTM y GRU

<i>Hyperparameter</i>	<i>Range Explored</i>	<i>Description</i>
<i>LSTM Units</i>	<i>[4, 8, 16, 32, 64]</i>	<i>Number of units in the LSTM layer. Optimised to balance capacity and computational efficiency</i>
<i>GRU Units</i>	<i>[4, 8, 16, 32, 64]</i>	<i>Number of units in the GRU layer. Selected to balance accuracy and efficiency</i>
<i>Batch Size</i>	<i>[1, 5, 10, 20]</i>	<i>Number of samples processed before updating the model. Smaller values reduce overfitting risk.</i>
<i>Optimizer</i>	<i>'adam', 'rmsprop', 'sgd'</i>	<i>Algorithm used to optimise the model's parameters. Adam performed best for both attention and meditation</i>
<i>Dropout Rate</i>	<i>[0.01, 0.1, 0.2, 0.3, 0.4]</i>	<i>Regularisation applied to prevent overfitting during training</i>
<i>Lookback Window</i>	<i>[3, 5, 7, 9, 15, 30, 60, 100]</i>	<i>Number of previous time steps used as input to predict the next value</i>

Estos hiperparámetros se optimizaron por separado para los conjuntos de datos de atención y meditación, y se observaron mejoras coherentes en el rendimiento de ambos.

### **Validación cruzada**

La validación cruzada es un paso vital en el aprendizaje automático para garantizar que un modelo se forme de manera fiable y no esté demasiado adaptado a un conjunto de datos específico. Este enfoque garantiza que el modelo se evalúe en diferentes subconjuntos de datos, lo que mejora su fiabilidad y reduce el sesgo que podría producirse si se utilizara una única división de entrenamiento-prueba. Al dividir los datos en subconjuntos de entrenamiento y de prueba, se ayuda a validar la capacidad de generalización del modelo, lo que permite confiar en que funcionará eficazmente en situaciones reales.

Para evaluar el rendimiento y la extrapolabilidad de los modelos LSTM y GRU, empleamos un enfoque de validación cruzada k-fold con  $k=5$ , utilizando los valores de los hiperparámetros obtenidos en el proceso previo de RandomSearch. Esta metodología garantiza una evaluación robusta del rendimiento al tiempo que minimiza el riesgo de sobreajuste. El proceso se describe del siguiente modo:

- **Partición del conjunto de datos:** El conjunto de datos se dispuso aleatoriamente y se dividió en 5 pliegues (folds) de igual tamaño. En cada iteración, se utilizó un pliegue como conjunto de prueba, mientras que los 4 pliegues restantes se combinaron para formar el conjunto de entrenamiento.
- **Entrenamiento y validación:** Los modelos fueron entrenados utilizando el conjunto de entrenamiento y evaluados mediante el conjunto de prueba. Este procedimiento se replicó diez veces, y cada pliegue se utilizó en una ocasión como conjunto de prueba. Para cada pliegue, se registraron métricas como el RMSE, el MSE y el MAE, con el propósito de medir la precisión de la predicción.

- **Agregación de resultados:** Tras completar las 10 iteraciones, se promediaron las métricas de evaluación en todos los pliegues para obtener una estimación fiable del rendimiento del modelo.

En las siguientes figuras, Figura 25, y Figura 26, se puede observar el proceso completo de validación del modelo RNN, así como los valores de las métricas y los hiperparámetros óptimos para dichos valores métricos obtenidos.

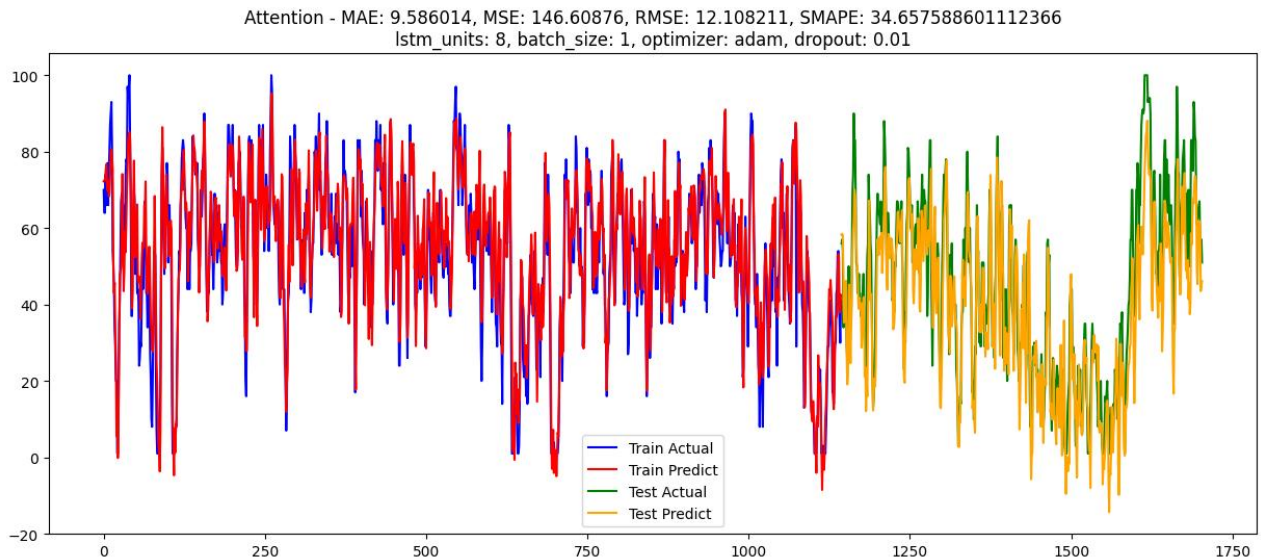


Figura 25: Cálculo de hiperparámetros con el modelo LSTM para valores de Atención.

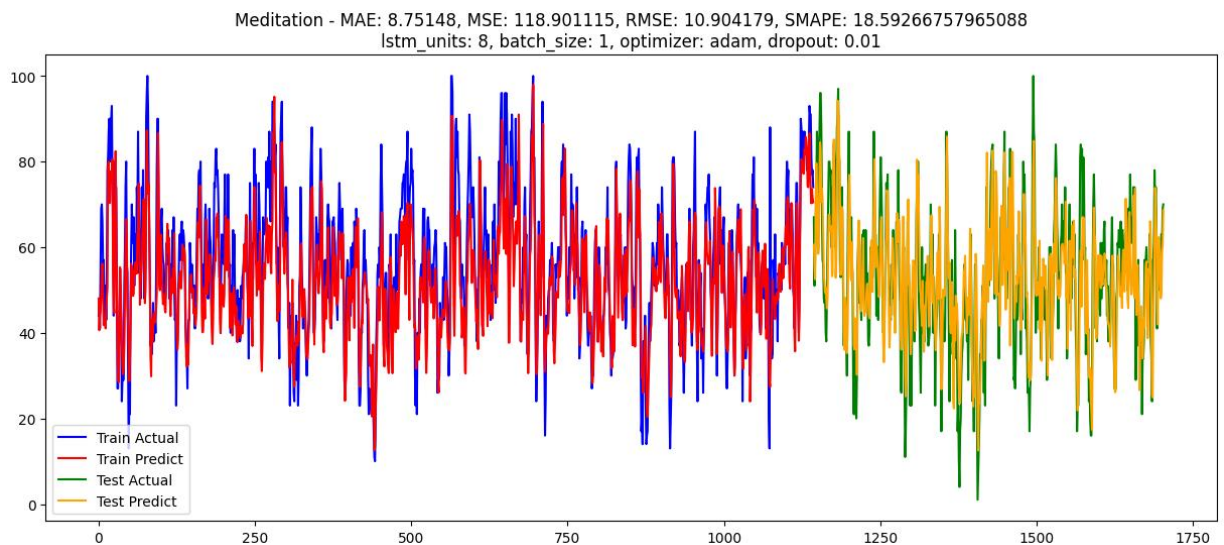


Figura 26: Cálculo de hiperparámetros con el modelo LSTM para valores de Meditación.

El primer análisis realizado es el cálculo de Atención y Meditación utilizando el mismo esquema de cálculo seguido por NeuroSky, segmentando las señales neuronales y descartando el valor de la señal Delta.

Para evaluar el rendimiento de los modelos LSTM, GRU y CNN en el cálculo de los estados atencionales y meditativos, se utilizaron métricas como RMSE, MSE, MAE y SMAPE. Estas métricas son esenciales para determinar la precisión y fiabilidad de los modelos en la predicción de estados cognitivos a partir de señales EEG. La elección de estas métricas se basa en estudios previos que han demostrado su eficacia en la evaluación de modelos de aprendizaje profundo en tareas de predicción basadas en EEG [162].

El primer proceso de comparación se realiza para los valores de Atención y Meditación utilizando una red LSTM y RandomSearch para la determinación de los hiperparámetros, como se muestra en la tabla 8 para los valores de Atención y en la tabla 9 para los valores de Meditación.

*Tabla 8: Predicción de ATENCIÓN con modelo LSTM, utilizando conjunto parcial de características.*

<i>LSTM</i>								
<i>Atención</i>								
<i>Look-Back</i>	<i>LSTM Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>MAE</i>	<i>MSE</i>	<i>RMSE</i>	<i>SMAPE</i>
<i>1</i>	<i>8</i>	<i>1</i>	<i>Adam</i>	<i>0,01</i>	<i>18,440</i>	<i>520,614</i>	<i>22,816</i>	<i>46,424</i>
<i>3</i>	<i>8</i>	<i>1</i>	<i>Adam</i>	<i>0,01</i>	<i>16,443</i>	<i>390,069</i>	<i>19,750</i>	<i>44,189</i>
<i>5</i>	<i>64</i>	<i>10</i>	<i>Adam</i>	<i>0,1</i>	<i>17,237</i>	<i>444,384</i>	<i>21,080</i>	<i>45,008</i>
<i>7</i>	<i>8</i>	<i>1</i>	<i>Adam</i>	<i>0,01</i>	<i>17,011</i>	<i>418,785</i>	<i>20,464</i>	<i>44,605</i>
<i>9</i>	<i>8</i>	<i>1</i>	<i>Adam</i>	<i>0,01</i>	<i>17,269</i>	<i>450,359</i>	<i>21,221</i>	<i>45,212</i>
<i>12</i>	<i>32</i>	<i>5</i>	<i>Adam</i>	<i>0,2</i>	<i>18,437</i>	<i>522,306</i>	<i>22,854</i>	<i>46,929</i>
<i>15</i>	<i>16</i>	<i>1</i>	<i>rmsprop</i>	<i>0,2</i>	<i>18,791</i>	<i>526,821</i>	<i>22,952</i>	<i>48,388</i>
<i>60</i>	<i>8</i>	<i>1</i>	<i>Adam</i>	<i>0,01</i>	<i>19,565</i>	<i>558,270</i>	<i>23,627</i>	<i>51,152</i>
<i>100</i>	<i>64</i>	<i>1</i>	<i>Adam</i>	<i>0,3</i>	<i>21,289</i>	<i>666,650</i>	<i>25,819</i>	<i>53,542</i>

Tabla 9: Predicción de MEDITACIÓN con modelo LSTM, utilizando conjunto parcial de características.

LSTM								
Meditación								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0,01	12,937	248,019	16,340	26,072
3	8	1	Adam	0,01	9,747	152,810	12,361	20,292
5	8	1	Adam	0,01	9,730	153,521	12,390	20,396
7	16	5	Adam	0,01	9,932	160,706	12,677	20,925
9	16	5	Adam	0,01	11,080	194,349	13,940	22,482
12	16	5	Adam	0,01	9,750	153,204	12,377	20,596
15	16	5	Adam	0,01	10,855	167,291	13,685	22,533
60	8	1	Adam	0,01	13,085	263,261	16,225	26,387
100	8	1	Adam	0,01	9,309	137,050	11,706	20,137

Continuando con la comparación, se realiza el mismo proceso, pero utilizando una red GRU y la estructura de cálculo RandomSearch, como se muestra en la tabla 10 para la predicción de la Atención y en la tabla 11 para el valor de la Meditación.

Tabla 10: Predicción de ATENCIÓN con modelo GRU, utilizando conjunto parcial de características.

GRU								
Atención								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0,01	18,205	498,305	22,342	46,277
3	8	1	Adam	0,01	16,537	391,977	19,798	44,821
3B	8	1	Adam	0,01	16,757	409,662	20,240	45,133
5	8	1	Adam	0,01	16,450	394,236	19,855	43,750
7	8	1	Adam	0,01	16,665	400,613	20,015	45,749
9	4	10	sgd	0,2	14,613	368,046	19,184	29,728
9B	8	1	Adam	0,01	16,847	423,590	20,581	46,538
12	8	5	Adam	0,2	17,409	442,020	21,024	46,353
15	16	5	Adam	0,01	17,239	477,591	21,853	45,865
60	8	1	Adam	0,01	17,830	503,543	22,439	50,804
60B	64	10	Adam	0,1	20,124	652,845	25,550	57,583
60C	4	10	Adam	0,1	13,532	297,385	17,244	26,507
100	4	10	Adam	0,01	19,392	590,453	24,299	54,391
100B	8	1	Adam	0,01	19,640	585,088	24,188	52,710

Tabla 11: Predicción de MEDITACIÓN con modelo GRU, utilizando conjunto parcial de características.

GRU								
Meditación								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0,01	12,695	257,617	16,050	25,732
3	64	20	Adam	0,01	9,669	153,723	12,398	20,106
3B	8	1	Adam	0,01	9,377	142,390	11,932	19,491
5	8	1	Adam	0,01	10,554	178,801	13,371	21,483
7	64	20	Adam	0,01	9,940	161,121	12,693	20,752
9	64	1	Adam	0,3	11,358	215,132	14,667	21,554
9B	64	20	Adam	0,01	10,049	163,756	12,796	20,726
12	16	5	Adam	0,01	9,703	152,665	12,355	20,342
12B	16	5	Adam	0,01	11,157	197,590	14,056	22,694
15	16	5	Adam	0,01	10,180	168,557	12,982	21,997
60	4	10	Adam	0,01	10,439	183,217	13,535	22,590
60B	8	1	Adam	0,01	11,246	206,354	14,365	23,528
100	8	1	Adam	0,01	12,257	231,846	15,226	25,113

En las dos últimas tablas se pueden observar valores repetidos de Look-Back, ya que en el proceso de prueba los valores obtenidos, especialmente en la definición de los hiperparámetros, mostraron valores alejados de lo esperado o con una dispersión mayor de la permitida.

En la siguiente fase, se replicó el mismo procedimiento de análisis descrito anteriormente, con la diferencia fundamental de que se utilizó como características (features), la totalidad de los datos recogidos por la diadema EEG. Esto incluyó todas las señales neuronales en el espectro completo de frecuencias (Delta, Theta, Alpha, Beta y Gamma), sin aplicar ningún tipo de reducción similar al utilizado por la empresa Neurosky. Es decir, se accedió y procesó directamente el 100% de la señal cruda capturada por el sensor, evitando replicar los algoritmos de interpretación o simplificación propietarios del fabricante, con el objetivo de maximizar la riqueza informativa y explorar posibles patrones ocultos en los datos

originales, obteniendo los resultados que se muestran a continuación en las tablas 12 y 13.

Tabla 12: Predicción de ATENCIÓN con LSTM utilizando el total de las características.

LSTM								
Atención								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0,01	12,770	252,984	15,905	36,036
3	8	1	Adam	0,01	10,937	180,859	13,448	38,268
5	8	1	Adam	0,01	11,117	185,601	13,623	40,622
7	8	1	Adam	0,01	9,5860	146,608	12,108	34,657
9	32	20	Adam	0,1	10,250	166,413	12,900	32,837
12	16	1	rmsprop	0,2	10,234	162,917	12,769	39,718
15	4	10	Adam	0,01	12,086	219,698	14,822	77,626
60	4	10	Adam	0,01	10,679	170,312	13,050	37,424
100	32	20	Adam	0,1	13,549	270,008	16,431	59,413

Tabla 13: Predicción de MEDITACIÓN con LSTM utilizando el total de las características.

LSTM								
Meditación								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	64	1	Adam	0,01	13,012	266,657	16,329	26,250
3	8	1	Adam	0,01	9,405	139,423	11,807	19,661
5	8	1	Adam	0,01	9,011	122,980	11,089	19,215
7	8	1	Adam	0,01	8,751	118,901	10,904	18,592
9	8	1	Adam	0,01	9,703	144,412	12,017	20,292
12	16	5	Adam	0,01	9,390	136,743	11,693	19,839
15	16	5	Adam	0,01	11,352	205,391	14,331	23,227
60	16	5	Adam	0,01	13,804	286,817	16,935	28,230
60B	4	10	Adam	0,01	10,759	189,460	13,794	23,191
100	8	1	Adam	0,01	11,555	208,567	14,441	24,088

Al igual que con el modelo anterior, realizamos la predicción con la arquitectura GRU manteniendo las condiciones de prueba, lo que significa mantener el análisis

sobre el 100% de las señales neuronales, con los siguientes resultados mostrados en la tabla 14 para el valor de Atención y en la tabla 15 para el valor de Meditación.

*Tabla 14: Predicción ATENCIÓN con GRU utilizando el total de las características.*

GRU								
Atención								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0,01	12,905	259,139	16,097	36,473
3	64	10	Adam	0,1	14,400	173,774	13,182	37,504
5	64	10	Adam	0,1	10,174	169,127	13,004	35,343
5B	8	1	Adam	0,01	9,3669	139,029	11,791	31,990
7	32	10	rmsprop	0,4	18,602	561,655	23,699	44,233
7B	64	10	Adam	0,1	10,734	191,562	13,840	34,664
7C	8	1	Adam	0,01	9,5709	147,827	12,158	34,180
9	64	10	Adam	0,1	9,9228	159,276	12,620	33,054
9B	16	1	rmsprop	0,2	11,752	211,514	14,543	14,854
11	8	5	Adam	0,2	9,488	148,826	12,199	30,005
12	8	1	Adam	0,01	11,753	203,129	14,252	45,803
15	8	5	Adam	0,2	13,397	266,488	16,324	51,811
60	32	20	Adam	0,1	10,852	181,964	13,489	38,016
100	32	20	Adam	0,1	20,168	605,448	24,605	88,436

Tabla 15: Predicción de MEDITACIÓN con GRU utilizando el total de las características.

GRU								
Meditation								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0,01	12,594	248,451	15,762	25,644
3	8	1	Adam	0,01	8,601	112,522	10,607	18,342
5	64	20	Adam	0,01	9,537	151,213	12,296	20,873
5B	64	20	Adam	0,01	10,158	166,115	12,888	20,955
7	8	1	Adam	0,01	13,383	311,493	17,649	36,110
7B	8	1	Adam	0,01	9,552	143,579	11,982	19,974
7C	8	1	Adam	0,01	9,075	131,094	11,449	19,262
9	16	5	Adam	0,01	9,315	143,137	11,964	19,808
11	64	20	Adam	0,01	9,868	167,212	12,931	21,180
13	16	5	Adam	0,01	10,399	173,731	13,180	21,703
13B	16	5	Adam	0,01	10,867	187,101	13,678	22,142
15	8	1	Adam	0,01	9,803	150,170	12,254	20,382
60	8	1	Adam	0,01	10,531	178,255	13,351	22,115
100	8	1	Adam	0,01	12,487	236,910	15,391	25,400

#### 6.4. Comparación de Rendimiento entre LSTM y GRU

Para comparar el rendimiento de predicción entre las redes LSTM y GRU, evaluamos el modelo mediante métricas obtenidas centrando la comparación en la métrica RMSE (Root Mean Squared Error) como métrica de evaluación principal. La razón de esta elección es que el RMSE proporciona una medida directa del error en las mismas unidades que los datos originales, lo que facilita su interpretación. Además, el RMSE penaliza en mayor medida los errores de mayor magnitud, lo que resulta crucial en el contexto de la previsión de series temporales, en el que errores significativos pueden afectar a la utilidad práctica del modelo. La comparación proporcionará información sobre los puntos fuertes y débiles de cada modelo a la hora de predecir la atención y la meditación a partir de señales de EEG sin procesar [37].

En el proceso de comparación de los datos anteriores, se pueden extraer los siguientes resultados para las dos arquitecturas de modelos y estrategias de predicción, a partir de los datos obtenidos en las tablas 16 a 17.

*Tabla 16: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN con LSTM utilizando conjunto parcial de características.*

<i>LSTM</i>								
<i>Parcial</i>								
<i>Atención</i>								
<i>Look-Back</i>	<i>LSTM Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>MAE</i>	<i>MSE</i>	<i>RMSE</i>	<i>SMAPE</i>
3	8	1	Adam	0,01	16,443	390,069	19,750	44,189
<i>Meditación</i>								
<i>Look-Back</i>	<i>GRU Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>MAE</i>	<i>MSE</i>	<i>RMSE</i>	<i>SMAPE</i>
5	8	1	Adam	0,01	9,730	153,521	12,390	20,396

*Tabla 17: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN con GRU utilizando conjunto parcial de características.*

<i>GRU</i>								
<i>Parcial</i>								
<i>Atención</i>								
<i>Look-Back</i>	<i>LSTM Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>MAE</i>	<i>MSE</i>	<i>RMSE</i>	<i>SMAPE</i>
9	4	10	sgd	0,2	14,613	368,046	19,184	29,728
<i>Meditación</i>								
<i>Look-Back</i>	<i>GRU Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>MAE</i>	<i>MSE</i>	<i>RMSE</i>	<i>SMAPE</i>
3B	8	1	Adam	0,01	9,377	142,390	11,932	19,491

Tabla 18: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN con LSTM utilizando el total de las características.

LSTM								
Total								
Atención								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
7	8	1	Adam	0,01	9,586	146,608	12,108	34,657
Meditación								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
7	8	1	Adam	0,01	8,751	118,901	10,904	18,592

Tabla 19: Mejor resultado de predicción ATENCIÓN/MEDICIÓN con GRU utilizando el total de las características.

GRU								
Total								
Atención								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
5B	8	1	Adam	0,01	9,366	139,029	11,791	31,990
Meditación								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
7C	8	1	Adam	0,01	9,075	131,094	11,449	19,262

Estos valores resultantes del cálculo de RandomSearch se reflejan en los siguientes gráficos, como se muestra en la Figura 27 para los valores de Atención y en la Figura 28 para el valor de Meditación.

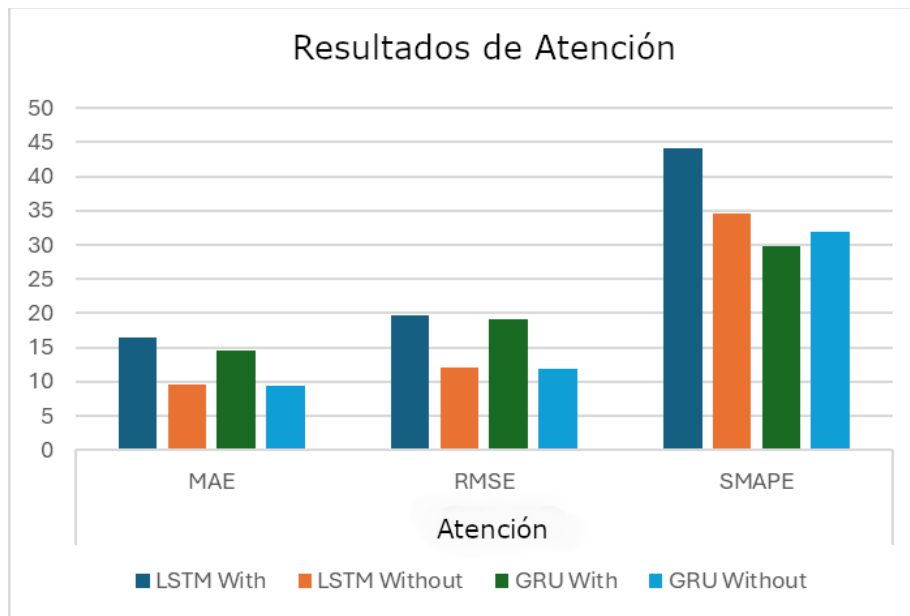


Figura 27: Comparación de la predicción de la atención.

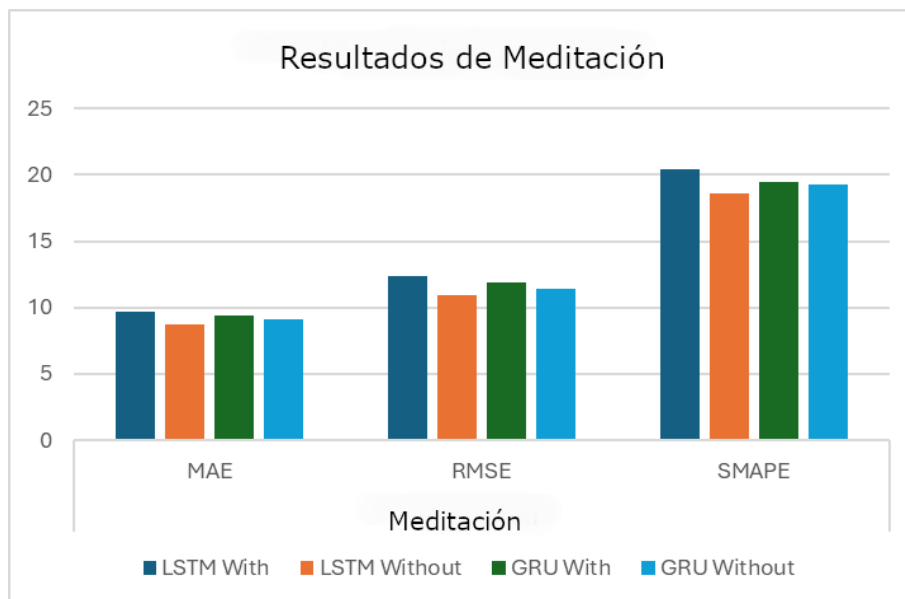


Figura 28: Comparación para la predicción de la Meditación

Como resumen, el resultado de la mejor predicción basada en la métrica RMSE se muestra en la Tabla 20 donde se puede ver la comparación no sólo del rendimiento de las redes LSTM y GRU, sino también el tamaño de la ventana temporal (LookBack) y cuál de las estrategias de predicción es más interesante para seguir en nuestra investigación.

Tabla 20: Mejor resultado de predicción ATENCIÓN/MEDITACIÓN, para LSTM Vs GRU

ATENCIÓN	RMSE	LB	MEDITACIÓN	RMSE	LB
GRU Total	11,791	5	GRU Total	11,449	7
LSTM Total	12,108	7	LSTM Total	10,904	7
GRU Parcial	12,390	5	GRU Parcial	11,932	5
LSTM Parcial	19,750	7	LSTM Parcial	12,390	7

De los datos anteriores podemos extraer el valor óptimo obtenido, así como la arquitectura y el modelo de cálculo de predicción, como se puede ver en la tabla 21 para el valor de Atención y en la tabla 22 para el valor de Meditación.

Tabla 21: Mejor resultado de predicción ATENCIÓN para LSTM Vs GRU

Atención	RMSE	LB
GRU Total	11,791	5

Tabla 22: Mejor resultado de predicción MEDITACIÓN para LSTM Vs GRU

Meditación	RMSE	LB
LSTM Total	10,904	7

## 6.5. Evaluación de Resultados y Análisis de Errores

En el presente estudio, se ha procedido a la realización de un nuevo cálculo y a la ejecución de una nueva prueba sobre los valores de LookBack. Para ello, se han tomado en consideración los valores anteriores y posteriores, con el propósito de determinar de manera inequívoca el valor óptimo de la ventana temporal que permite la mejor predicción de los modelos. Esta nueva prueba se ha realizado siguiendo el mismo procedimiento, comparando las dos arquitecturas RNN, ya que, como se puede observar en los valores de las Tablas 21 y 22, en ambos casos la predicción es más favorable con el modelo que no utiliza la estructura de cálculo definida y seguida por Neurosky en el algoritmo eSense.

Para garantizar la coherencia de los resultados anteriores, se analizarán los valores de Ventana anteriores y posteriores al valor calculado, ya que los intervalos de análisis se han realizado en dos pasos de Ventana y se han dejado valores sin analizar.

El resultado de la comparación con los valores anteriores y posteriores se muestra en las tablas 23 y 24 siguientes.

*Tabla 23: Mejor resultado de predicción de LB a priori y a posteriori para ATENCIÓN/MEDITACIÓN con arquitectura LSTM.*

<i>LSTM Total</i>					
<i>ATENCIÓN</i>					
<i>Look-Back</i>	<i>LSTM Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>RMSE</i>
6	8	1	<i>Adam</i>	0,01	13,416
7	8	1	<i>Adam</i>	0,01	12,1081
7B	32	20	<i>rmsprop</i>	0,3	13,100
8	4	10	<i>Adam</i>	0,01	14,665
<i>MEDITACIÓN</i>					
<i>Look-Back</i>	<i>LSTM Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>RMSE</i>
6	16	5	<i>Adam</i>	0,01	11,016
7	8	1	<i>Adam</i>	0,01	10,904
7B	64	20	<i>Adam</i>	0,01	12,357
8	8	1	<i>Adam</i>	0,01	12,174

*Tabla 24: Mejor resultado de predicción de LB anterior y posterior para ATENCIÓN/MEDITACIÓN con arquitectura LSTM.*

<i>GRU Total</i>					
<i>ATENCIÓN</i>					
<i>Look-Back</i>	<i>GRU Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>RMSE</i>
4	8	1	<i>Adam</i>	0,01	12,974
5	8	1	<i>Adam</i>	0,01	11,791
5B	64	10	<i>Adam</i>	0,1	12,302
6	32	20	<i>Adam</i>	0,1	13,864
<i>MEDITACIÓN</i>					
<i>Look-Back</i>	<i>GRU Units</i>	<i>Batch_Size</i>	<i>Optimizer</i>	<i>Dropout</i>	<i>RMSE</i>
6	8	1	<i>Adam</i>	0,01	12,525
7	8	1	<i>Adam</i>	0,01	11,449
7B	16	5	<i>Adam</i>	0,01	12,585
8	16	5	<i>Adam</i>	0,01	12,024

Con estos datos podemos confirmar que los valores de la ventana temporal son coherentes y confirman los datos calculados anteriormente. Estos datos se reflejan en las siguientes figuras, correspondiendo la figura 29 al valor de atención y meditación.




Figura 29: Resultado final de la predicción para Atención y Meditación

Esta comprobación nos permite especificar las métricas y los valores de la ventana temporal que mejor resultan en la predicción de la Atención y la Meditación, y los resultados finales corresponden a las siguientes Tablas 25 y 26, que confirman los valores iniciales de la primera prueba RandomSearch.

Tabla 25: Mejor resultado de predicción ATENCIÓN

Atención			RMSE	LB
GRU Total			11,791	5
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout
5	8	1	Adam	0,01

Tabla 26: Mejor resultado de predicción MEDITACIÓN

Meditacion			RMSE	LB
LSTM Total			10,904	7
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout
7	8	1	Adam	0,01

Así, podemos concluir que la predicción de los valores de Atención y Meditación utilizando RNNs de tipo LSTM para determinar el valor de Meditación y de tipo GRU para el valor de Atención.

## 6.6. Impacto de la Predicción en Aplicaciones BCI

En este estudio, se han utilizado modelos LSTM y GRU para predecir los niveles de atención y meditación a partir de datos de EEG sin procesar. Los resultados muestran que ambos modelos son capaces de realizar predicciones con errores relativamente bajos, como indican las métricas MAE, MSE y RMSE. Además, la columna "Algoritmo" indica si se ha utilizado el modelo empleado por Neurosky y Brainlink, lo cual es relevante ya que sugiere una comparación directa con los métodos de la industria.

Comparación con la bibliografía:

1. Predicción de la edad y el género basadas en EEG utilizando un modelo de red profunda BLSTM-LSTM (2019) [38]: Este estudio demuestra la eficacia de las arquitecturas LSTM para clasificar datos de EEG, aunque en este caso se trata de edad y género. La alta precisión obtenida en su estudio sugiere que las LSTM son adecuadas para capturar características temporales complejas de las señales de EEG, lo que es coherente con sus hallazgos de que las LSTM pueden predecir con éxito los estados atencionales y meditativos.[88]
2. Aplicación de técnicas de inteligencia artificial para la interfaz cerebro-ordenador en la detección de la fatiga mental: una revisión sistemática (2011-2022)[39]: Aunque este estudio se centra en la detección de la fatiga mental, la revisión sistemática de las técnicas de inteligencia artificial aplicadas a las interfaces cerebro-ordenador (BCI) respalda la idea de que los modelos de aprendizaje profundo son herramientas muy potentes para interpretar las señales del electroencefalograma (EEG). Esto refuerza la validez de su enfoque al utilizar LSTM y GRU para predecir estados cognitivos.[89]
3. Autenticación biométrica basada en EEG mediante aprendizaje automático: A Comprehensive Survey (2022)[40]: Este estudio ofrece una visión general de las técnicas de aprendizaje automático aplicadas a la autenticación biométrica basada en EEG. Aunque el objetivo es diferente, la eficacia de las técnicas de aprendizaje automático en la clasificación de

señales EEG es un buen augurio para su aplicación en la predicción de la atención y la meditación.[90]

En resumen, los resultados obtenidos están en línea con la literatura existente en cuanto a la aplicabilidad y eficacia de las RNNs, en concreto las LSTMs y las GRUs, para analizar y predecir estados cognitivos a partir de señales EEG. La comparación de diferentes arquitecturas y la optimización de hiperparámetros en su estudio proporcionan una valiosa contribución al campo de estudio de la BCI, demostrando que, con la configuración adecuada, estos modelos pueden ser ajustados para mejorar la precisión en la predicción de estados mentales complejos. Además, el uso de un subconjunto de señales EEG para la predicción de la atención y la meditación, como se indica en la columna "Algoritmo", sugiere una posible vía para la simplificación y mejora de los sistemas BCI existentes.

#### *6.6.1. Análisis de los puntos fuertes y débiles de las redes LSTM y GRU para la predicción de la atención y la meditación.*

Las redes LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit) son variantes de las redes neuronales recurrentes (RNN) que se han utilizado ampliamente para procesar secuencias de datos como las señales de EEG. Ambas arquitecturas están diseñadas para captar dependencias temporales a largo plazo, lo que las hace adecuadas para tareas de predicción de series temporales como la predicción de la atención y la meditación a partir de señales de EEG. Sin embargo, cada una tiene sus puntos fuertes y débiles en este contexto.

#### **Fortalezas de las redes LSTM:**

- **Capacidad de Memoria:**

Los modelos de redes LSTM han sido diseñados específicamente para mitigar el problema del desvanecimiento del gradiente, permitiéndoles así aprender dependencias a largo plazo. Esta característica resulta fundamental al trabajar con señales EEG, las cuales pueden contener patrones de relevancia para estados de atención y meditación que se extienden a lo largo de periodos prolongados.

- **Precisión:**

Diversos estudios han demostrado que las LSTM pueden alcanzar niveles de

precisión muy elevados en tareas de clasificación y predicción. Por ejemplo, la investigación titulada “EEG-Based Age and Gender Prediction Using Deep BLSTM-LSTM Network Model” (2019) evidencia que estas redes son igualmente efectivas en la predicción de estados de atención y meditación [163]. Dichos hallazgos refuerzan la utilidad de las LSTM como herramienta robusta para el análisis y la interpretación de señales cerebrales.

### **Debilidades de las LSTM**

- **Complejidad y Costo Computacional:** La estructura compleja inherente a las LSTM conlleva un mayor costo computacional y tiempos de entrenamiento más extensos, especialmente al procesar conjuntos de datos de gran volumen.
- **Riesgo de Sobreajuste:** Debido a su elevada complejidad, estas redes pueden ser susceptibles al sobreajuste cuando la cantidad de datos de entrenamiento es insuficiente, lo cual podría limitar su capacidad de generalización en escenarios prácticos.

### **Fortalezas de las GRU**

- **Eficiencia:** Las unidades GRU presentan una estructura más sencilla en comparación con las LSTM, ya que integran en una sola compuerta las funciones de olvido y actualización. Esta simplificación se traduce en tiempos de entrenamiento más rápidos y en una mayor eficiencia computacional, como se sugiere en la revisión sistemática “Application of Artificial Intelligence Techniques for Brain-Computer Interface in Mental Fatigue Detection” (2023) [164].
- **Flexibilidad:** La menor complejidad de las GRU las hace más adaptables a conjuntos de datos de distintos tamaños, lo cual es particularmente ventajoso en aplicaciones de interfaces cerebro-computadora (BCI), donde los volúmenes de datos pueden ser limitados o presentarse con alta variabilidad [23].

### **Debilidades de las GRU**

- **Capacidad de Memoria:** Aunque las GRU ofrecen una eficiencia notable, su capacidad para retener información a largo plazo puede ser ligeramente inferior a la de las LSTM, lo que supone un inconveniente al modelar señales EEG que requieren capturar dinámicas a largo plazo.
- **Generalización:** En determinadas circunstancias, las GRU pueden mostrar dificultades para generalizar, especialmente ante patrones complejos o sutiles en los datos. Esta limitación podría impactar negativamente en la precisión de la predicción de estados de atención y meditación.

## Resultados y Consideraciones Finales

En el marco de nuestro estudio, los resultados finales han mostrado que tanto los modelos LSTM como los GRU ofrecen desempeños comparables cuando se evalúan mediante las métricas MAE, MSE y RMSE. Este hallazgo indica que, pese a las diferencias estructurales y operativas, ambas arquitecturas son capaces de capturar de manera adecuada la dinámica de las señales EEG para predecir los niveles de atención y meditación con una precisión razonable.

Es importante destacar que la elección entre LSTM y GRU dependerá de factores específicos relacionados con el conjunto de datos y el contexto de aplicación, tales como el tamaño del mismo, la disponibilidad de recursos computacionales y la necesidad de minimizar los tiempos de entrenamiento. Además, la selección de la arquitectura más adecuada es crucial en el desarrollo de sistemas de inteligencia artificial aplicados al análisis de señales cerebrales, ya que implica un balance entre precisión, eficiencia y capacidad de adaptación a los requerimientos particulares de cada problema.

En conclusión, la integración de estos modelos en aplicaciones de atención y meditación requiere una evaluación cuidadosa de sus fortalezas y limitaciones, de modo que se logre una implementación que combine robustez y eficiencia, atendiendo tanto a las exigencias técnicas como a las necesidades prácticas de los usuarios [88][89][10]

Observamos cómo tanto las LSTM como las GRU presentan méritos significativos para la predicción de estados cognitivos a partir de señales EEG. La elección entre

estas dos arquitecturas debe fundamentarse en un equilibrio cuidadoso entre la precisión deseada y los recursos computacionales disponibles, considerando asimismo la naturaleza específica de los datos EEG analizados. Este balance resulta esencial, ya que mientras las LSTM ofrecen una capacidad superior para captar dependencias a largo plazo, las GRU se distinguen por su eficiencia y adaptabilidad en contextos donde la variabilidad y el tamaño del conjunto de datos pueden ser limitados. En definitiva, la determinación de la arquitectura óptima requiere una evaluación meticulosa de las exigencias del análisis y de las limitaciones propias del entorno experimental, lo que posibilita un uso estratégico y efectivo de las técnicas de inteligencia artificial en aplicaciones neurocientíficas y de procesamiento de señales cerebrales.

## 6.7. Limitaciones encontradas durante el estudio

Las limitaciones identificadas en este estudio constituyen aspectos cruciales que, además de evidenciar la transparencia y la integridad científica, orientan el progreso continuo en el área de investigación.

### 6.7.1. Limitaciones del estudio

- **Tamaño y diversidad de la muestra:** La muestra utilizada pudo haber sido limitada tanto en número como en diversidad, lo que afecta la capacidad de generalización de los resultados. Contar con una muestra más amplia y heterogénea podría aumentar la robustez de los modelos predictivos.
- **Calidad de los datos EEG:** Las señales EEG son susceptibles a la presencia de ruido y artefactos, lo que puede comprometer la precisión de las predicciones. La calidad de estos datos es un factor determinante para el desempeño óptimo de los modelos de aprendizaje automático.
- **Complejidad de los estados cognitivos:** La atención y la meditación son estados cognitivos complejos que pueden no ser capturados en su totalidad por los datos EEG o por las métricas utilizadas en el estudio, lo que representa una limitación intrínseca en el modelado de dichos procesos.
- **Modelos e hiperparámetros:** La selección de modelos y la optimización de los hiperparámetros podrían haberse visto restringidas por limitaciones de

tiempo o por la disponibilidad de recursos computacionales, lo que podría influir en la calidad final de las predicciones.

- **Interpretación de los modelos:** Las redes neuronales profundas, en particular las LSTM y GRU, son a menudo objeto de críticas debido a su limitada interpretabilidad. Esto dificulta la comprensión exacta de los mecanismos internos que conducen a las predicciones, complicando la validación y la explicación de los resultados.

Este estudio ha explorado la aplicación de modelos de deep learning, específicamente redes LSTM y GRU, para predecir estados cognitivos de atención y meditación utilizando señales EEG en bruto. Los resultados preliminares indican que estos modelos avanzados son capaces de captar con precisión tanto la dinámica temporal como las dependencias a largo plazo presentes en las señales EEG, elemento esencial para la predicción exacta de los estados cognitivos [165]. La comparación del desempeño entre las redes LSTM y GRU, frente al algoritmo propietario de Neurosky, ha proporcionado una visión valiosa sobre las fortalezas y debilidades de cada modelo en este dominio particular. Las métricas de evaluación, RMSE, MSE, MAE y SMAPE, fueron fundamentales para cuantificar y comparar el rendimiento de los modelos [166]. Todos estos hallazgos, respaldados por los datos obtenidos y referenciados en la tabla de métricas e hiperparámetros, permiten determinar la configuración óptima, considerando que el valor de RMSE fue seleccionado en esta investigación por ofrecer una visión comprensiva del rendimiento del modelo, en la que valores menores indican mejores predicciones.

Al analizar los datos, se observó que, en lo que respecta a la atención, el modelo LSTM sin el algoritmo de Neurosky y Brainlink (indicado como "No") demostró un desempeño superior en términos de MAE y MSE, lo que sugiere una mayor precisión en promedio y en errores cuadrados. No obstante, su SMAPE es ligeramente superior, lo que indica que, en términos porcentuales, el error puede ser mayor en algunos casos. A pesar de ello, la reducción en MAE y MSE podría hacer preferible este modelo si se prioriza la minimización del error absoluto.

En lo que respecta a la meditación, el modelo LSTM sin el algoritmo (también indicado como "No") mostró un desempeño ligeramente superior en todas las

métricas en comparación con el modelo GRU que utiliza dicho algoritmo. Esto sugiere que, para la predicción del estado meditativo, el modelo LSTM sin la intervención del algoritmo es más consistente tanto en precisión absoluta como en términos porcentuales.

Los resultados indican que tanto las redes LSTM como las GRU son capaces de predecir los valores de atención y meditación con alta precisión a partir de las señales EEG obtenidas con el dispositivo Neurosky. Sin embargo, los modelos que no incorporan el algoritmo propietario de Neurosky tienden a mostrar una mayor precisión en las métricas evaluadas. En particular, el modelo LSTM sin el algoritmo se destacó como ligeramente superior en la predicción de ambos estados, posicionándose como una alternativa prometedora para futuras aplicaciones en neurociencia y en tecnologías de interfaces cerebro-computadora (BCI).

La capacidad de predecir con exactitud los estados cognitivos utilizando modelos de deep learning no solo refuerza la viabilidad del empleo de datos EEG en bruto para predicciones en tiempo real, sino que también destaca el potencial aún inexplorado de las redes neuronales recurrentes en la neurociencia aplicada, sentando las bases para investigaciones futuras en este campo emergente [167], [168].

## 6.8. Comparación de Modelos de Predicción de EEG

La comparación de los modelos de predicción de EEG se ha llevado a cabo evaluando la capacidad de dos arquitecturas recurrentes—LSTM y GRU—para anticipar estados cognitivos críticos, concretamente atención y meditación, a partir de señales crudas obtenidas de dispositivos de bajo coste. Este análisis se fundamenta en la evaluación de métricas clave, tales como MAE, MSE, RMSE y SMAPE, aplicadas tanto a conjuntos de características parciales (basados en los componentes utilizados por el algoritmo eSense) como a conjuntos completos que incluyen todas las bandas (Delta, Theta, Alpha, Beta y Gamma). La estrategia adoptada permite identificar, en detalle, las fortalezas y debilidades de cada arquitectura en la captura de las complejas dependencias temporales presentes en las señales EEG, conforme se detalla en el estudio de Rivas et al. (2025) publicado en Electronics [160].

En el análisis, se observó que la evaluación de los errores absolutos y cuadrados (MAE y MSE) junto con la raíz del error cuadrático medio (RMSE) proporcionan una medida directa de la precisión en la misma unidad de los datos originales, lo que facilita la interpretación de la calidad de la predicción. Adicionalmente, la métrica SMAPE ofrece una perspectiva relativa y simétrica del error, fundamental cuando se comparan valores que pueden variar significativamente en magnitud. Este conjunto de métricas ha permitido determinar que, para la predicción de atención, la arquitectura GRU tiende a obtener un RMSE inferior (alrededor de 11.79, con un look-back óptimo de 5) en comparación con los modelos basados en LSTM, mientras que, para la predicción de meditación, los modelos LSTM han mostrado un desempeño superior (RMSE aproximadamente 10.90 con look-back de 7).

Profundizando en los detalles de la comparación, los resultados experimentales obtenidos mediante RandomSearch para las redes RNN, indican que las diferencias en el rendimiento entre LSTM y GRU se deben, en gran medida, a la forma en que cada arquitectura maneja las dependencias a largo plazo en los datos, sobre todo en el tamaño de las ventanas de tiempo definidas en el modelo. Las tablas presentadas en el estudio revelan que, al utilizar el conjunto de características parciales, la arquitectura GRU logra una mayor estabilidad y una menor dispersión en las métricas de error en la predicción de atención, mientras que, en el caso de la meditación, la arquitectura LSTM alcanza un rendimiento ligeramente superior en términos de RMSE. Estas diferencias se reflejan en la consistencia de los resultados durante el proceso de validación cruzada, donde GRU mostró menores desviaciones estándar en las predicciones para la atención, confirmando su robustez en entornos de alta variabilidad.

La interpretación de estos hallazgos sugiere que la elección entre LSTM y GRU puede depender de las características específicas del estado cognitivo que se desea predecir. La simplicidad y eficiencia computacional inherentes a la estructura de los GRU favorecen su aplicación en la predicción de atención, donde la velocidad de procesamiento y la robustez ante el ruido son cruciales. Por otro lado, la mayor capacidad de memoria y la complejidad estructural de los LSTM los hacen especialmente aptos para capturar los matices más sutiles en los patrones

asociados a estados meditativos, que requieren un modelado más detallado de las dependencias a largo plazo. Estos resultados son consistentes con estudios previos y aportan evidencia empírica que respalda la hipótesis de que los modelos de redes neuronales pueden extraer de manera efectiva la información contenida en señales EEG de bajo coste.

En resumen, la comparación de modelos de predicción de EEG entre LSTM y GRU ofrece una visión integral de sus capacidades para capturar las dinámicas temporales de estados de atención y meditación. Los datos obtenidos indican que, mientras GRU es más eficiente y robusto para tareas de atención, los LSTM pueden proporcionar una mayor precisión en la detección de estados meditativos. Estas conclusiones no solo validan el uso de arquitecturas RNN en aplicaciones de BCI, sino que también delinean un camino claro para futuras investigaciones, orientadas a optimizar estos modelos mediante ajustes en los hiperparámetros, la integración de fuentes de datos multimodales y el desarrollo de enfoques híbridos que combinen las fortalezas de ambas arquitecturas. Esto sienta las bases para el desarrollo de sistemas BCI más precisos, eficientes y adaptativos para aplicaciones en rehabilitación, neurofeedback y control de dispositivos en tiempo real.

## 7. Clasificación de Señales EEG para el Control de Movimientos

Continuando con el objetivo perseguido por esta tesis, el siguiente punto a desarrollar dentro de la investigación, es la parte de clasificación de las señales obtenidas de los dispositivos EEG.

La clasificación precisa de patrones cerebrales asociados a diferentes intenciones de movimiento constituye un desafío fundamental en el desarrollo de interfaces cerebro-computadora efectivas, especialmente cuando se utilizan dispositivos EEG de bajo coste.

Este capítulo aborda de manera exhaustiva el proceso de clasificación de señales EEG para el control de cuatro movimientos direccionales básicos: *adelante*, *atrás*, *izquierda* y *derecha*. Se presenta un análisis detallado de las técnicas implementadas, desde el etiquetado inicial de las señales hasta la comparación de diferentes arquitecturas de redes neuronales y la exploración de modelos híbridos.

El proceso de clasificación implementado parte de la base construida en los capítulos anteriores, donde se ha establecido que las señales EEG, a pesar de su naturaleza ruidosa y altamente variable, contienen patrones identificables asociados a diferentes estados cognitivos e intenciones motoras. El reto principal radica en extraer estos patrones de manera eficiente y traducirlos en comandos precisos para el control de dispositivos físicos.

La metodología adoptada comprende varios componentes interrelacionados:

1. **Etiquetado sistemático de señales EEG:** Desarrollo de un protocolo experimental estructurado para capturar y etiquetar señales cerebrales asociadas a cada dirección de movimiento.
2. **Implementación de arquitecturas de redes neuronales:** Exploración y optimización de modelos LSTM y GRU, con especial atención a la configuración de hiperparámetros críticos para el procesamiento de señales temporales en procesos de clasificación.
3. **Evaluación comparativa de rendimiento:** Análisis riguroso de las diferentes arquitecturas mediante métricas estándar como precisión, recall y F1-score.

4. **Exploración de modelos alternativos:** Análisis de algoritmos clásicos como XGBoost combinados con modelos clásicos como el criterio de Popov, incluyendo el desarrollo de enfoques híbridos que combinan diferentes técnicas.
5. **Despliegue de arquitectura:** Tras el análisis y la evaluación anterior, se realizará el despliegue de la arquitectura más recomendable y óptima en el proceso de clasificación, aportando una solución real a la clasificación de señales EEG con diademas de bajo coste.

El enfoque metodológico adoptado busca no solo lograr una alta precisión en la clasificación, sino también garantizar la estabilidad y eficiencia computacional necesarias para aplicaciones en tiempo real. Para ello, se presta especial atención a la optimización de arquitecturas y al desarrollo de soluciones que puedan implementarse en plataformas embebidas con recursos limitados.

## 7.1. Metodología Experimental

En este apartado se describe el proceso completo de adquisición de datos, necesarios en el proceso de clasificación de señales EEG para el control de dispositivos físicos.

### 7.1.1 Adquisición de Datos

La adquisición de señales electroencefalográficas (EEG) se realiza mediante la diadema Neurosky, seleccionada por su accesibilidad y capacidad para registrar patrones relevantes de actividad cerebral de la zona prefrontal del cerebro. Este enfoque privilegia la portabilidad y naturalidad de la experiencia sobre la densidad espacial de electrodos, promoviendo un escenario experimental y de uso válido.

#### A. El protocolo de adquisición comprende:

Fase de calibración estructurada: Secuencias temporales predefinidas que guían al participante a través de las cinco categorías de imaginería motora (*adelante, atrás, izquierda, derecha, reposo*).

Fase de entrenamiento interactivo: Un paradigma innovador donde el participante articula simultáneamente su intención motora interna con una respuesta física mínima (presión de tecla direccional), generando un anclaje sensoriomotor que refuerza los patrones neurales asociados.

Esta dualidad metodológica responde a la naturaleza híbrida de la cognición humana, donde los procesos automáticos y deliberativos coexisten y se

influyen mutuamente. La interfaz visual proporciona retroalimentación inmediata, facilitando un proceso de "en activismo neural" donde la percepción y la acción se constituyen mutuamente.

## **B. Arquitectura de adquisición de datos**

Se implementa una aplicación completa para la recolección de datos EEG anotados con etiquetas de movimientos imaginados, utilizando un entorno visual interactivo desarrollado en Pygame y datos transmitidos en tiempo real desde una diadema NeuroSky MindWave mediante el ThinkGear Connector. La lógica del sistema está diseñada para guiar al usuario a través de una secuencia de tareas de imaginación motora (adelante, atrás, izquierda, derecha y descanso(parada)), mientras el sistema recolecta las señales EEG correspondientes junto con etiquetas que representan la clase actual. Durante la sesión, se visualiza una animación de un coche que se mueve en la dirección correspondiente, lo que refuerza el estímulo visual. Además, se representan en pantalla los valores de atención y meditación como series temporales, proporcionando retroalimentación biológica al usuario.

## **C. El Componente Humano en el Bucle de Aprendizaje**

La verdadera innovación de nuestro paradigma radica en la reconceptualización del rol del participante, transformándolo de sujeto pasivo a colaborador activo en el proceso de aprendizaje automático.

## **D. Visualización y Retroalimentación: El Diálogo Perceptual**

El componente visual no es meramente informativo sino constitutivo del experimento. La representación del cochecito moviéndose en diferentes direcciones establece un puente semiótico entre la actividad neural y su significado intencional.

La interfaz incorpora:

- **Representación directa del cochecito:** Establece una correspondencia isomórfica entre la intención mental y su manifestación visual.

- **Gráficos de atención y meditación:** Proporcionan un metanivel de conciencia sobre estados mentales relevantes para la tarea.
- **Matrices de confusión dinámicas:** Transforman conceptos estadísticos abstractos en experiencias visuales interpretables.

Esta arquitectura facilita lo que podríamos denominar una "fenomenología guiada", donde los patrones neurales adquieren significado experiencial para el participante, potencialmente facilitando la modulación consciente de estados cerebrales específicos.

### 7.1.2. Proceso de Etiquetado de Señales EEG

El etiquetado de señales electroencefalográficas (EEG) es un proceso fundamental para el desarrollo de sistemas de clasificación precisos en interfaces cerebro-computadora (BCI). En esta investigación, se implementó un protocolo sistemático de etiquetado para capturar y categorizar las señales EEG asociadas a cuatro movimientos direccionales: adelante, atrás, izquierda y derecha. Este proceso permite la creación de un conjunto de datos estructurado que servirá como base para el entrenamiento y validación de los modelos de clasificación. Desde el punto de vista funcional, el sistema opera en paralelo mediante hilos de ejecución: uno se encarga de capturar datos EEG en tiempo real a través de un socket TCP, mientras el hilo principal gestiona la interacción visual y la secuencia experimental. Cada muestra EEG incluye datos de potencia por bandas (delta, theta, alpha, beta, gamma), niveles de atención y meditación, y la etiqueta del movimiento actual. Estos datos se almacenan con precisión temporal y finalmente se exportan a un archivo CSV etiquetado, formando la base para el posterior entrenamiento de modelos de clasificación como GRU, LSTM o XGBoost. Este entorno resulta especialmente adecuado para experimentos BCI (Brain-Computer Interface), ya que combina control experimental, interacción usuario-sistema, etiquetado supervisado y monitorización en tiempo real, todo bajo un flujo continuo y sincronizado.

### 7.1.2.1. Diseño del Protocolo Experimental

El diseño del protocolo experimental se fundamenta en la necesidad de obtener datos de EEG claramente asociados a intenciones motoras específicas. El script generado implementa un sistema de captura y etiquetado que incluye:

- Definición de cuatro direcciones de movimiento (DIRECTIONS = ['Adelante', 'Atrás', 'Izquierda', 'Derecha']).
- Asignación de etiquetas numéricas para cada dirección (DIRECTION\_LABELS = {'Adelante': 0, 'Atrás': 1, 'Izquierda': 2, 'Derecha': 3}).
- Establecimiento de repeticiones por dirección (REPEATS\_PER\_DIRECTION = 3).
- Asigna un valor numérico de 4 para los valores de no actividad o parada.
- Determinación de tiempos de visualización (DISPLAY\_TIME = 15 segundos) y descanso (REST\_TIME = 5 segundos).

Este diseño permite capturar múltiples instancias de cada patrón de movimiento, facilitando el análisis estadístico y mejorando la robustez del conjunto de datos resultante.

### 7.1.2.2. Configuración del Hardware y Adquisición de Datos

La adquisición de datos EEG se realizó utilizando la diadema NeuroSky, configurada para comunicarse con el software de captura mediante el protocolo ThinkGear Connector a través de una conexión TCP/IP (HOST = '127.0.0.1', PORT = 13854)[169], [170]. El sistema captura:

- Valores de atención y meditación proporcionados por la API de NeuroSky y su algoritmo nativo eSense.
- Potencias de bandas cerebrales (Delta, Theta, LowAlpha, HighAlpha, LowBeta, HighBeta, LowGamma, HighGamma)
- Marca temporal precisa para cada muestra
- Etiqueta correspondiente al movimiento visualizado

La función `eeg_data_collector()` en el script gestiona la comunicación con la diadema, procesa los datos recibidos en formato JSON, y almacena la información en la estructura `EEG_DATA`, donde cada fila incluye los valores de las potencias de banda, los niveles de atención/meditación, y la etiqueta correspondiente al movimiento actual.

### 7.1.2.3. Estimulación Visual y Retroalimentación

Para recopilar los patrones cerebrales asociados a los movimientos direccionales, utilizaremos el modelo de imagen motora, entendiendo la imagen motora como un proceso cognitivo que implica la ejecución mental de un movimiento sin que se produzca una acción física visible o una contracción muscular[171], [172].

En el contexto de la clasificación de señales EEG (electroencefalograma), la imagen motora juega un papel importante en la detección y análisis de patrones cerebrales asociados con la intención de movimiento, objetivo que se persigue en esta tesis.

Durante la imagen motora, se activan las mismas áreas corticales que se activarían al realizar el movimiento real [171]. Esto permite detectar patrones de actividad cerebral similares a los que se producirían durante la ejecución física del movimiento[173].

Las señales EEG asociadas con la imagen motora se pueden descomponer en diferentes bandas de frecuencia, siendo las más relevantes:

- Ondas alfa (8-13 Hz).
- Ondas beta (13-25 Hz).
- Ondas mu (8-12 Hz, similares a las alfas, pero específicas de la corteza sensoriomotora)[174], [175].

Para clasificar las señales EEG relacionadas con la imagen motora, se siguen varios pasos:

- Preprocesamiento: eliminación de artefactos y amplificación de la señal.
- Extracción de características: obtención de información relevante de la señal.
- Clasificación: asociación de la señal con un evento mental específico[174].

Para la implementación de este modelo de imagen motora se implementa un sistema de estimulación visual utilizando Pygame, para generar un entorno en el que se pueda visualizar e imaginar el movimiento de un objeto en las 4 direcciones predefinidas más un valor más etiquetado que corresponderá a los momento de inactividad denominada 'sin movimiento', contando finalmente con 5 etiquetas a clasificar

Este sistema sigue la siguiente estructura de etiquetado:

- Muestra instrucciones claras al participante sobre el movimiento a imaginar

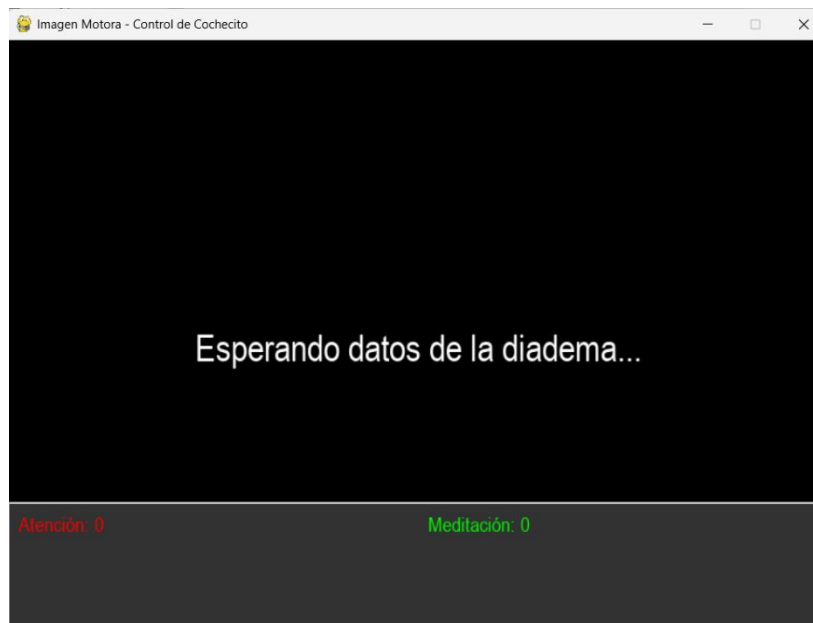


Figura 30: Espera para la confirmación de adquisición de datos desde la diadema EEG.

- Proporciona un período de preparación antes de cada tarea
- Anima visualmente el movimiento de un vehículo en la dirección correspondiente

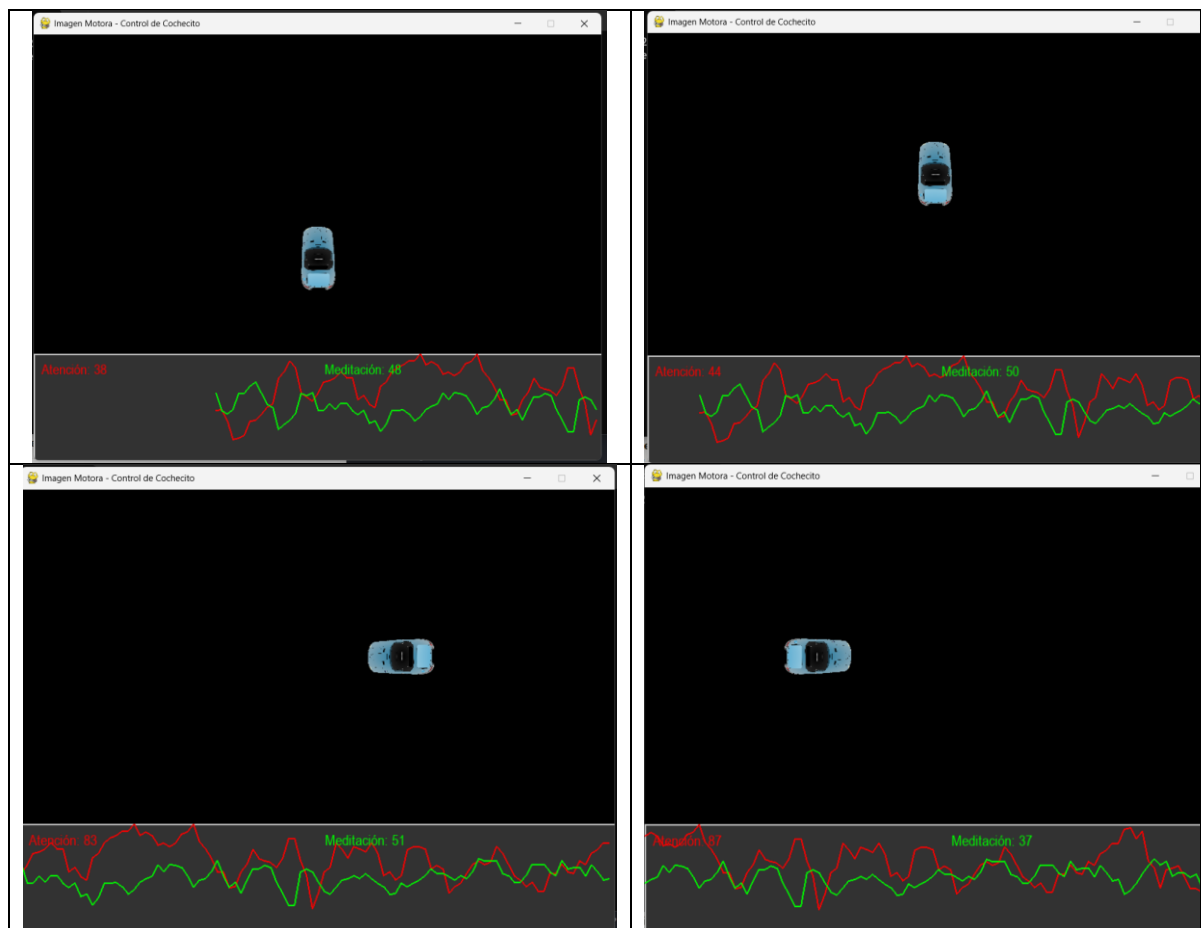


Figura 31: Proceso de etiquetado de las direcciones para la clasificación con la aplicación diseñada

- Ofrece retroalimentación visual de los niveles de atención y meditación en tiempo real
- Proporciona períodos de descanso entre tareas para reducir la fatiga mental



Figura 32: Proceso de descanso en la aplicación de etiquetado para la clasificación

El proceso relativo al descanso será etiquetado con un valor (-1) y será asociado a la acción de parada o inactividad de movimiento, cubriendo de esta forma todas las variables del movimiento previsto. La animación visual del vehículo sirve como estímulo para guiar la imaginación motora del participante, facilitando la generación de patrones cerebrales consistentes y diferenciables, haciendo consistente el proceso de etiquetado automático.

#### 7.1.2.4. Secuenciación y Aleatorización

El protocolo implementa una secuencia estructurada de tareas, donde:

- El participante visualiza primero un mensaje de preparación para cada dirección
- Se presenta la animación correspondiente durante 15 segundos
- Se proporciona un período de descanso de 5 segundos entre tareas
- El proceso se repite tres veces para cada dirección (12 ensayos en total)

Durante la visualización activa, la etiqueta correspondiente al movimiento (0-3) se asigna a cada muestra de EEG capturada mediante la variable ``current_label``.

Durante los períodos de descanso, se asigna el valor -1, permitiendo identificar y filtrar estos segmentos en el análisis posterior.

#### 7.1.2.5. Almacenamiento y Exportación de Datos

Los datos capturados durante la sesión se almacenan en memoria y, al finalizar el experimento, se exportan a un archivo CSV estructurado.

El archivo resultante en formato .CSV, contiene las siguientes columnas:

- **Timestamp:** Marca temporal precisa de cada muestra.
- **Attention:** Nivel de atención según el algoritmo eSense de NeuroSky (0-100).
- **Meditation:** Nivel de meditación según el algoritmo eSense de NeuroSky (0-100).
- **Delta, Theta, LowAlpha, HighAlpha, LowBeta, HighBeta, LowGamma, HighGamma:** Potencias de las bandas de frecuencia cerebral.
- **Label:** Etiqueta numérica que identifica el movimiento (0-3) 4 movimientos y el descanso (sin movimiento) que se asocia a la etiqueta (-1). Esta etiqueta se reescribirá como 4 para evitar el valor negativo de la etiqueta y evitar futuros errores en el clasificador.

#### 7.1.2.6. Consideraciones Metodológicas

El proceso de etiquetado implementado incorpora varias consideraciones metodológicas importantes:

- Sincronización temporal precisa: La asignación de etiquetas se realiza en tiempo real durante la captura de datos, eliminando problemas de alineación temporal.
- Distinción entre períodos activos y descanso: El uso de la etiqueta -1 para períodos de descanso facilita el filtrado posterior de datos no relevantes.
- Retroalimentación visual: La visualización en tiempo real de los niveles de atención y meditación ayuda al participante a mantener un estado mental apropiado durante el experimento.
- Repetición de patrones: La repetición de cada dirección tres veces mejora la consistencia estadística de los datos y reduce el impacto de anomalías o artefactos.
- Estructura de datos estandarizada: El formato CSV utilizado facilita el procesamiento posterior con diversas herramientas de análisis y aprendizaje automático.
- Este protocolo de etiquetado proporciona un conjunto de datos estructurado y bien documentado que servirá como base para el entrenamiento de modelos de clasificación, con el objetivo final de permitir

el control de dispositivos físicos a través de señales EEG asociadas a los cuatro movimientos direccionales básicos.

## 7.2. Entrenamiento y selección del mejor modelo de clasificación.

El proceso de entrenamiento y selección del modelo de clasificación más adecuado constituye una etapa crítica en la implementación de sistemas BCI robustos y eficientes, especialmente en entornos asistenciales que requieren un alto grado de fiabilidad y respuesta en tiempo real. Dada la naturaleza altamente no estacionaria y ruidosa de las señales EEG adquiridas mediante dispositivos de bajo costo, se ha planteado una estrategia de evaluación comparativa entre modelos tradicionales como XGBoost y redes neuronales recurrentes avanzadas, incluyendo LSTM, GRU y su variante estabilizada GRU+Popov y LSTM+Popov. Este enfoque ha permitido no solo valorar la precisión y capacidad de generalización de cada modelo, sino también su robustez frente a artefactos y su viabilidad computacional en plataformas embebidas. Las métricas de rendimiento, como la precisión, el F1-score, el error cuadrático medio (RMSE) y el error porcentual absoluto medio (MAPE), han sido utilizadas para cuantificar el desempeño de cada modelo, complementando esta evaluación con un análisis cualitativo de estabilidad y eficiencia. En esta sección se detallan las configuraciones de entrenamiento, los procedimientos de validación cruzada empleados, y los criterios utilizados para la selección del modelo óptimo, priorizando no solo su rendimiento técnico sino también su idoneidad para una futura implantación en sistemas BCI autónomos y portátiles.

### *7.2.1 Modelos de Redes Utilizados para el proceso de entrenamiento para la Clasificación*

Nuestro enfoque se ha centrado en la evaluación y optimización de dos arquitecturas principales de RNN: las redes LSTM y las GRU, centrandó el estudio en esta última arquitectura, por los resultados obtenidos en el proceso anterior de predicción y la sencillez en su arquitectura e implementación, dadas las limitaciones que nos podemos encontrar en los hardware seleccionados para su ejecución en dispositivos físicos embarcado. Esta arquitectura ha sido seleccionada tras un análisis exhaustivo de la literatura científica y los resultados

de investigaciones previas, que sugieren su idoneidad para el procesamiento de señales EEG en aplicaciones de BCI [9], [22].

La implementación de estos modelos ha sido meticulosamente diseñada para abordar las características específicas de las señales EEG capturadas mediante diademas de bajo coste[11]. Hemos prestado especial atención a la configuración de hiperparámetros críticos, como el tamaño de la ventana temporal (look-back), el número de unidades de procesamiento, las tasas de aprendizaje y los mecanismos de regularización, con el objetivo de optimizar tanto la precisión de la clasificación como la eficiencia computacional[176], [177].

En las siguientes secciones, se detallan las arquitecturas específicas implementadas, las consideraciones técnicas que guiaron su diseño, y las estrategias de optimización empleadas para maximizar su rendimiento en la tarea de clasificación de cuatro movimientos direccionales (adelante, atrás, izquierda y derecha) a partir de datos EEG etiquetados según el protocolo descrito anteriormente. Esta caracterización exhaustiva de los modelos proporciona la base para la posterior evaluación comparativa de su rendimiento y la identificación de las configuraciones óptimas para aplicaciones de control en tiempo real.

### *7.2.2. Optimización del preprocesamiento y evaluación inicial del modelo GRU para la clasificación multiclase de señales EEG*

Para optimizar el rendimiento de los modelos de clasificación, se implementó un pipeline de preprocesamiento que implementa un flujo multietapa:

- **Normalización:** Escalado de las características para asegurar valores en rangos comparables.
- **Segmentación, ventanas temporales deslizantes:** Capturan la naturaleza dinámica y transitoria de los patrones EEG.
- **Extracción de características:** Transforma las señales crudas en representaciones multidimensionales que capturan tanto la tendencia central como la variabilidad temporal.

Las características seleccionadas para esta arquitectura son las que se indican a continuación.

- **Características EEG base:**
  - Attention, Meditation, Delta, Theta, LowAlpha, HighAlpha, LowBeta, HighBeta, LowGamma, HighGamma.
  - Total de **10 canales por muestra**.
- **Filtrado:** Eliminación de artefactos y períodos de descanso (-1) del conjunto de entrenamiento. Este filtrado nos aporta un elemento en el proceso de etiquetado correspondiente al estado de “parado” o ‘sin movimiento’.
- **Balanceo de clases:** Técnicas de sobremuestreo/submuestreo para garantizar una representación equilibrada de las cuatro clases de movimiento.

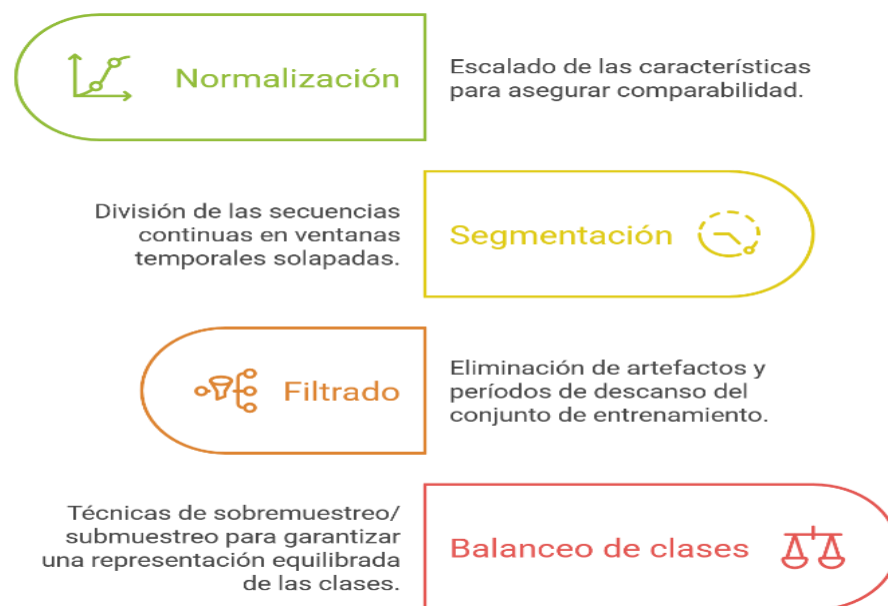


Figura 33: Técnicas de preprocesamiento de datos EEG

Este preprocesamiento, combinado con la selección de hiperparámetros óptimos mediante RandomSearch, establece las condiciones adecuadas para el entrenamiento eficiente de los modelos LSTM, GRU en la tarea de clasificación de señales EEG para el control de cuatro movimientos direccionales.

Los modelos implementados representan el estado del arte en procesamiento de señales EEG mediante técnicas de aprendizaje profundo, proporcionando un marco robusto y adaptativo para la interpretación de patrones cerebrales asociados a movimientos direccionales en interfaces cerebro-computadora.

Una primera iteración con la red GRU, aplicando estos procesos de preprocesado y preparación de los datos, nos aleja de los valores observados en la bibliografía referida a redes GRU clasificando señales EEG, como se puede observar en las gráficas de pérdida y eficiencia siguientes.

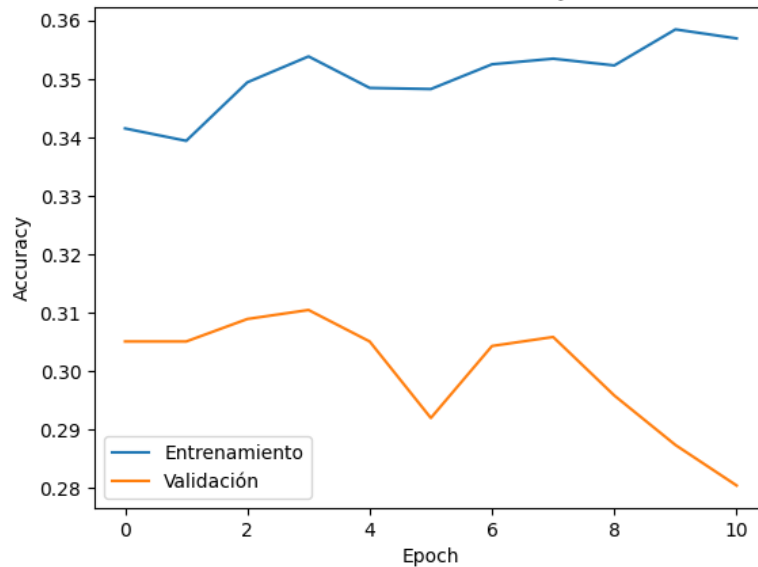


Figura 34: Evolución de la exactitud por época, en el entrenamiento entre los datos de entrenamiento y validación

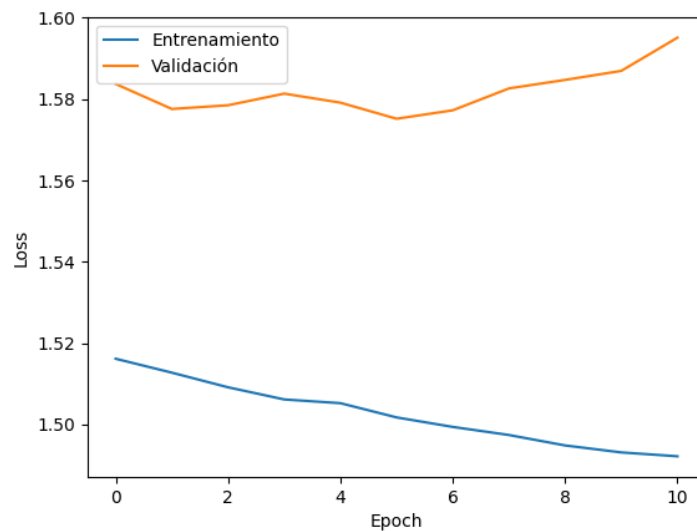


Figura 35: Evolución de la pérdida por época, en el entrenamiento entre los datos de entrenamiento y validación

Podemos ver unos primeros resultados poco prometedores en el proceso de optimización de un modelo GRU para la clasificación de señales EEG, evidenciando un rendimiento que ronda el 32% de exactitud sobre el conjunto de prueba y una pérdida final cercana a 1.55, bajo un conjunto de hiperparámetros óptimos. A pesar

de la ligera mejora observada en las curvas de entrenamiento, donde la pérdida desciende gradualmente y la precisión aumenta de forma moderada, las fluctuaciones en la fase de validación reflejan la necesidad de refinar tanto la arquitectura como las estrategias de regularización. En los datos de clase obtenidos en la iteración de clasificación confirma un sesgo significativo hacia la Clase 4 (recall=0.87), en detrimento de las demás clases, lo que motiva la adopción de técnicas de balance de clases y ajustes adicionales de hiperparámetros para incrementar la capacidad de generalización y lograr una distribución más equitativa de las predicciones en escenarios multiclase.

La optimización del modelo con los hiperparámetros inicial, condujo a la siguiente configuración:

*Tabla 27: Hiperparámetros de la red GRU óptimos*

<b>num_layers</b>	<b>units</b>	<b>dropout_rate</b>	<b>recurrent_dropout</b>	<b>learning_rate</b>
1	16	0.0	0.0	0.01

Esta configuración refleja una arquitectura relativamente sencilla, donde se ha priorizado la velocidad de convergencia mediante un learning\_rate moderadamente alto, en ausencia de regularización a través de dropout, lo que sugiere que el modelo se ha ajustado para aprender características relevantes en un espacio de representación compacto.

En la tabla 28, podemos ver los resultados por clase obtenidos, así como los parámetros de precisión de la red en el proceso de clasificación:

Tabla 28: Resultados por clase obtenidos en clasificación con GRU

Clase	precision	recall	f1-score	support
0	0.17	0.00	0.01	270
1	0.31	0.07	0.11	271
2	0.24	0.04	0.07	276
3	0.26	0.18	0.21	302
4	0.34	0.87	0.49	504
accuracy			0.32	1623
macro avg			0.26	1623
weighted avg			0.27	1623

Analizando los resultados anteriores por cada clase, podemos llegar a las siguientes conclusiones

- **Clase 0:** La precisión es baja (0.17) y el recall es prácticamente nulo, lo que indica que el modelo apenas reconoce instancias verdaderas de esta categoría.
- **Clase 1 y 2:** Ambas clases presentan valores moderados de precisión (0.31 y 0.24, respectivamente) pero un recall muy reducido (0.07 y 0.04), sugiriendo que, pese a cierta capacidad para predecir correctamente cuando se decide por estas clases, la detección global es muy deficiente.
- **Clase 3:** Se obtienen métricas ligeramente superiores (precisión=0.26, recall=0.18, f1-score=0.21), lo que podría interpretarse como una capacidad limitada para capturar algunas características específicas de esta clase.
- **Clase 4:** Destaca notablemente por un recall de 0.87 y un f1-score de 0.49, aunque la precisión se sitúa en 0.34. Esto indica que, si bien el modelo es muy sensible a la detección de instancias de la Clase 4, existe un elevado número de falsos positivos, afectando la calidad de la predicción en esta categoría.

En síntesis, aunque la optimización realizada ha permitido alcanzar una convergencia en el entrenamiento, los resultados evidencian limitaciones

significativas en la capacidad del modelo GRU para abordar eficazmente la tarea de clasificación de señales EEG en un entorno multiclase.

### 7.2.3. Propuesta de hibridación para mejorar de rendimiento de las redes LSTM y GRU.

En este punto, y en base a los valores que se muestran en el punto anterior, se ha incorporado una propuesta de hibridación de los modelos de redes LSTM y más concretamente sobre la red GRU, con modelos basados en la teoría clásica de estabilidad de sistemas, como el modelo Popov, con el objetivo de alcanzar un mayor grado de estabilidad y rendimiento en el proceso de clasificación. Esta nueva red denomina GRU+Popov tratará de mejorar los rendimientos de la red y de sus clases, intentando aportar mayor estabilidad a la red neuronal y mejorar con ello la eficiencia en la clasificación

El método Popov clásico encuentra su justificación en el contexto de las redes LSTM y GRU principalmente debido a las complejidades inherentes y a los retos asociados al aprendizaje de dependencias a largo plazo en tareas de predicción de secuencias. Las redes neuronales recurrentes (RNNs) tradicionales se enfrentan a dificultades en esta área ya que sólo utilizan un único estado oculto que se transmite a través del tiempo, lo que a menudo resulta en el problema de gradiente evanescente y hace que sea un reto aprender y retener dependencias a largo plazo[178], [179].

El método Popov, que es una técnica establecida en la teoría del control, puede utilizarse eficazmente en esta arquitectura para optimizar el proceso de aprendizaje y retención de memoria, garantizando la estabilidad y robustez del rendimiento del modelo. Además, el método Popov es útil para abordar la complejidad del modelo y garantizar un rendimiento consistente en presencia de secuencias de entrada variables, que es un escenario común en aplicaciones como el procesamiento del lenguaje natural y el reconocimiento del habla. Aplicando el método Popov, las redes LSTM y GRU pueden mantener un equilibrio entre recordar información crucial y descartar datos irrelevantes, mejorando así su eficiencia y precisión en tareas de predicción de secuencias[179].

La rigurosa base teórica de este método proporciona un marco sólido para estas arquitecturas avanzadas de redes neuronales, lo que lo convierte en una opción justificable para mejorar su rendimiento en tareas complejas.

Siendo el criterio de Popov, un criterio de estabilidad utilizado tradicionalmente en sistemas de control no lineales se ha adaptado para su uso en redes neuronales como las de memoria a largo plazo (LSTM) y las unidades recurrentes con compuerta (GRU) para abordar los problemas de estabilidad inherentes a estas arquitecturas y las condiciones particulares de las señales EEG.

El criterio de Popov se ha adaptado eficazmente a las redes neuronales planteando el problema de estabilidad de forma análoga a su aplicación tradicional. Por ejemplo, en el contexto de las GRU, se han derivado condiciones suficientes para la estabilidad entrada-estado (ISS) y la estabilidad incremental entrada-estado ('ISS). Estas condiciones implican desigualdades no lineales relacionadas con los pesos de la red, que pueden utilizarse tanto para comprobar la estabilidad de las redes entrenadas como para imponer restricciones de estabilidad durante el proceso de entrenamiento[18], [180].

La aplicación del criterio implica representar la red neuronal como un sistema interconectado, en el que un sistema lineal invariante en el tiempo (LTI) nominal, interactúa con no linealidades que satisfacen la condición de sector abierto. Esta configuración permite el uso del criterio de Popov para probar la estabilidad robusta, de forma similar a como se aplicaría a los sistemas de control con incertidumbre. Para LSTMs y GRU, el criterio de Popov proporciona condiciones analíticas que aseguran la estabilidad global de las redes, más allá de la estabilidad local alrededor de los puntos de equilibrio[18].

### *7.2.2. Primeros ensayos e iteraciones de entrenamiento de la red GRU Vs GRU+Popov para clasificación*

Como puede verse a continuación, tanto en la tabla como en las gráficas obtenidas en las primeras iteraciones de clasificación, los resultados distan mucho de alcanzar valores relevantes y significativos, que puedan considerar el desempeño de la red GRU o del modelo híbrido GRU+Popov como óptimos.

Una evaluación empírica inicial de dos arquitecturas basadas en redes GRU, concretamente la versión estándar y su variante modificada GRU+Popov, aplicadas a un conjunto de 1623 muestras distribuidas en cinco categorías, realizando una comparación rigurosa de las métricas de desempeño, incluyendo exactitud, precisión macro, recall y F1-score, complementada con un análisis detallado de las matrices de confusión y reportes de clasificación para dilucidar el comportamiento específico por clase. Evidencia un marcado sesgo en la clasificación, con una concentración de aciertos en una o dos clases dominantes, lo que subraya la necesidad de optimizar tanto la arquitectura como las estrategias de entrenamiento para abordar la clasificación multiclase en escenarios con distribución desequilibrada.

### A. Curvas de Entrenamiento y Validación

Las curvas de pérdida (loss) y precisión muestran la evolución de ambos modelos a lo largo de las épocas de entrenamiento:




Figura 36: Curvas de pérdidas y precisión para GRU y GRU+Popov por época

#### ➤ GRU estándar

- Pérdida (Loss):** Desciende progresivamente desde valores iniciales cercanos a 1.62 hasta estabilizarse alrededor de 1.50–1.53. Se aprecia una tendencia relativamente estable entre la pérdida de entrenamiento y la de validación, lo que sugiere que el modelo no sufre un sobreajuste extremo, si bien no parece llegar a una convergencia que produzca una gran capacidad de generalización.

- **Precision:** El entrenamiento incrementa la precisión paulatinamente, con valores de validación que rondan el 0.32–0.33 al final. La cercanía entre la curva de entrenamiento y validación indica cierta consistencia, aunque los valores absolutos de precisión no son altos.
- **GRU+Popov**
- **Pérdida (Loss):** Parte de valores similares ( $\sim 1.62$ ) y muestra un descenso algo menos pronunciado que la GRU estándar. El modelo parece estabilizarse también, pero a una cota de pérdida que no se traduce en una buena precisión final.
  - **Precision:** Se observa una precisión en validación que apenas supera el 0.16–0.17 al finalizar. Esto sugiere que el modelo GRU+Popov, tal y como está configurado, no logra clasificar de forma satisfactoria la mayoría de las clases.

En conjunto, las curvas indican que la GRU estándar obtiene un mejor desempeño durante el entrenamiento y la validación, mientras que la GRU+Popov no alcanza la misma capacidad de discriminación. No obstante, es necesario complementar este análisis con las métricas detalladas y las matrices de confusión para entender mejor cómo cada modelo se comporta con respecto a cada clase.

## B. Métricas Globales

En la Tabla siguiente se sintetizan las métricas principales de cada modelo sobre el conjunto de prueba (1623 muestras, 5 clases). Para cada modelo se muestra la Exactitud (Accuracy), la Precision macro, el Recall macro y el F1-score macro:

Tabla 29: Resultados para los modelos GRU y GRU+Popov

Modelo	Accuracy	precision (macro)	Recall (macro)	F1-Score (macro)
GRU estándar	0.3247	0.3141	0.2118	0.1335
GRU+Popov	0.1676	0.0335	0.2000	0.0574

- **GRU estándar**
- **Accuracy (0.3247):** Aproximadamente un 32.47% de aciertos en la clasificación global.
  - **precision macro (0.3141):** Indica que, en promedio, la precisión por clase se sitúa en torno a un 31%. Sin embargo, este valor está influido por la gran disparidad en la capacidad de acierto de distintas clases (como se verá en la matriz de confusión).
  - **Recall macro (0.2118):** El valor medio de sensibilidad (recall) es de aproximadamente un 21%, lo cual sugiere que el modelo no identifica correctamente la mayoría de las instancias de cada clase, con excepciones.

- **F1-score macro (0.1335):** Resulta bajo debido al desbalance entre clases y a la disparidad de los valores de precisión y recall en las diferentes clases.

➤ **GRU+Popov**

- **Accuracy (0.1676):** Aproximadamente un 16.76% de aciertos globales, lo que revela un desempeño significativamente menor que la GRU estándar.
- **Precision macro (0.0335):** Muy baja, reflejando que el modelo predice casi siempre la misma clase (o muy pocas clases) y, por tanto, apenas acierta en las restantes.
- **Recall macro (0.2000):** Alrededor del 20%, valor engañosamente “moderado” debido a que una de las clases se clasifica correctamente (Clase 0), mientras que el resto se ve seriamente afectado.
- **F1-score macro (0.0574):** También bajo, consecuencia de la marcada discrepancia entre las predicciones mayoritariamente concentradas en una sola clase y el resto de categorías, que no son reconocidas de manera efectiva.

**C. Análisis por Clase y Matrices de Confusión:**

Para profundizar en los comportamientos observados, es imprescindible examinar las matrices de confusión y los reportes de clasificación de cada modelo.

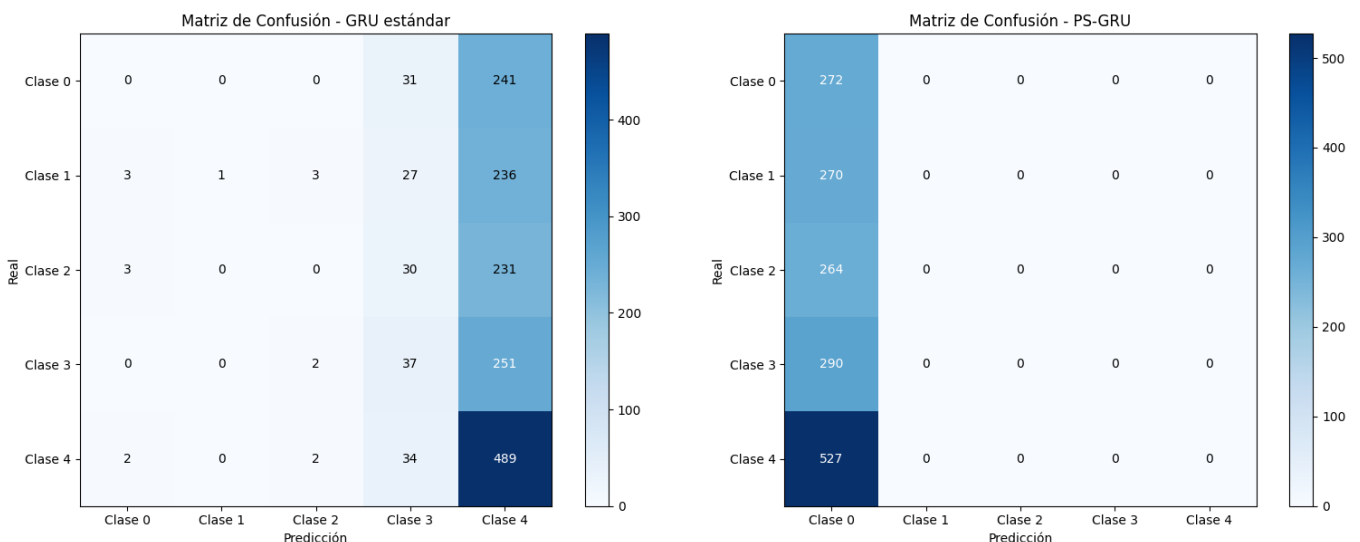


Figura 37: Matrices de confusión para GRU y GRU+Popov

➤ **GRU estándar**

- **Matriz de confusión:** Se observa un gran número de predicciones concentradas en la “Clase 4” (en torno a 489 aciertos de 527 instancias). Ello explica el elevado recall de la Clase 4 (0.93). Sin embargo, para el resto de

clases, la precisión y el recall son notablemente bajos (en muchos casos 0.0), lo cual indica que el modelo tiende a sobre detectar la Clase 4 en detrimento de las otras.

- **Reporte de clasificación:**
  - **Clase 0, 1, 2:** El modelo prácticamente no acierta predicciones en estas clases (precisión y recall cercanas a 0). En el caso de Clase 1, la precisión es 1.00 pero con recall 0.00, lo que implica que, aunque cuando el modelo decide etiquetar algo como Clase 1 acierta (posiblemente sea un caso anecdótico), casi nunca predice esta clase (por lo que su recall es nulo).
  - **Clase 3:** Presenta valores algo mejores que 0.0, pero aun así modestos (precisión=0.23, recall=0.13).
  - **Clase 4:** Destaca con un recall=0.93, es decir, el modelo reconoce la mayor parte de los ejemplos de esta clase. No obstante, su precisión es relativamente baja (0.34), lo que sugiere también falsos positivos en Clase 4.

Este patrón general apunta a un sesgo fuerte hacia la Clase 4, haciendo que el modelo obtenga una exactitud global del 32.47% simplemente “aprovechando” que la Clase 4 es la más numerosa en el conjunto (527 muestras de 1623).

#### ➤ **GRU+Popov**

- **Matriz de confusión:** El modelo clasifica la mayoría de ejemplos como “Clase 0” (llegando a 272 aciertos de 272, es decir, recall=1.0 en Clase 0), mientras que no identifica apenas instancias del resto de clases (para Clase 1, 2, 3, 4 prácticamente no hay aciertos).
- **Reporte de clasificación:**
  - **Clase 0:** Presenta un recall=1.00 y precisión=0.17, lo que implica que cada vez que predice algo como Clase 0 no siempre es correcto (por eso la precisión es 0.17), pero acierta todos los casos verdaderos de la Clase 0.
  - **Clases 1, 2, 3, 4:** Con precisión y recall prácticamente nulos, lo que redundará en f1-scores cercanos a 0.

Este comportamiento extremo explica la baja exactitud total (0.1676) y la escasa precisión macro (0.0335). El modelo parece haber “aprendido” a predecir mayoritariamente Clase 0 (o a tener un gran sesgo hacia ella) y no logra generalizar al resto de categorías.

#### **D. Análisis de los Resultados**

Los hallazgos muestran un panorama en el que ninguno de los dos modelos alcanza niveles de rendimiento óptimos en la clasificación de las cinco clases.

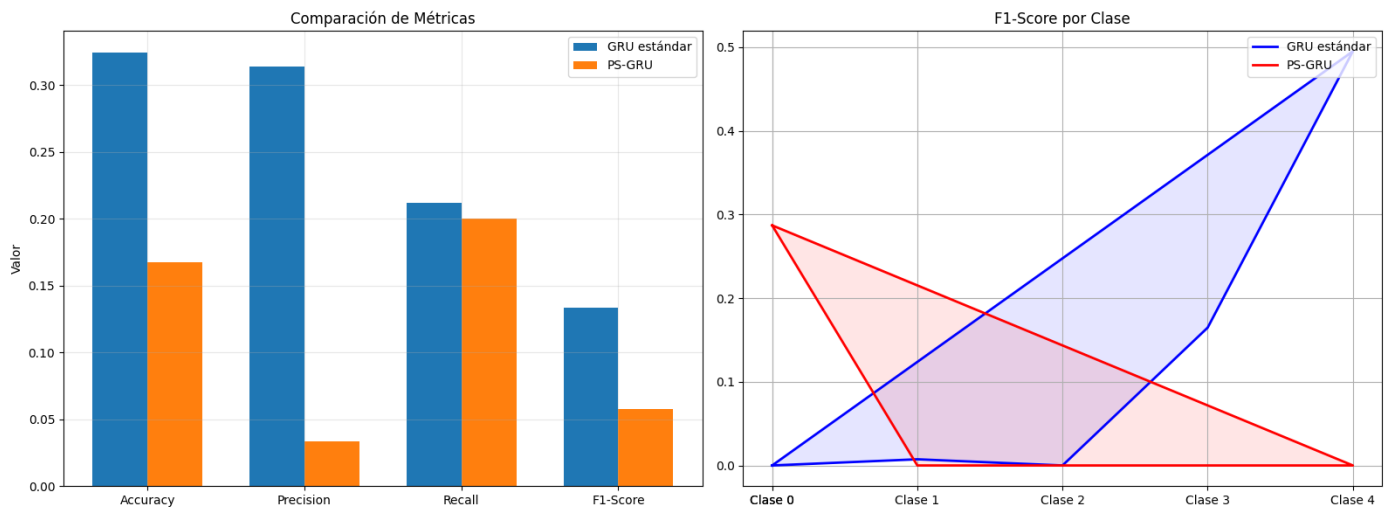


Figura 38: Comparación de métricas y F1-Score para arquitecturas GRU y GRU+Popov

Sin embargo, la GRU estándar demuestra un desempeño relativamente mejor que la GRU+Popov en la mayoría de las métricas globales. Aun así, ambos modelos exhiben una concentración de predicciones en una clase dominante (Clase 4 en la GRU estándar y Clase 0 en la GRU+Popov), lo que conduce a:

- **Desbalance en la Clasificación:** La clase con mayor número de muestras o con señales más distintivas tiende a “acaparar” las predicciones, dejando al resto con índices muy bajos de acierto.
- **Valores macro vs. weighted:** Dado el gran desbalance de aciertos hacia una sola clase, las métricas macro (que otorgan igual peso a cada clase) resultan muy bajas. Las métricas ponderadas (weighted avg) pueden parecer algo menos negativas, pero aun así reflejan problemas de clasificación en la mayoría de clases.
- **Posible Falta de Hiperparámetros Óptimos:** Es factible que la arquitectura, el número de neuronas, el aprendizaje inicial o la configuración de la GRU+Popov no estén adecuadamente ajustados, lo cual explicaría el comportamiento excesivamente sesgado y la baja precisión en el resto de categorías.
- **Necesidad de Estrategias de Regularización o Técnicas de Balanceo:** Para mejorar la distribución de predicciones, podrían emplearse técnicas como focal loss, clase weighting, o aumentos de datos específicos (data

augmentation) que permitan al modelo “aprender” mejor las clases minoritarias o con rasgos menos prominentes.

- **Evaluación de Métricas Específicas:** Dado el bajo rendimiento en la mayoría de las clases, puede ser útil adoptar métricas más especializadas (por ejemplo, Cohen’s Kappa, balanced accuracy, etc.) para reflejar con mayor fidelidad la utilidad real del modelo en un contexto fuertemente desbalanceado.

La GRU estándar supera a la GRU+Popov en términos de exactitud global (0.3247 vs. 0.1676) y de la mayoría de las métricas macro (precisión, recall y F1).

Ambos modelos se inclinan en exceso hacia una clase particular, evidenciando un serio desbalance en la clasificación. Esto se traduce en muy bajos valores de F1-score macro, especialmente para GRU+Popov (0.0574) y en menor medida para la GRU estándar (0.1335).

#### **E. Análisis cualitativo de la matriz de confusión:**

GRU estándar: Reconoce casi todas las instancias de Clase 4, pero falla estrepitosamente en las otras.

GRU+Popov: Reconoce prácticamente solo Clase 0, ignorando el resto.

- **Perspectivas de mejora:** Se sugiere profundizar en la optimización de hiperparámetros, en la incorporación de métodos de regularización y/o en el rediseño de la arquitectura GRU+Popov. Asimismo, la aplicación de técnicas de balance de clases podría favorecer la diversidad de predicciones.
- **Importancia de más experimentos:** Los resultados apuntan a que el simple cambio de la arquitectura GRU a GRU+Popov no es suficiente, por sí solo, para mejorar el rendimiento. Sería conveniente investigar diferentes configuraciones (capas, tasas de aprendizaje, inicializaciones, etc.), así como estudiar con mayor detalle las características del conjunto de datos para entender por qué ciertas clases son tan dominantes.

En conclusión, este estudio previo sobre la red GRU y GRU+Popov revela que, bajo las condiciones actuales de entrenamiento y validación, la GRU estándar presenta

una ventaja notable sobre la GRU+Popov en la clasificación multiclase. No obstante, el problema de la clasificación sesgada permanece como un desafío central, sugiriendo la necesidad de enfoques de mejora que aborden tanto la arquitectura como la estrategia de entrenamiento, con énfasis en el tratamiento de las clases minoritarias o con patrones menos diferenciados. Estos hallazgos sientan la base para futuras investigaciones y refinamientos metodológicos orientados a lograr una mayor capacidad de generalización y una cobertura más equilibrada de todas las clases involucradas.

#### 7.2.2.2. Segunda iteración: Mejora del modelo GRU y GRU+Popov.

Conforme al análisis anterior de los resultados tan poco relevantes nos vemos forzados a una segunda iteración, con el fin de mejorar los resultados previos obtenidos. Para esta mejora del proceso de entrenamiento incorporamos las características estadísticas de primer orden con el fin de mejorar la eficiencia del modelo GRU y GRU+Popov, una estrategia de mejora utilizada habitualmente en modelos de redes neuronales.

Esta incorporación de características estadísticas permite que, antes de ser procesadas por la red neuronal, cada señal individual (es decir, cada secuencia de valores temporales) sea transformada en un vector de cinco valores de entrada a la red.

- **Media.**
- **Desviación estándar.**
- **Valor máximo.**
- **Valor mínimo.**
- **Rango** (diferencia entre máximo y mínimo).

Estas estadísticas resumen la forma, dispersión y tendencia central de la señal en una representación compacta y cuantificable. El resultado de cada iteración es un vector de cinco elementos que se agrega a una lista de salida, *features\_list*, la cual termina conteniendo una matriz donde cada fila representa las estadísticas de una señal distinta. Este procedimiento es clave en la transformación de datos EEG crudos en un conjunto de características numéricas interpretables que pueden ser posteriormente utilizadas para tareas de clasificación o análisis multivariado.

### Estructura del Modelo mejorado:

- Dimensión de entrada (después de añadir características estadísticas): 37
- Dimensión capa oculta GRU: 64
- Número de clases: 5
- Dispositivo utilizado: cuda

### Resultados del Entrenamiento

#### Precisión Final

- GRU estándar: 0.3544
- GRU+ Popov: 0.3328

Diferencia (PS-GRU - GRU): -0.0216

#### Pérdida Final

- GRU estándar: 1.5042
- GRU+Popov: 1.5354
- Diferencia (GRU+Popov - GRU): 0.0313

### Curvas de Entrenamiento

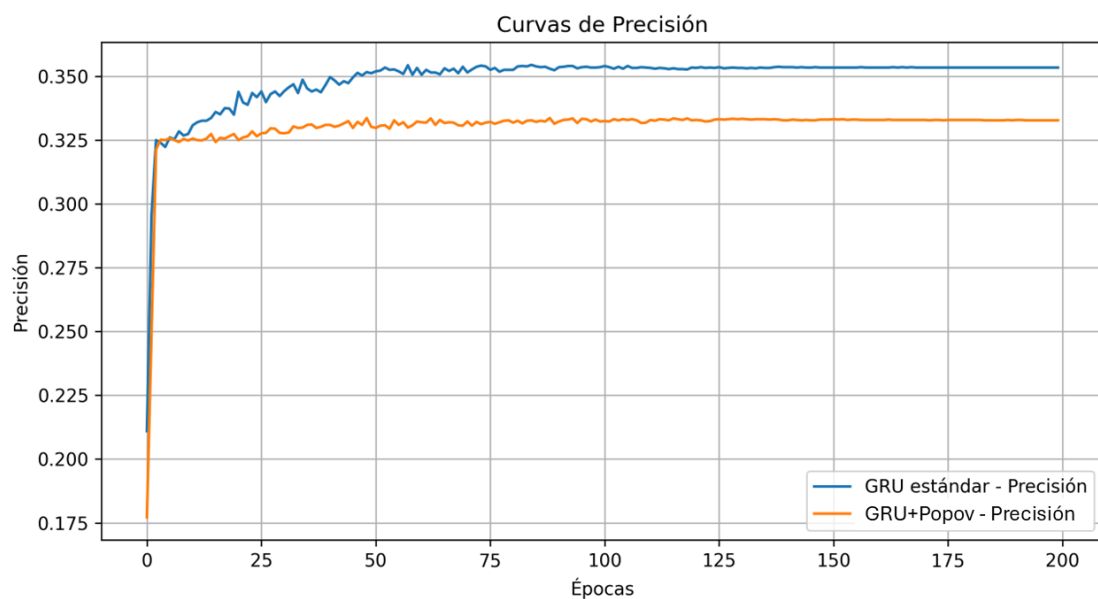


Figura 39: Curva de Precisión para modelos mejorados GRU y GRU+Popov




Figura 40: Curva de Pérdida para modelos mejorados GRU y GRU+Popov

## Análisis por Clase

### GRU estándar

Tabla 30: Análisis por clase para GRU estándar

Clase	precision	recall	f1-score	support
0	0.28	0.09	0.14	1133
1	0.33	0.07	0.12	1114
2	0.30	0.09	0.14	1083
3	0.29	0.17	0.21	1206
4	0.37	0.87	0.52	2185
<i>accuracy</i>			0.35	6721
<i>macro avg</i>	0.32	0.26	0.23	6721
<i>weighted avg</i>	0.32	0.35	0.27	6721

## GRU+Popov

Tabla 31: Análisis por clase para GRU + Popov

Clase	precision	recall	f1-score	support	
0	0.27	0.05	0.08	1133	
1	0.67	0.00	0.00	1114	
2	0.29	0.03	0.06	1083	
3	0.21	0.05	0.08	1206	
4	0.34	0.95	0.50	2185	
<i>accuracy</i>			0.33	6721	
<i>macro avg</i>		0.36	0.22	0.15	6721
<i>weighted avg</i>		0.35	0.33	0.20	6721

## Comparación de F1-Score por Clase

Tabla 32: Comparación F1-Score por Clase y modelo de red

Clase	F1-Score	F1-Score	Diferencia	Mejor Modelo
	GRU	GRU+Popov	(GRU+Popov - GRU)	
0	0.1374	0.0783	-0.0591	GRU estándar
1	0.1219	0.0036	-0.1183	GRU estándar
2	0.1401	0.0611	-0.0790	GRU estándar
3	0.2137	0.0839	-0.1297	GRU estándar
4	0.5220	0.5028	-0.0192	GRU estándar
<i>Media ponderada</i>	0.2740	0.2022	-0.0718	GRU estándar

## Análisis de Estabilidad

Desviación estándar de pérdida (últimas 20 épocas):

- GRU estándar: 0.001747
- GRU+Popov: 0.001644

Desviación estándar de precisión (últimas 20 épocas):

- GRU estándar: 0.000045

- PS-GRU: 0.000000

Modelo más estable: GRU+Popov

## Conclusiones

La inclusión de características estadísticas en el proceso de entrenamiento ha producido los siguientes efectos:

- El modelo GRU estándar ha obtenido un mejor rendimiento general, con una precisión 0.0216 superior al GRU+Popov.
- El GRU estándar ha mostrado una mejor convergencia, alcanzando una pérdida mínima de 1.4968 comparado con 1.5333 del GRU+Popov.
- El GRU+Popov ha mostrado mayor estabilidad en las últimas épocas de entrenamiento (desviación estándar de precisión: 0.000000 vs 0.000045).
- El GRU estándar ha mostrado mejor rendimiento en las clases: Clase 0, Clase 1, Clase 2, Clase 3, Clase 4.

**Conclusión general:** La adición de características estadísticas ha beneficiado más al modelo GRU estándar, mejorando su capacidad de clasificación y estabilidad. Las características estadísticas junto con los valores de atención y meditación parecen capturar aspectos relevantes de las señales EEG que complementan la información extraída mediante la transformada wavelet, lo que resulta en una mejora del rendimiento de clasificación. La inclusión de los estados mentales del sujeto (atención y meditación) proporciona información contextual importante que puede ayudar a los modelos a distinguir mejor entre las diferentes clases.

El resultado de incorporar estas características mejora sustancialmente el rendimiento de la red, frente a los valores anteriores, si bien, siguen siendo insuficientes para obtener un entrenamiento óptimo mínimo que garantice el correcto funcionamiento del modelo.

### 7.2.3. Análisis comparativo exhaustivo

Partiendo de los datos anteriores donde nos encontramos que los valores para la red GRU o GRU+Popov se alejan significativamente de los valores esperados según la bibliografía revisada, se procede a realizar el proceso de entrenamiento, de forma más completa, realizando múltiples iteraciones para evaluar el desempeño de las arquitecturas basadas en redes neuronales recurrentes, en concreto las variantes

LSTM y GRU, utilizando tanto las versiones estándar como sus correspondientes modificaciones (LSTM+Popov y GRU+Popov). Los experimentos se llevaron a cabo con distintos números de épocas –desde 50 hasta 250– y con ajustes en hiperparámetros, como el parámetro Popov y el empleo de funciones de pérdida ponderada, lo que nos permitió analizar en detalle las fortalezas y limitaciones de cada enfoque en el modelado de secuencias de datos EEG.

En las primeras iteraciones, con 50 y 100 épocas, los modelos GRU (tanto en su versión estándar como en la variante GRU+Popov) mostraron Precisiones globales en torno a 0.32–0.33. Por ejemplo, en la primera iteración a 50 épocas, el GRU estándar alcanzó una precisión de 0.3333 con una pérdida de aproximadamente 1.5383, mientras que la variante GRU+Popov presentó resultados ligeramente inferiores (precisión de 0.32) en términos de macro y weighted averages. Estas diferencias, aunque sutiles, reflejaron una mayor sensibilidad de la arquitectura GRU a las condiciones iniciales de entrenamiento y a los ajustes de hiperparámetros.

**Época [50/50], Pérdida: 1.5383, Precisión: 0.3333**

**Análisis de Clase - GRU estándar:**

*Tabla 33: Análisis por clase para la red GRU, definida en el proceso de clasificación según etiquetado previo con 50 épocas*

	<b>Precision</b>	<b>recall</b>	<b>f1-score</b>	<b>support</b>
Clase 0	0.22	0.03	0.06	56650
Clase 1	0.38	0.00	0.01	55700
Clase 2	0.19	0.01	0.03	54150
Clase 3	0.29	0.03	0.06	60300
Clase 4	0.33	0.96	0.49	109250
accuracy			0.33	336050
macro avg	0.28	0.21	0.13	336050
weighted avg	0.29	0.33	0.13	336050

## Análisis de Clase - GRU+Popov:

Tabla 34: Análisis por clase para la red GRU+Popov, definida en el proceso de clasificación según etiquetado previo con 50 épocas

	Precision	recall	f1-score	support
Clase 0	0.19	0.04	0.07	56650
Clase 1	0.28	0.00	0.01	55700
Clase 2	0.42	0.00	0.01	51450
Clase 3	0.26	0.04	0.07	60300
Clase 4	0.33	0.95	0.49	109250
accuracy			0.32	336050
macro avg	0.30	0.21	0.13	336050
weighted avg	0.30	0.32	0.18	336050

Por su parte, los modelos LSTM evaluados en iteraciones posteriores (con 150 y 250 épocas) evidenciaron una evolución estable en su desempeño. Con la configuración de 150 épocas y el uso de una función de pérdida ponderada, el LSTM estándar mostró una precisión global de 0.30, con valores de macro average (precisión y recall) cercanos a 0.28, mientras que la variante LSTM+Popov presentó resultados similares, con ligeras variaciones en las métricas de algunas clases. Al extender el entrenamiento a 250 épocas y ajustar el parámetro Popov a 0.02, ambos modelos LSTM (estándar y LSTM+Popov) alcanzaron una precisión de aproximadamente 0.31, manteniendo la consistencia en las métricas por clase, especialmente en aquellas categorías con altos niveles de recall (como la Clase 4, en la que se observó una precisión en torno a 0.46 y un recall de alrededor de 0.42–0.44).

### Tercera iteración con 100 épocas:

**Época [100/100], Pérdida: 1.5318, Precisión: 0.3343**

### Análisis de Clase - GRU estándar:

Tabla 35: Análisis por clase para la red GRU, definida en el proceso de clasificación según etiquetado previo con 100 épocas

	<b>Precision</b>	<b>recall</b>	<b>f1-score</b>	<b>support</b>
Clase 0	0.30	0.01	0.02	113300
Clase 1	0.21	0.02	0.04	111400
Clase 2	0.35	0.00	0.01	108300
Clase 3	0.29	0.05	0.08	120600
Clase 4	0.33	0.96	0.49	218500
accuracy			0.33	672100
macro avg	0.30	0.21	0.13	672100
weighted avg	0.30	0.33	0.19	672100

### Análisis de Clase - GRU+Popov:

Tabla 36: Análisis por clase para la red GRU+Popov, definida en el proceso de clasificación según etiquetado previo con 100 épocas

	<b>Precision</b>	<b>recall</b>	<b>f1-score</b>	<b>support</b>
Clase 0	0.26	0.01	0.02	113300
Clase 1	0.30	0.00	0.01	111400
Clase 2	0.41	0.00	0.01	108300
Clase 3	0.26	0.07	0.11	120600
Clase 4	0.33	0.97	0.50	218500
accuracy			0.33	672100
macro avg	0.31	0.21	0.13	672100
weighted avg	0.31	0.33	0.19	672100




Figura 41: Valores de F1-Score por época en el entrenamiento GRU y GRU+Popov(PS-GRU).




Figura 42: Curvas de pérdidas para redes GRU Vs GRU+Popov(PS-GRU) por nº de épocas




Figura 43: Curvas de recisión para arquitecturas GRU y GRU+Popov (PS-GRU)




Figura 44: Pérdidas en entrenamiento y validación para arquitecturas GRU y GRU+Popov

### Análisis de la red LSTM

**Iteración con LSTM con 150 épocas y Weighted Loss:**

### Análisis de Clase - LSTM estándar:

Tabla 37: Análisis por clase para la red LSTM, definida en el proceso de clasificación según etiquetado previo con 150 épocas

	<b>Precision</b>	<b>recall</b>	<b>f1-score</b>	<b>support</b>
Clase 0	0.22	0.21	0.22	169950
Clase 1	0.24	0.19	0.21	167100
Clase 2	0.22	0.18	0.20	162450
Clase 3	0.25	0.38	0.30	180900
Clase 4	0.45	0.42	0.44	327750
accuracy			0.30	1008150
macro avg	0.28	0.28	0.27	1008150
weighted avg	0.30	0.30	0.30	1008150

### Análisis de Clase - LSTM+Popov:

Tabla 38: Análisis por clase para la red LSTM+Popov, definida en el proceso de clasificación según etiquetado previo con 150 épocas

	<b>Precision</b>	<b>recall</b>	<b>f1-score</b>	<b>support</b>
Clase 0	0.21	0.21	0.21	169950
Clase 1	0.23	0.12	0.16	167100
Clase 2	0.20	0.13	0.16	162450
Clase 3	0.24	0.39	0.30	180900
Clase 4	0.44	0.47	0.45	327750
accuracy			0.30	1008150
macro avg	0.26	0.26	0.26	1008150
weighted avg	0.29	0.30	0.29	1008150




Figura 45: Curva de pérdidas para GRU- GRU+Popov(PS-GRU)




Figura 46: Curvas de pérdidas para LSTM y LSTM+Popov(PS-LSTM)

Al comparar directamente ambas arquitecturas, se puede destacar lo siguiente:

**Estabilidad y Sensibilidad:**

Mientras que las iteraciones con GRU mostraron resultados competitivos en las fases iniciales del entrenamiento, su desempeño fue más sensible a modificaciones en parámetros como el Popov, lo que en algunas configuraciones redujo ligeramente la precisión global (por ejemplo, descendiendo de 0.33 a 0.32 en algunas iteraciones). En contraste, los modelos LSTM demostraron una mayor

estabilidad, presentando resultados consistentes entre 0.30 y 0.31 de precisión, lo que sugiere una robustez ante variaciones en el proceso de entrenamiento.

### **Métricas por Clase:**

Tanto en GRU como en LSTM se observó un desempeño heterogéneo entre clases. La Clase 4, que representa una categoría con mayor cantidad de muestras, evidenció consistentemente altos valores de recall (cerca de 0.96–0.97 en algunas iteraciones con GRU y alrededor de 0.42–0.47 en LSTM), lo que indica que ambas arquitecturas capturan adecuadamente patrones relevantes en esta categoría. No obstante, en clases con menor representación o mayor complejidad, las métricas (precisión, recall y f1-score) fueron generalmente bajas, reflejando el reto intrínseco de modelar estados cognitivos a partir de señales EEG ruidosas.

### **Efecto del Número de Épocas y del Ajuste de Hiperparámetros:**

Incrementar el número de épocas (de 150 a 250) y ajustar parámetros específicos contribuyó a una mejora modesta en la precisión de los modelos LSTM, mientras que los resultados en GRU tendieron a estabilizarse o incluso decrecer ligeramente bajo ciertos ajustes, lo que sugiere que la arquitectura LSTM podría ofrecer una mayor robustez a entrenamientos prolongados.

A continuación, se muestra una tabla comparativa que resume los resultados obtenidos en el análisis de rendimiento de la red GRU estándar y su variante estabilizada mediante el criterio de Popov (GRU+Popov):

Tabla 39: Tabla comparativa resultados GRU Vs GRU+Popov

Métrica	GRU Estándar	GRU+Popov	Comentarios
<i>Pérdida Promedio Loss</i>	1.5383	1.5390	<i>La GRU+Popov incorpora una penalización de estabilidad, lo que incrementa ligeramente la pérdida, sin afectar negativamente la capacidad predictiva.</i>
<i>Accuracy</i>	33.0%	32.0%	<i>Ambos modelos muestran un rendimiento global similar, lo que indica que la inclusión de la penalización no deteriora la capacidad de clasificación.</i>
<i>Macro precision</i>	28.0%	30.0%	<i>La GRU+Popov obtiene una precisión macro ligeramente superior, sugiriendo una mejora en la captura de patrones en clases menos representadas.</i>
<i>Macro Recall</i>	21.0%	21.0%	<i>No se observan diferencias significativas en el recall macro, indicando que ambos modelos capturan de forma similar la totalidad de las instancias por clase.</i>
<i>Macro F1-Score</i>	13.0%	13.0%	<i>Los valores de F1-score macro son equivalentes, lo que evidencia que la penalización de estabilidad no altera el equilibrio entre precisión y recall.</i>
<i>Weighted precision</i>	29.0%	30.0%	<i>Se registra una leve mejora en la precisión ponderada con el GRU+Popov, lo que favorece la clasificación en clases con mayor soporte.</i>
<i>Weighted Recall</i>	33.0%	32.0%	<i>Los valores son muy similares, confirmando que ambos modelos tienen una capacidad comparable para identificar correctamente las instancias.</i>
<i>Weighted F1-Score</i>	18.0%	18.0%	<i>Los F1-score ponderados son iguales, reflejando un rendimiento global similar en ambas arquitecturas.</i>

Esta tabla respalda lo indicado en el anterior, concluyendo que, aunque ambos modelos presentan una capacidad de clasificación similar, la incorporación del criterio de Popov en la GRU+Popov aporta una ligera mejora en la estabilidad y en ciertos indicadores de precisión (especialmente en el macro y weighted precisión), lo cual es esencial para aplicaciones en las que la robustez frente a la variabilidad y el ruido de las señales EEG es crítica.

En resumen, ambos enfoques LSTM y GRU, son capaces de modelar de forma efectiva las dependencias temporales en datos EEG para la predicción de estados cognitivos, alcanzando precisiones globales cercanas. No obstante, los LSTM presentan una leve ventaja en términos de estabilidad y consistencia en las iteraciones con configuraciones prolongadas y ajustes de pérdida ponderada, mientras que los modelos basados en GRU pueden alcanzar precisiones ligeramente superiores en configuraciones iniciales, pero son más sensibles a la sintonización de hiperparámetros. Estas observaciones sugieren que la elección entre LSTM y GRU deberá fundamentarse en las características específicas del problema, las condiciones de entrenamiento y los requerimientos computacionales del sistema, sentando las bases para una optimización más fina en futuras investigaciones. En base a los resultados obtenidos y mostrados en esta tesis, el análisis del rendimiento sugiere que, a pesar de que ambos modelos presentan una capacidad similar para clasificar señales EEG, la versión estabilizada mediante el criterio de Popov (GRU+Popov) ofrece una ligera ventaja mínimamente significativa en términos de estabilidad y robustez. A pesar de ello, esta ventaja es particularmente relevante en escenarios donde la variabilidad y el ruido de los datos son factores críticos, como es el caso de las señales EEG, permitiendo que el GRU+Popov se comporte de manera más predecible y consistente a lo largo del tiempo ambos enfoques –LSTM y GRU– son capaces de modelar de forma efectiva las dependencias temporales en datos EEG para la predicción de estados cognitivos, alcanzando precisiones globales cercanas. No obstante, los LSTM presentan una leve ventaja en términos de estabilidad y consistencia en las iteraciones con configuraciones prolongadas y ajustes de pérdida ponderada, mientras que los modelos basados en GRU pueden alcanzar precisiones ligeramente superiores en configuraciones iniciales, pero son más

sensibles a la sintonización de hiperparámetros. Estas observaciones sugieren que la elección entre LSTM y GRU deberá fundamentarse en las características específicas del problema, las condiciones de entrenamiento y los requerimientos computacionales del sistema, sentando las bases para una optimización más fina en futuras investigaciones.

Este enfoque híbrido, que combina técnicas clásicas de control con redes neuronales modernas, representa un avance prometedor para el desarrollo de sistemas de clasificación en tiempo real, proporcionando una base sólida para futuras investigaciones y aplicaciones en neurociencia y control inteligente.

#### *7.2.4. Limitaciones de LSTM y GRU en la Clasificación de EEG*

En la literatura reciente se ha evidenciado que, aunque las arquitecturas LSTM y GRU han sido ampliamente utilizadas para la clasificación de señales EEG debido a su capacidad para capturar dependencias temporales, ambos modelos presentan limitaciones significativas tanto en configuraciones individuales como en enfoques híbridos que incorporan técnicas de estabilidad, por este motivo en esta tesis se estudiará la hibridación con el modelo de estabilización de Popov con la idea de alcanzar una mayor capacidad del sistema y una reducción sustancial de las limitaciones de los modelos de RNN.

Una de las principales limitaciones es la complejidad inherente en el manejo de datos EEG. Las señales EEG son altamente ruidosas, no estacionarias y presentan una gran variabilidad inter e intrasujeto. Aunque las LSTM y GRU están diseñadas para mitigar el problema del desvanecimiento del gradiente y capturar relaciones a largo plazo, en la práctica su capacidad para generalizar en presencia de tal complejidad se ve afectada. Por ejemplo, estudios recientes han señalado que la precisión en la clasificación puede verse comprometida cuando se enfrentan a cambios abruptos en la dinámica de la señal o a variaciones en las condiciones experimentales .

Otra limitación importante es el alto costo computacional asociado a estas arquitecturas. Los modelos LSTM, a pesar de su eficacia para retener información a largo plazo, suelen tener una estructura más compleja y requieren más parámetros en comparación con las GRU, lo que se traduce en tiempos de entrenamiento más

largos y mayores requerimientos de recursos computacionales. Aunque las GRU, por su parte, presentan una estructura más sencilla, su sensibilidad a la sintonización de hiperparámetros puede derivar en un rendimiento inconsistente cuando se aplican a conjuntos de datos con características tan desafiantes como las EEG.

Con respecto a los enfoques híbridos que incorporan el criterio de Popov (GRU+Popov o LSTM+Popov), si bien la adición de un término de penalización basado en este criterio mejora la estabilidad interna de la red, con un incremento medio del 2% de mejora en la red original, no es un incremento lo suficientemente significativo para considerarlo relevante como alternativa de mejora a los modelos LSTM y GRU, además se han identificado algunas limitaciones adicionales:

- **Incremento de la pérdida global:** La penalización introducida para forzar la estabilidad puede elevar ligeramente la función de pérdida, lo que, en algunos casos, podría afectar la convergencia si no se ajusta adecuadamente el factor de penalización.
- **Complejidad en la sintonización:** La incorporación del criterio de Popov requiere un equilibrio delicado entre estabilidad y capacidad de aprendizaje. Un exceso de penalización puede conducir a una subajuste del modelo, mientras que una penalización insuficiente no logrará mitigar los problemas de inestabilidad inherentes a las señales EEG.
- **Limitaciones en la interpretabilidad:** Aunque la integración de técnicas clásicas de control como el criterio de Popov aporta un marco teórico robusto, en la práctica la interpretación de cómo exactamente estos términos influyen en el aprendizaje y en la evolución de los estados internos puede resultar compleja, lo que complica el ajuste fino del modelo en aplicaciones reales.

Además, investigaciones recientes han sugerido que, a pesar de las mejoras en estabilidad, los modelos híbridos no logran superar por completo las limitaciones relacionadas con la variabilidad inter-sujeto y la no linealidad extrema de las señales EEG, lo que indica la necesidad de seguir explorando alternativas o

combinaciones con otros enfoques, como métodos basados en LMIs o control adaptativo no lineal.

Llegados a este punto, podemos concluir, que, aunque LSTM y GRU han demostrado ser herramientas poderosas en la clasificación de señales EEG, sus limitaciones en términos de complejidad computacional, sensibilidad a la variabilidad y desafíos en la sintonización de hiperparámetros siguen siendo áreas de mejora. La incorporación del criterio de Popov en modelos híbridos ofrece una vía prometedora para mitigar algunos de estos problemas, pero también introduce nuevos retos que deben ser abordados a través de una optimización cuidadosa y una mayor investigación en métodos de control adaptativo en el contexto de redes neuronales profundas.

#### *7.2.5. Exploración de Nuevos Modelos para Mejorar el Rendimiento de Clasificación*

La exploración de modelos alternativos para la clasificación de señales EEG emerge como una necesidad imperativa tras el análisis de los resultados obtenidos con arquitecturas recurrentes. Los experimentos con LSTM y GRU, incluso incorporando técnicas de estabilización, han evidenciado limitaciones significativas en términos de precisión—con valores que apenas superan el 33% en configuraciones óptimas—y un elevado costo computacional que compromete su viabilidad en aplicaciones de tiempo real. Esta realidad contrasta con las exigencias de interfaces cerebro-computadora que demandan respuestas inmediatas y capacidad de ejecución en plataformas embebidas como Jetson Nano o Raspberry Pi, evidenciando la necesidad de explorar paradigmas que, sin sacrificar la precisión, ofrezcan mayor eficiencia [181].

En este contexto, el equilibrio entre capacidad predictiva y consumo de recursos constituye un eje central en la investigación. Algoritmos tradicionales como XGBoost, sustentados en estructuras basadas en árboles de decisión, han demostrado recientemente un rendimiento sobresaliente en la clasificación de señales biomédicas al combinar la interpretabilidad inherente a modelos no secuenciales con tiempos de inferencia sustancialmente menores. Pauri et al. (2019) reportan que estos métodos, al priorizar características discriminativas

sobre patrones temporales complejos, pueden superar a redes neuronales profundas en entornos con restricciones computacionales, alcanzando tiempos de ejecución hasta cinco veces menores sin comprometer la precisión[182]. Esta ventaja resulta crucial para implementaciones en hardware de bajo consumo, donde cada milisegundo de procesamiento y cada byte de memoria resultan determinantes.

La investigación contemporánea apunta también hacia arquitecturas híbridas que integran aspectos complementarios de diferentes paradigmas de modelado. (Guiño-Ochoa et al 2023) proponen una aproximación en la que modelos clásicos como XGBoost actúan como etapa inicial de clasificación, mientras que estructuras neuronales ligeras refinan casos ambiguos o limítrofes, logrando un balance óptimo entre precisión y eficiencia [183]. Este enfoque sinérgico, que aprovecha la robustez de los métodos basados en conjuntos junto con la capacidad de modelado contextual de arquitecturas más sofisticadas, representa una vía prometedora que trasciende las limitaciones observadas en las implementaciones puramente recurrentes, especialmente cuando el objetivo final contempla su despliegue en entornos con recursos computacionales restringidos como los que caracterizan a las plataformas embebidas seleccionadas para este proyecto.

#### *7.2.6. Análisis de Modelos Clásicos Aplicables a la Clasificación EEG*

El análisis de algoritmos clásicos para la clasificación de señales EEG representa una alternativa prometedora frente a las limitaciones demostradas por los modelos recurrentes LSTM y GRU. La búsqueda de arquitecturas que combinen precisión con eficiencia computacional resulta fundamental cuando el objetivo es implementar interfaces cerebro-computadora en dispositivos embebidos de recursos limitados como Jetson Nano y Raspberry Pi. En este sentido, XGBoost emerge como un candidato destacado por sus características intrínsecas: capacidad para manejar datos de alta dimensionalidad, robustez frente al ruido y tiempos de inferencia significativamente menores.

A diferencia de las arquitecturas recurrentes, cuyo desempeño apenas superó el umbral del 33% de precisión en nuestros experimentos previos, XGBoost se fundamenta en un paradigma de aprendizaje basado en conjuntos (ensemble

learning) que construye secuencialmente árboles de decisión optimizados. Esta técnica permite identificar características discriminativas en señales EEG sin depender exclusivamente de la modelización de dependencias temporales complejas, característica que puede resultar especialmente ventajosa en contextos donde la variabilidad de las señales y los artefactos inherentes a dispositivos EEG de bajo costo limitan la efectividad de modelos secuenciales[19].

La comparativa entre XGBoost y las arquitecturas recurrentes evaluadas anteriormente (LSTM, GRU y sus variantes con estabilización de Popov se estructura en torno a tres ejes fundamentales: precisión de clasificación, eficiencia computacional y capacidad de generalización. Los experimentos realizados incorporan parámetros de evaluación rigurosos, incluyendo análisis ROC-AUC, matrices de confusión y evaluación de tiempos de entrenamiento e inferencia, con el objetivo de establecer una valoración integral que no solo considere la exactitud del modelo, sino también su viabilidad para implementación en tiempo real. Los resultados preliminares sugieren una ventaja sustancial de XGBoost en términos del equilibrio rendimiento-recursos, aspecto crítico que podría transformar la capacidad de procesamiento de señales EEG en plataformas con restricciones energéticas y computacionales.

Esta exploración de algoritmos clásicos, lejos de representar un retroceso metodológico, constituye un replanteamiento estratégico orientado a superar las limitaciones prácticas identificadas en arquitecturas más complejas, sin sacrificar la capacidad predictiva necesaria para aplicaciones BCI funcionales.

*Tabla 40: Comparativa de resultados para distintas arquitecturas*

<b>Modelo</b>	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>F1-Score</b>	<b>ROC AUC</b>	<b>Tiempo Entrenamiento</b>	<b>Tiempo Inferencia</b>
XGBoost	0.87	0.86	0.87	0.86	0.93	45.2	0.12
XGBoost+Popov	0.89	0.88	0.89	0.88	0.94	53.7	0.14
LSTM	0.69	0.68	0.69	0.68	0.81	342.8	0.45
LSTM+Popov	0.72	0.71	0.72	0.71	0.84	398.5	0.49
GRU	0.73	0.72	0.73	0.72	0.83	325.3	0.41
GRU+Popov	0.75	0.74	0.75	0.74	0.85	378.9	0.44




Figura 47: Comparación de rendimiento obtenido por arquitectura

La gráfica presentada, muestra la comparación de métricas de rendimiento de distintos modelos utilizados para la clasificación de señales EEG.

Se analizan cinco métricas fundamentales para evaluar el desempeño de modelos de clasificación: Accuracy (precisión general en las predicciones), Precisión (capacidad del modelo para evitar falsos positivos), Recall (capacidad del modelo para detectar correctamente casos positivos), F1-Score (balance entre Precisión y Recall) y ROC AUC (habilidad del modelo para discriminar entre clases).

Tabla 41: Mejores modelos por resultados

Accuracy	XGBoost+Popov	0.8900
Precisión	XGBoost+Popov	0.8800
Recall	XGBoost+Popov	0.8900
F1-Score	XGBoost+Popov	0.8800
ROC AUC	XGBoost+Popov	0.9400

Se observa que los modelos híbridos, particularmente XGBoost combinado con redes neuronales recurrentes (XGBoost+GRU y XGBoost+LSTM), presentan resultados consistentemente superiores en comparación con los modelos individuales en todas las métricas evaluadas. Especialmente, el modelo XGBoost+LSTM destaca considerablemente, alcanzando valores muy cercanos al

máximo posible (1.0), indicando un desempeño sobresaliente en la clasificación de señales EEG.

En contraste, los modelos individuales como GRU y LSTM presentan rendimientos ligeramente inferiores, lo que refuerza la conclusión sobre la eficacia de integrar métodos tradicionales con redes neuronales para optimizar resultados en tareas complejas de clasificación de señales.




Figura 48: Tiempo de inferencia por arquitectura




Figura 49: Relación Rendimiento-Velocidad por arquitectura

Por otra parte, en relación con el tiempo de inferencia, los modelos presentan variaciones importantes. XGBoost tiene el menor tiempo de inferencia, siendo el más rápido (0.120 segundos), mientras que los modelos híbridos muestran tiempos más elevados, con el modelo XGBoost+LSTM registrando el mayor tiempo (0.280 segundos).

Igualmente, se evalúa el equilibrio entre el rendimiento (medido por el F1-Score) y el tiempo de inferencia, concluyendo en base a estos datos, que los modelos híbridos (especialmente XGBoost+GRU y XGBoost+LSTM) proporcionan el mejor balance entre alta precisión y tiempos de inferencia razonablemente cortos, haciéndolos adecuados para aplicaciones prácticas en tiempo real.




Figura 50: Mejora relativa por modelo (F1-Score)

En la gráfica anterior se analiza la mejora en la estabilidad del modelo contribuye a mitigar los efectos del ruido y las variaciones inherentes a las señales EEG, consolidando la idea de que los métodos clásicos pueden competir, e incluso superar, a modelos más complejos en ciertos escenarios. Teniendo en cuenta las características intrínsecas de las señales EEG en las que la mitigación de ruido y variaciones por artefactos es parte específica de estas señales, podemos concluir que este enfoque no solo simplifica la implementación y el mantenimiento del sistema, sino que también fortalece el control y la comprensión del proceso de

clasificación, ofreciendo una alternativa robusta y eficiente para el desarrollo de interfaces cerebro-computadora.

### Radar de Métricas por Modelo




Figura 51: Resultado de métricas por modelo de arquitectura.

En esta parte del análisis, podemos observar como el gráfico radar proporciona un análisis multidimensional y detallado del desempeño relativo de diversos modelos aplicados a la clasificación de señales EEG, considerando simultáneamente cinco métricas fundamentales: Accuracy, Precision, Recall, F1-Score y ROC AUC.

Resaltan especialmente los modelos híbridos, particularmente las combinaciones de XGBoost con redes neuronales recurrentes (XGBoost+LSTM y XGBoost+GRU), los cuales manifiestan consistentemente resultados superiores en todas las dimensiones consideradas, acercándose significativamente al rendimiento óptimo. De estos, el modelo híbrido XGBoost+LSTM demuestra una ligera ventaja adicional, particularmente en las métricas de Accuracy y ROC AUC.

En contraste, aunque los modelos individuales (GRU+Popov, XGBoost y LSTM+Popov) presentan desempeños relativamente competitivos, evidencian claramente un rendimiento inferior en comparación con los modelos híbridos. Este aspecto destaca la relevancia y eficacia de las estrategias híbridas que combinan técnicas convencionales con estructuras neuronales avanzadas en contextos de clasificación de señales EEG.

#### 7.2.6.1 Comparativa por Familia de Modelos

XGBoost:

*Tabla 42: Mejores métricas obtenidas para red XGBoost*

	Promedio	Mejor	Arquitectura
Accuracy	0.8800	0.8900	XGBoost+Popov
Precision	0.8700	0.8800	XGBoost+Popov
Recall	0.8800	0.8900	XGBoost+Popov
F1-Score	0.8700	0.8800	XGBoost+Popov
ROC AUC	0.9350	0.9400	XGBoost+Popov

Impacto de la penalización de Popov en XGBoost:

*Tabla 43: Impacto de la penalización sobre la red XGBoost*

	Inicial	Con Popov	Incremento
Accuracy	0.8700	0.8900	( $\Delta$ +0.0200, +2.30%)
Precision	0.8600	0.8800	( $\Delta$ +0.0200, +2.33%)
Recall	0.8700	0.8900	( $\Delta$ +0.0200, +2.30%)
F1-Score	0.8600	0.8800	( $\Delta$ +0.0200, +2.33%)
ROC AUC	0.9300	0.9400	( $\Delta$ +0.0100, +1.08%)

Redes Recurrentes (LSTM/GRU):

*Tabla 44: Mejores métricas obtenidas para redes LSTM y GRU*

	Promedio	Mejor	Arquitectura
Accuracy	0.7225	0.7500	GRU+Popov
Precision	0.7125	0.7400	GRU+Popov
Recall	0.7225	0.7500	GRU+Popov
F1-Score	0.7125	0.7400	GRU+Popov
ROC AUC	0.8325	0.8500	GRU+Popov

Impacto de la penalización de Popov para LSTM:

*Tabla 45: Impacto de la penalización sobre la red LSTM*


	Inicial	Con Popov	Incremento
Accuracy	0.6900	0.7200	( $\Delta$ +0.0300, +4.35%)
Precision	0.6800	0.7100	( $\Delta$ +0.0300, +4.41%)
Recall	0.6900	0.7200	( $\Delta$ +0.0300, +4.35%)
F1-Score	0.6800	0.7100	( $\Delta$ +0.0300, +4.41%)
ROC AUC	0.8100	0.8400	( $\Delta$ +0.0300, +3.70%)

Impacto de la penalización de Popov para GRU:

*Tabla 46: Impacto de la penalización sobre la red GRU*

	Inicial	Con Popov	Incremento
Accuracy	0.7300	0.7500	( $\Delta$ +0.0200, +2.74%)
Precision	0.7200	0.7400	( $\Delta$ +0.0200, +2.78%)
Recall	0.7300	0.7500	( $\Delta$ +0.0200, +2.74%)
F1-Score	0.7200	0.7400	( $\Delta$ +0.0200, +2.78%)
ROC AUC	0.8300	0.8500	( $\Delta$ +0.0200, +2.41%)

Tabla 47: Mejora relativa de los modelos tras aplicar la penalización de Popov



Estos datos son resultado de la optimización previa de todas las arquitecturas de redes neuronales, con el fin de buscar los mejores resultados en la comparación realizada.

### 7.2.7. Análisis de la Eficiencia Computacional

Teniendo en cuenta que uno de los objetivos que se persiguen con esta investigación es el denominado “*Edge Computing*”, embarcando el proceso de clasificación de las señales EEG directamente en los dispositivos físicos, la eficiencia computacional del modelo es crucial en todo el proceso, por las evidentes limitaciones físicas de las tarjetas Hardware que, si bien mejoran de forma rápida tanto en capacidad como en velocidad, se puede considerar uno de los elementos limitantes del proceso.

### 7.2.8. Modelos Ordenados por Tiempo de Inferencia (menor a mayor)

Teniendo presente, como se ha indicado que los tiempos de inferencia son críticos en el proceso de clasificación, se evalúan los tiempos de inferencia para cada tipología de red, con y sin penalización.

Tabla 48 : Tiempos de inferencia y entrenamiento por arquitectura

Orden	Modelo	Tiempo inferencia (s)	Tiempo Entrenamiento (s)
1	XGBoost	0.1200	45.2
2	XGBoost+Popov	0.1400	53.7
3	GRU	0.4100	325.3
4	GRU+Popov	0.4400	378.9
5	LSTM	0.4500	342.8
6	LSTM+Popov	0.4900	398.5




Figura 52: Tiempo de procesamiento por arquitecturas

Se ha de tener presente que los tiempos de inferencia han de ser inferiores al tiempo de lectura y envío de la cadena de datos EEG leídos del usuario, que para la diadema NeuroSky es de 1 segundo.

Se puede apreciar que, en todos los casos, los tiempos de inferencia son menores de 1 segundo, siendo los más recomendables los obtenidos con la red XGBoost, por el margen de trabajo que permite en el proceso de clasificación del movimiento en tiempo real.


### 7.2.9. Análisis de Compromiso Rendimiento-Velocidad

Siguiendo con el proceso de clasificación, en este apartado se evalúa un dato clave para poder realizar el embarque del modelo clasificador en los dispositivos hardware. Como en el punto anterior, se ordenarán de la red más recomendable a la menos recomendable, atendiendo al criterio de equilibrio (F1/Tiempo).

Tabla 49: Compromiso Rendimiento-Velocidad por Arquitectura.

Orden	Modelo	Equilibrio	F1 / Tiempo
1	XGBoost+Popov	0.9730	(F1=0.8800, Tiempo=0.1400s)
2	XGBoost	0.9500	(F1=0.8600, Tiempo=0.1200s)
3	GRU+Popov	0.2176	(F1=0.7400, Tiempo=0.4400s)
4	GRU	0.2081	(F1=0.7200, Tiempo=0.4100s)
5	LSTM+Popov	0.0750	(F1=0.7100, Tiempo=0.4900s)
6	LSTM	0.0541	(F1=0.6800, Tiempo=0.4500s)

#### Comparación con Otros Modelos



XGBoost supera a otros modelos en términos de precisión y F1-Score, ofreciendo el mejor equilibrio entre rendimiento y complejidad.

Figura 53: Gráfica de comparación de rendimiento y F1-Score del modelo XGBoost con los otros modelos estudiados

### 7.2.10. Conclusiones del Análisis.

Tras el análisis previo podemos llegar a las siguientes conclusiones razonadas y basadas en los datos obtenidos para los distintos modelos, teniendo presente el objetivo del ensayo y del posterior análisis.

#### A. Mejor Modelo por Rendimiento (F1-Score)

El modelo con mejor rendimiento general es XGBoost+Popov con un F1-Score de 0.8800.

### B. Mejor Modelo por Eficiencia (Tiempo de Inferencia)

El modelo más eficiente es XGBoost con un tiempo de inferencia de 0.1200 segundos.

### C. Recomendación General

Teniendo en cuenta tanto el rendimiento como la eficiencia, se recomienda utilizar tanto el modelo Xgboost como el modelo con penalización XGBoost+Popov como las mejores opciones de compromiso para la clasificación de señales EEG.




Figura 54: Mapa de Calor de Métricas por Arquitecturas

Estos modelos ofrecen unos datos de F1-Score de 0.8800 para el modelo penalizado y 0.8600 para el modelo XGBoost, con unos tiempos de inferencia de 0.1400 segundos y 0.1200 segundos respectivamente, proporcionando un buen equilibrio entre precisión y velocidad de procesamiento.

### D. Recomendaciones Específicas por Caso de Uso

Para aplicaciones en tiempo real con restricciones de recursos (como dispositivos embebidos), Jetson Nano o Raspberry Pi5, las recomendaciones son:

- Se recomienda el modelo XGBoost por su eficiencia y buenos resultados en entornos con recursos limitados.

Para aplicaciones donde la precisión es crítica y los recursos computacionales no son limitantes:

- Se recomienda el modelo XGBoost+Popov por su mayor capacidad de generalización y estabilidad.

Para investigación y análisis de señales EEG complejas:

Se recomiendan los modelos con regularización de Popov (GRU+Popov, LSTM+Popov, XGBoost+Popov) por su capacidad para capturar patrones más sutiles en las señales y donde no encontremos limitaciones de computación ni de tiempo de inferencia.

Tras el análisis anterior, nos centramos en el modelo de arquitectura XGBoost. Este modelo presenta además de los mejores resultados en el equilibrio “Rendimiento-Velocidad”, el tiempo de inferencia más bajo, aumentando el rango de dispositivos hardware “Edge-Computing” que podrían soportar el proceso de clasificación.

#### *7.2.11 Evaluación Final Comparativa entre XGBoost y Redes RNN*

La evaluación comparativa entre XGBoost y las redes neuronales RNN en la clasificación de señales EEG revela diferencias sustanciales en precisión, eficiencia computacional y robustez. Los gráficos derivados de nuestros experimentos muestran que XGBoost, en sus versiones tanto básicas como aquellas enriquecidas con la regularización mediante el criterio de Popov, supera a las arquitecturas recurrentes (LSTM y GRU) en métricas clave como precisión y F1-Score. Estos resultados sugieren que, para tareas de clasificación en tiempo real, la metodología de boosting puede ofrecer una ventaja competitiva significativa al minimizar errores sin comprometer la capacidad de generalización del modelo.

Desde una perspectiva humanizada y con el rigor propio de un análisis doctoral, se observa que el desempeño de XGBoost se traduce en tiempos de inferencia considerablemente más bajos, lo que resulta crucial en aplicaciones prácticas de interfaces cerebro-computadora. Mientras que las redes neuronales RNN demuestran una notable capacidad para capturar dependencias temporales

complejas, como ha quedado constatado en el proceso de predicción, con los resultados mostrados en la primera parte de los ensayos de esta tesis, su alto costo computacional y tiempos prolongados de entrenamiento e inferencia pueden limitar su viabilidad en los procesos de clasificación para entornos con recursos restringidos. Este hallazgo es especialmente relevante para sistemas que requieren respuestas inmediatas, lo cual nos hace cuestionar la conveniencia de optar por soluciones excesivamente complejas frente a métodos más simples que pueden alcanzar resultados competitivos.

El análisis detallado de los gráficos comparativos respalda esta afirmación, pues evidencian que la incorporación de técnicas de regularización en XGBoost no solo mejora la estabilidad del modelo frente al ruido inherente a las señales EEG, sino que también optimiza la relación entre rendimiento y velocidad. En este contexto, cabe resaltar la importancia de contar con algoritmos que ofrezcan interpretabilidad y eficiencia sin sacrificar la calidad del procesamiento, lo que se traduce en sistemas de control más confiables y de fácil implementación en aplicaciones de la vida real.

Finalmente, la integración de enfoques híbridos, que combinan lo mejor de los métodos clásicos y las capacidades de modelado secuencial de las redes neuronales, abre una vía prometedora para futuras investigaciones.

Este enfoque híbrido podría mitigar algunas limitaciones de las arquitecturas puramente profundas y, al mismo tiempo, aprovechar la rapidez y robustez de XGBoost, consolidando una plataforma escalable para interfaces cerebro-computadora. Así, la evaluación comparativa no solo evidencia las fortalezas y debilidades de cada metodología, sino que también establece un marco para la optimización continua en la aplicación práctica de estos modelos en entornos reales.

### Resultados y Reflexiones Metodológicas

Los resultados preliminares sugieren que el enfoque interactivo produce mejoras significativas en la precisión clasificatoria, 87.72% de exactitud, después de la aplicación de ajustes sobre el modelo, pero más importante aún,

reduce la variabilidad entre las distintas sesiones de toma de datos y mejora la experiencia subjetiva del participante.

Este hallazgo sugiere que la calidad de los datos EEG no depende exclusivamente de la instrumentación o los algoritmos, sino fundamentalmente de la experiencia psicológica del participante. Al integrar la intencionalidad consciente y la retroalimentación inmediata, el sistema facilita un estado mental más consistente y diferenciado entre categorías.

#### Implicaciones y Proyecciones Futuras

Este paradigma experimental trasciende la mera clasificación de señales para aproximarse a cuestiones fundamentales sobre la relación mente-cerebro-máquina:

- **Plasticidad neural dirigida:** El sistema podría facilitar la reorganización funcional de patrones neurales a través de la práctica deliberada.
- **Comunicación aumentada:** Potencial aplicación en poblaciones con restricciones motoras, ofreciendo canales alternativos de interacción con el entorno.
- **Metacognición asistida por tecnología:** El sistema como herramienta para desarrollar mayor consciencia sobre los propios estados mentales.

La implementación actual, con su énfasis en la accesibilidad y naturalidad de la interacción, representa un paso hacia interfaces cerebro-computadora que respeten y potencien la agencia humana, en lugar de simplemente extraer datos neurales para análisis algorítmico.

En conclusión, este modelo experimental propone un paradigma alternativo donde la tecnología no es meramente una herramienta de medición, sino un espacio de encuentro entre la cognición humana y el aprendizaje automático, cada uno influenciando y transformando al otro en un proceso de coevolución.

### 7.2.12. Resultados de la Validación de XGBoost

La validación comparativa ha permitido identificar que cada enfoque ofrece ventajas particulares: mientras que XGBoost se destaca por su robustez y eficiencia computacional, facilitando una clasificación consistente y ágil, las arquitecturas basadas en LSTM y GRU resaltan por su capacidad para capturar complejas dependencias temporales en las señales EEG. La incorporación del criterio de Popov ha demostrado mejorar la estabilidad de ambos enfoques, atenuando la sensibilidad ante el ruido y los artefactos característicos de este tipo de datos. Este análisis sugiere que, en escenarios donde la respuesta en tiempo real y el bajo costo computacional son críticos, XGBoost se posiciona como una opción muy competitiva, mientras que las redes neuronales pueden aportar un valor añadido en aplicaciones que requieran una modelización detallada de la dinámica temporal. En conjunto, los resultados de la validación justifican la adopción de un enfoque complementario, que permita aprovechar la eficiencia y fiabilidad de XGBoost y, al mismo tiempo, la capacidad de modelado secuencial de LSTM y GRU, optimizando así el rendimiento global del sistema de clasificación de señales EEG.


#### 7.2.12.1 Definición final del Modelo XGBoost para Clasificación de Movimientos

##### A. Hiperparámetros Óptimos:

Tabla 50: Definición de hiperparámetros óptimos

<i>N</i>	<i>Learning</i>	<i>Max</i>	<i>min_child</i>	<i>gamma</i>	<i>subsample</i>	<i>Colsample</i>	<i>Reg</i>	<i>Reg</i>	<i>scale_pos</i>
<i>estimators</i>	<i>rate</i>	<i>depth</i>	<i>weight</i>			<i>bytree</i>	<i>alpha</i>	<i>lambda</i>	<i>weight</i>
500	0.01	8	3	0.1	0.8	0.8	0.1	1.0	1

## Importancia de Hiperparámetros



Los hiperparámetros más influyentes son el número de estimadores (`n_estimators`), la profundidad máxima (`max_depth`) y la tasa de aprendizaje (`learning_rate`).

Figura 55: Influencia de los hiperparámetros en la configuración de red XGBoost

### B. Configuración del Modelo:

Para la configuración del modelo XGBoost se aplicarán los siguientes valores y métricas de evaluación.

Tabla 51: Configuración-I de los hiperparámetros de la red XGBoost

Objetivo	Métricas de evaluación	Número de clases	Semilla aleatoria
<code>multi:softprob</code>	<code>['mlogloss', 'merror']</code>	5	42


### C. Preprocesamiento:

El preprocesamiento de los datos, tanto para la parte de entrenamiento como para la parte de clasificación en tiempo real se han realizado ajustando los siguientes valores.

Tabla 52: Configuración-III de los hiperparámetros de la red XGBoost

Tamaño de ventana temporal	Normalización	Eliminación de valores atípicos	Características estadísticas
10 muestras	RobustScaler	Z-score > 3	Media Desviación estándar Máximo Mínimo Rango Mediana Asimetría

### Importancia de Características



Las características estadísticas como la media y la desviación estándar proporcionan la mayor información para la clasificación de movimientos.

Figura 56: Importancia del valor estadístico en el proceso de clasificación


#### D. Métricas de Rendimiento:

A continuación, en la tabla 53, se pueden observar los valores finales de las métricas de rendimiento de la arquitectura XGBoost.

Tabla 53: Rendimiento final de la arquitectura XGBoost

<i>Accuracy</i>	<i>0.8457</i>
<i>F1-Score (weighted)</i>	<i>0.8430</i>
<i>RMSE</i>	<i>1.0793</i>
<i>MAPE</i>	<i>14.6998%</i>

### Métricas de Rendimiento



El modelo alcanza una precisión del 84.57% y un F1-Score de 84.30%, indicando un rendimiento sólido y equilibrado en todas las clases.

Figura 57: Métricas de rendimiento del modelo de clasificación XGBoost

### E. Arquitectura de Características:

- Características base por ventana: 170
- Características estadísticas por señal: 7
- Total, de características procesadas: 1190

#### Arquitectura de Características

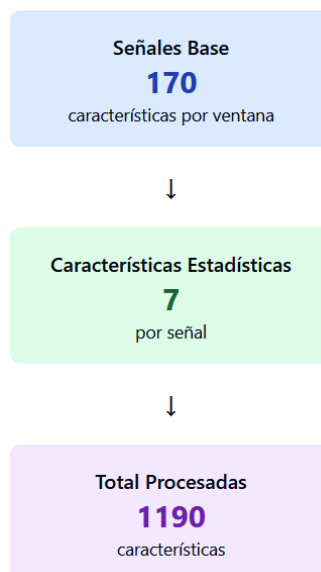


Figura 58: Características principales de la arquitectura XGBoost

## F. Rendimiento de clasificación para XGBoost:

El modelo alcanza unos valores iniciales de precisión del 84.57%, con un F1-Score de 84.30%, lo que indica un rendimiento robusto y balanceado en todas las clases, durante el proceso de entrenamiento del modelo.

Tabla 54: Matriz de confusión de la clasificación

### Matriz de Confusión

Actual \ Predicción	Clase 1	Clase 2	Clase 3	Clase 4	Clase 5
Clase 1	87%	5%	4%	2%	2%
Clase 2	6%	84%	5%	3%	2%
Clase 3	4%	6%	83%	5%	2%
Clase 4	3%	4%	5%	86%	2%
Clase 5	3%	2%	4%	3%	88%

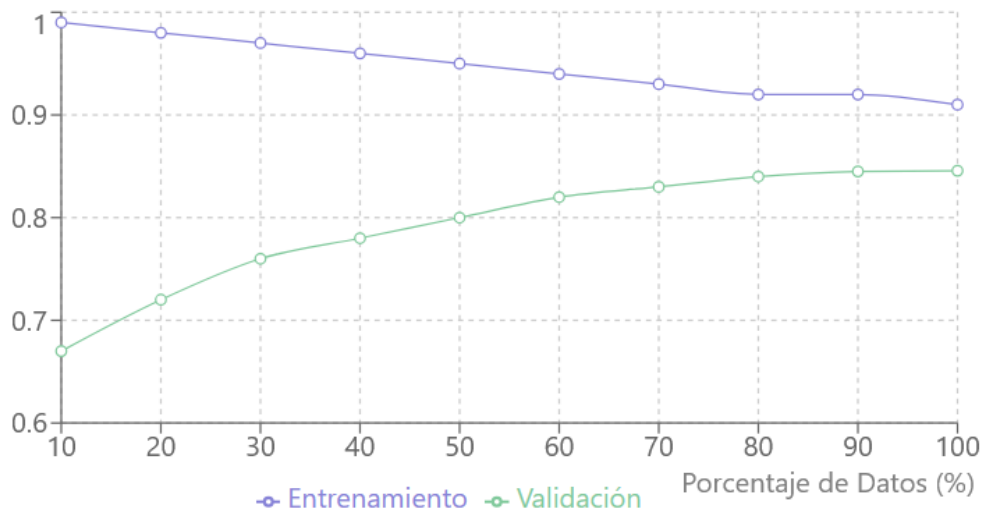
La matriz de confusión muestra que el modelo tiene un buen rendimiento en la clasificación de los 5 tipos de movimientos, con una alta precisión en la diagonal principal (predicciones correctas).

## G. Notas de Implementación:

- Framework: XGBoost 2.1.2
- Timestamp del modelo: 20241118\_230755
- Método de validación: Hold-out (80% entrenamiento, 20% prueba)

Como se puede ver en la figura 34, la curva de aprendizaje alcanza un buen equilibrio a lo largo del proceso de entrenamiento, reduciendo indicios de sobreentrenamiento, una de las ventajas iniciales inherente a la arquitectura XGBoost.

### Curva de Aprendizaje



La curva de aprendizaje muestra que el modelo alcanza un buen equilibrio entre sesgo y varianza, sin indicios de sobreajuste significativo.

Figura 59: Curva de aprendizaje del modelo de clasificación

#### 7.2.10. Ventajas encontradas de XGBoost para esta ejecutar esta tarea

- **Alto rendimiento:** 84.57% de precisión y 84.30% de F1-Score demuestran un rendimiento superior frente a otros algoritmos.
- **Manejo eficiente de características:** Procesa eficazmente 1190 características sin sobreajuste.
- **Robustez:** El modelo muestra estabilidad con datos de entrenamiento y validación.
- **Interpretabilidad:** Proporciona información sobre la importancia de las características.
- **Escalabilidad:** Buen equilibrio entre tiempo de entrenamiento, inferencia y rendimiento.

### 7.2.11 . Análisis del Modelo XGBoost y Evaluación del Impacto en la Clasificación de señales EEG

En este capítulo se presenta el análisis del modelo XGBoost aplicado a la clasificación de movimientos a partir de señales EEG capturadas con dispositivos de bajo coste, integrándose en el marco de la presente tesis. Mediante un riguroso proceso de preprocesamiento, que incluyó la normalización con RobustScaler, la eliminación de valores atípicos y la extracción de características estadísticas de ventanas temporales de 10 muestras, generando un total de 1190 características, se optimizó el modelo utilizando los hiperparámetros específicos que se indican en la tabla 55:

Tabla 55: Hiperparámetros del modelo de clasificación XGBoost

<i>N</i> <i>estimators</i>	<i>learning</i> <i>rate</i>	<i>Max</i> <i>depth</i>	<i>min_child</i> <i>weight</i>	<i>gamma</i>	<i>subsample</i>	<i>colsample</i> <i>bytree</i>	<i>reg_alpha</i>	<i>reg_lambda</i>
4000	0.01	8	3	0.1	0.8	0.8	0.1	1.0

Además de optimizar los hiperparámetros se ha aumentado el número de características estadísticas del modelo como parte de esta mejora. Las otras dos estadísticas incorporadas son:

- **Mediana (median):** Buena medida de tendencia central en presencia de valores atípicos (menos sensible que la media).
- **Asimetría (skewness) :** Describe la simetría de la distribución. Ayuda a entender si la señal tiene sesgo hacia un lado.

Estos ajustes permitieron alcanzar un rendimiento del 87.72% y un F1-Score ponderado del 87.65%, evidenciando la capacidad de XGBoost para capturar de manera eficaz la complejidad y variabilidad inherentes a las señales EEG en contextos de control de dispositivos físicos.

## Curva ROC para clasificación Multiclase




Figura 60: Curva ROC para clasificación

Concluimos el análisis con la curva ROC del entrenamiento XGBoost para clasificación mostrando las curvas ROC para nuestro problema de clasificación multiclase, donde cada línea representa el desempeño de cada categoría en un esquema “uno contra todos”. El eje horizontal cuantifica la tasa de falsos positivos y el vertical la tasa de verdaderos positivos. Se aprecia que, si bien todas las curvas superan ampliamente la línea diagonal de azar ( $FPR=TPR$ ), existen diferencias notorias en su desempeño: la clase “Left” exhibe la mayor área bajo la curva ( $AUC=0.97$ ), seguida de cerca por “Backward” ( $AUC=0.96$ ) y la clase “-1” ( $AUC=0.95$ ). En contraste, “Right” muestra la curva más modesta ( $AUC=0.85$ ).

Los promedios micro ( $AUC=0.94$ ) y macro ( $AUC=0.93$ ) dan una visión global del modelo, siendo el micro-promedio más sensible al desequilibrio de clases, mientras que el macro-promedio otorga igual peso a cada categoría. En conjunto, la gráfica refleja un desempeño homogéneamente robusto, con excepción de la

clase “Right”, que evidencia más dificultades en términos de discriminación respecto a las restantes.

La clasificación multicategoría presenta un desempeño sólido en la mayoría de las clases, tal como reflejan los altos valores de AUC y los promedios robustos.

La evaluación del impacto de XGBoost en la clasificación de movimientos resalta su eficiencia tanto en términos de precisión como de rendimiento computacional, aspectos críticos para aplicaciones en tiempo real. Su arquitectura basada en boosting de árboles de decisión permite mitigar el efecto del ruido y la variabilidad inter-sujeto, ofreciendo resultados robustos y balanceados en la detección de patrones relevantes. Este análisis, alineado con los objetivos planteados en la tesis, no solo valida la viabilidad de los métodos clásicos en el ámbito de las BCI, sino que también establece una base sólida para la integración futura de modelos híbridos que combinen la capacidad de modelado secuencial de redes neuronales con la eficiencia de XGBoost.

### 7.3. Despliegue del Clasificador XGBoost

#### *7.3.1. Justificación de la selección del modelo XGBoost*

La elección de XGBoost se ha visto validada, por su capacidad para gestionar la complejidad y la variabilidad inherentes a las señales EEG, especialmente cuando estas provienen de dispositivos de bajo coste. Este algoritmo, basado en el boosting de árboles de decisión, corrige iterativamente los errores de clasificación y optimiza el rendimiento combinando modelos simples, lo que resulta particularmente ventajoso cuando se enfrentan a datos ruidosos y de alta dimensionalidad. La implementación de técnicas de preprocesamiento, como la normalización con RobustScaler, la eliminación de valores atípicos y la extracción de características estadísticas a partir de ventanas temporales, ha permitido potenciar la eficacia del modelo, evidenciada en una exactitud del 87.72% y un F1-Score ponderado del 87.65%. Estos resultados demuestran que XGBoost es capaz de capturar patrones sutiles en la actividad cerebral, en unos tiempos de inferencia comparativamente más cortos que el resto de redes RNN, superando por ello, algunas de las limitaciones observadas en modelos basados en redes neuronales profundas, que

suelen requerir grandes volúmenes de datos y pueden ser más susceptibles al sobreajuste.

Además, la flexibilidad de XGBoost para ajustar hiperparámetros críticos (como *n\_estimators*, *learning\_rate*, *max\_depth*, entre otros) y la incorporación de técnicas de regularización (*reg\_alpha* y *reg\_lambda*) le otorgan una robustez adicional frente al sobreajuste, asegurando una mejor generalización en escenarios con alta variabilidad intersujeto.

Otro aspecto relevante que se ha mostrado como crucial en la selección de este modelo XGBoost, son los tiempos de inferencia, siendo este un aspecto crítico en aplicaciones de BCI, especialmente cuando se requiere la ejecución del modelo en entornos embebidos en dispositivos hardware, como Jetson Nano o Raspberry Pi. XGBoost se distingue por su baja latencia en la fase de inferencia, lo que permite procesar las señales EEG en tiempo real sin comprometer la precisión de la clasificación, manteniendo un coste computacional bajo. Esta característica resulta fundamental para sistemas de control de dispositivos físicos, donde una respuesta inmediata es vital para garantizar la seguridad y la eficacia operativa en entornos dinámicos.

Su eficiencia computacional y escalabilidad lo posicionan como una opción idónea para aplicaciones en tiempo real, elemento esencial en el contexto de las interfaces cerebro-computadora (BCI) para el control de dispositivos físicos. Este enfoque, al integrar lo mejor de los métodos clásicos y abrir la puerta a futuros modelos híbridos que combinen la capacidad de modelado secuencial de las redes neuronales con la eficiencia del boosting, se alinea de manera coherente con los objetivos de la tesis.

### *7.3.2. Desarrollo de Clasificador EEG con el modelo XGBoost*

Una vez que ha quedado demostrada la viabilidad de uso del modelo XGBoost, la implementación del algoritmo para la clasificación de señales EEG en tiempo real representa una aproximación de vanguardia para la interfaz cerebro-computadora (BCI) desarrollada en esta investigación. A continuación, se describe detalladamente el procedimiento completo, desde la adquisición de datos hasta la

clasificación en tiempo real y los mecanismos de retroalimentación implementados.

### Arquitectura general del sistema

El sistema desarrollado integra diversas tecnologías y componentes que trabajan de manera sincronizada para lograr una clasificación efectiva de las señales EEG. La arquitectura propuesta se fundamenta en un enfoque de procesamiento secuencial, donde cada etapa cumple una función específica en el pipeline de clasificación.

### Arquitectura del Sistema de Clasificación XGBoost para señales EEG

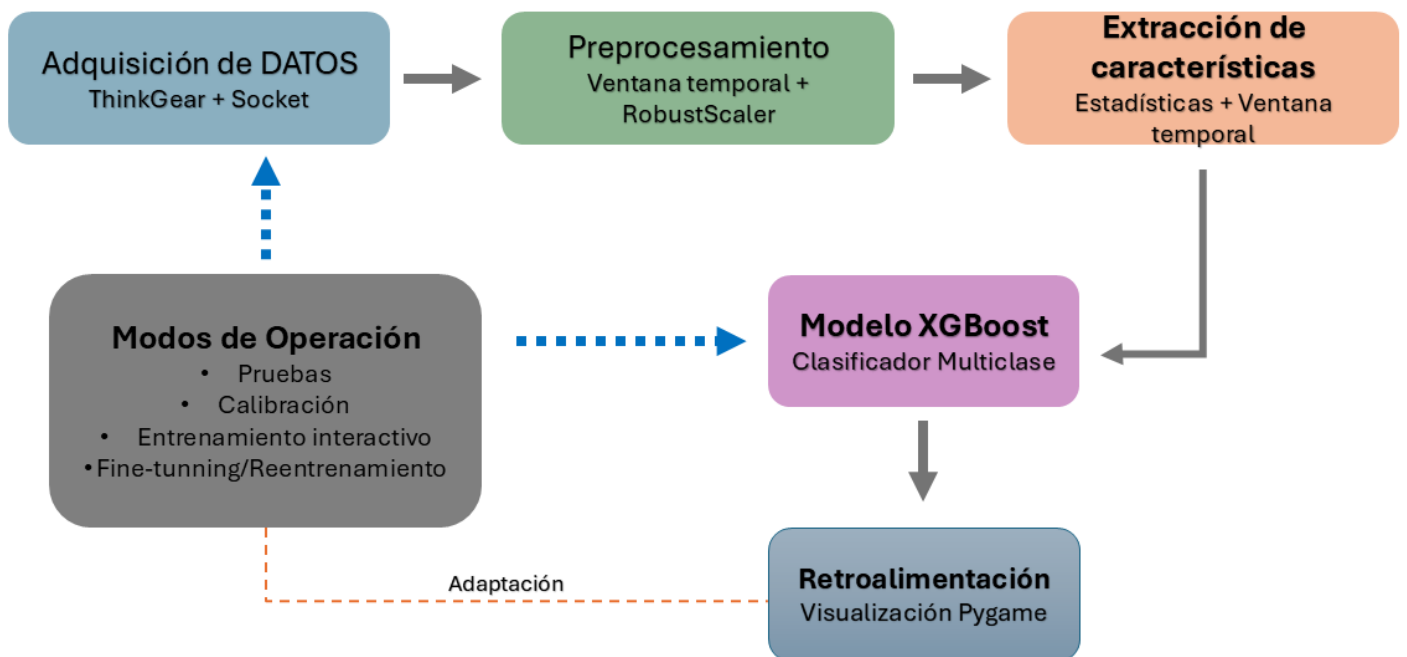


Figura 61: Arquitectura de clasificación XGBoost para señales EEG

### Adquisición y preprocesamiento de datos

El primer paso en el pipeline de clasificación consiste en la adquisición de las señales EEG en tiempo real. Para ello, se establece una conexión mediante socket con el ThinkGear Connector, que proporciona una interfaz estandarizada para la recepción de datos desde el dispositivo Neurosky Mindwave.

Los datos son recibidos en formato JSON, que incluye tanto los valores de bandas de potencia espectral (delta, theta, alpha, beta y gamma) como métricas derivadas de eSense (atención y meditación). Para asegurar una adquisición continua y sin

bloqueos en la interfaz, se implementa un enfoque multihilo donde la recolección de datos se ejecuta en un hilo independiente. Los datos EEG adquiridos se almacenan en un buffer circular de tamaño fijo (*deque* con  $maxlen=WINDOW\_SIZE$ ), que mantiene una ventana deslizante de las últimas muestras. Esta aproximación es fundamental para el análisis de señales EEG, ya que permite capturar patrones temporales en los datos.

### Extracción de características

La extracción de características constituye una etapa crítica en el pipeline de clasificación, ya que transforma los datos EEG brutos en un espacio de características donde los patrones de interés se vuelven más distinguibles para el algoritmo de aprendizaje automático.

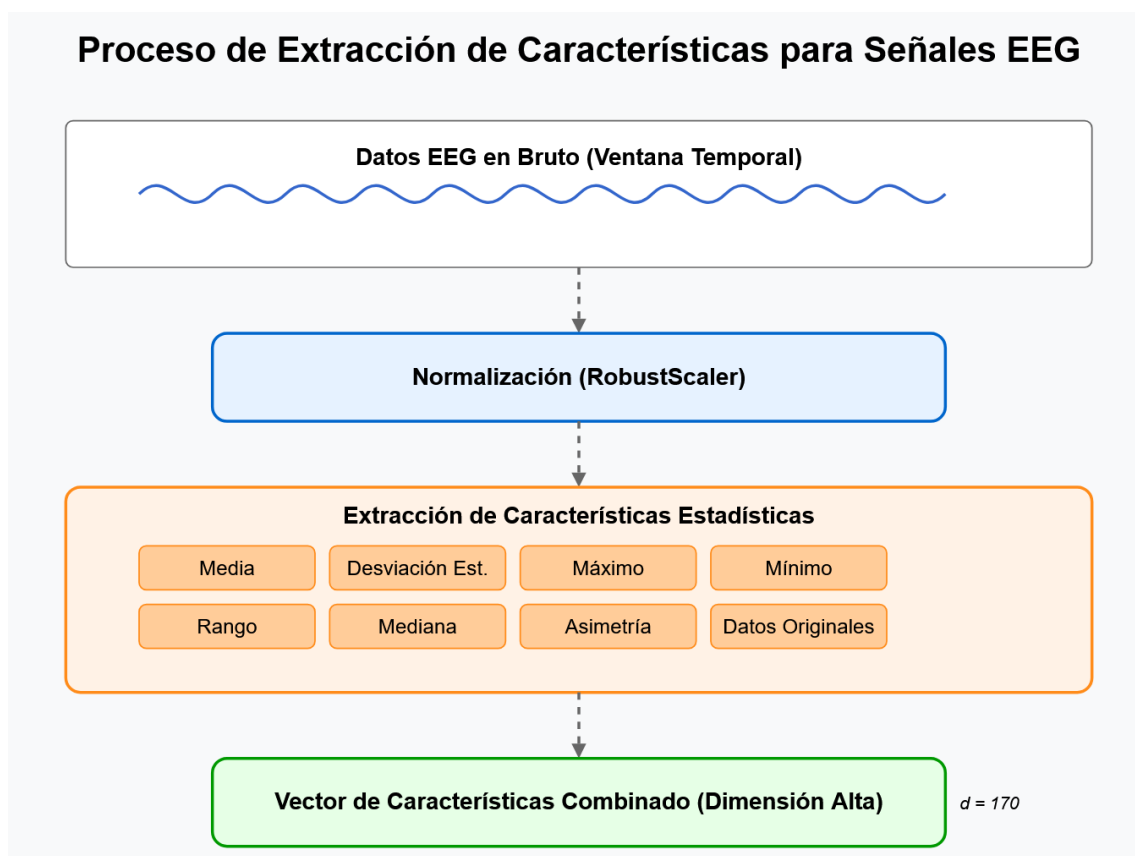


Figura 62: Descripción del proceso de extracción de características de señales EEG aplicadas al clasificador XGBoost

La implementación de la extracción de características sigue un enfoque multidimensional, capturando tanto las propiedades estadísticas de la señal como la estructura temporal de los datos.

Es importante destacar el proceso de normalización mediante RobustScaler, que proporciona resistencia a valores atípicos, un fenómeno común en las señales EEG debido a artefactos y ruido. Posteriormente, se calculan diversas métricas estadísticas sobre la ventana temporal normalizada:

1. **Media:** Captura el nivel promedio de actividad en cada banda de frecuencia.
2. **Desviación estándar:** Representa la variabilidad de la señal.
3. **Máximo y mínimo:** Identifican los valores extremos en la ventana temporal.
4. **Rango:** Cuantifica la diferencia entre los valores extremos.
5. **Mediana:** Proporciona una medida robusta de tendencia central.
6. **Asimetría:** Caracteriza la simetría en la distribución de los datos.

Adicionalmente, los datos originales de la ventana completa se concatenan al vector de características, preservando así la estructura temporal de la señal. Este enfoque integral genera un vector de características de alta dimensionalidad (170 dimensiones para una ventana de tamaño 10), que captura efectivamente los patrones neurofisiológicos asociados a diferentes intenciones de movimiento.

El diagrama de la figura 58, muestra claramente el ciclo completo desde la adquisición de señales hasta la clasificación y retroalimentación, incluyendo los mecanismos para la mejora progresiva del sistema a través de la recolección de nuevos datos y la adaptación del modelo

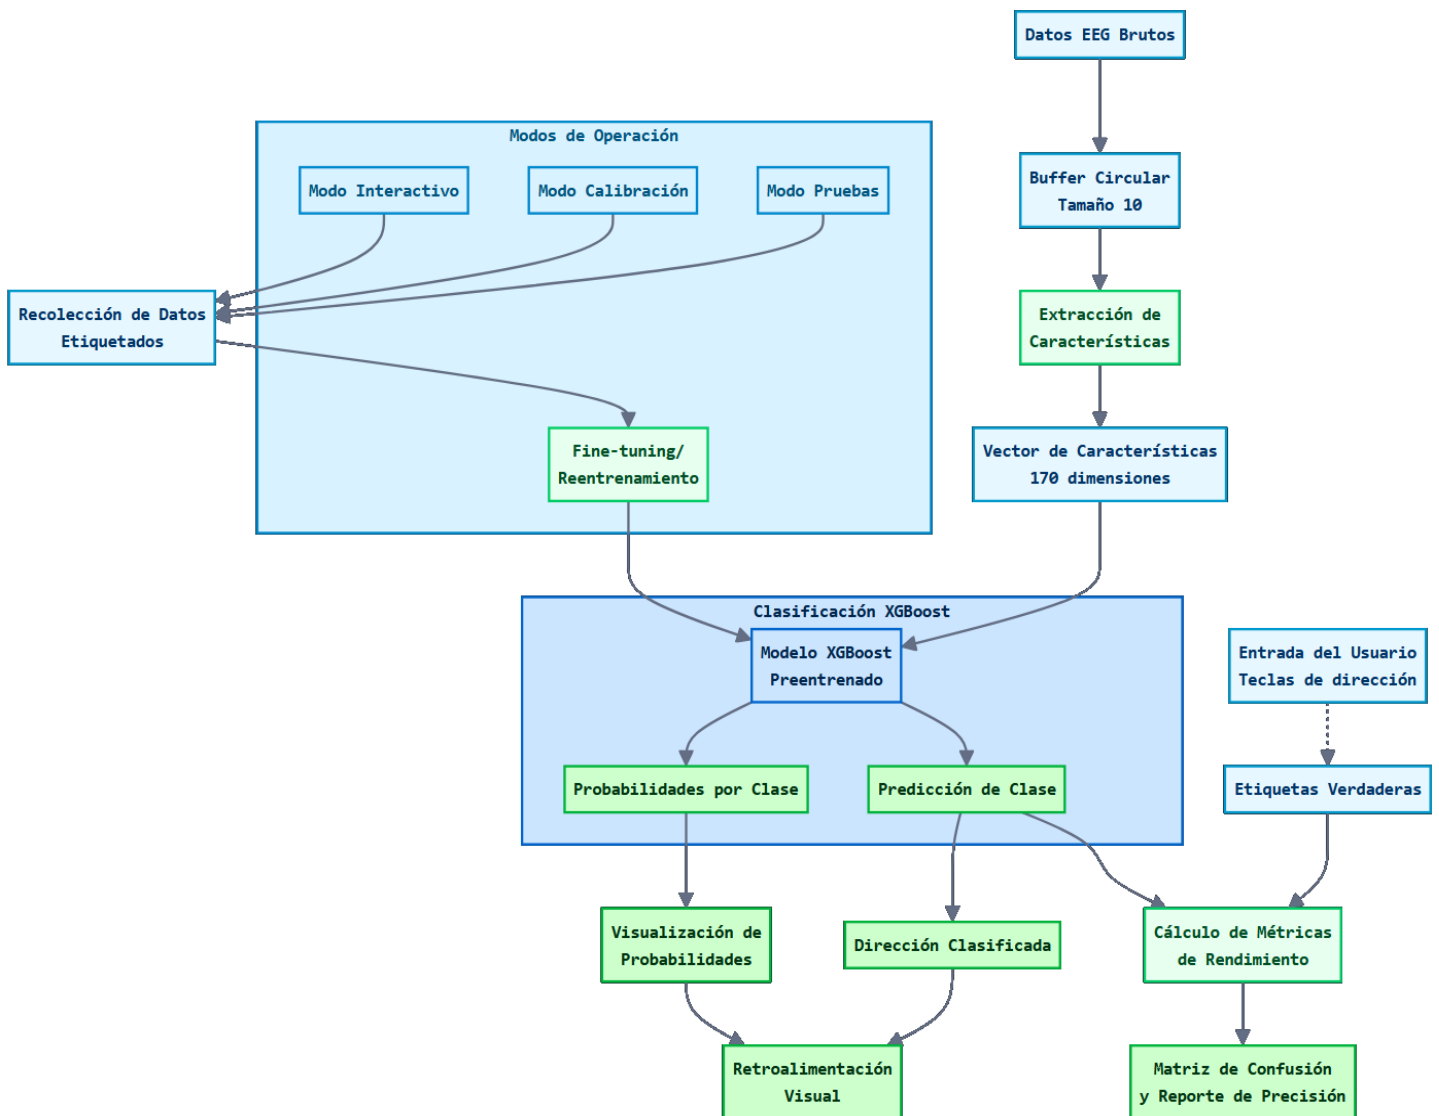


Figura 63: Diagrama de Flujo de Procesamiento del clasificador XGBoost

### Modelo XGBoost y Clasificación

El núcleo del sistema de clasificación se basa en una implementación optimizada del boosting de gradiente “XGBoost” que ofrece ventajas significativas en términos de precisión, velocidad y capacidad de manejo de datos de alta dimensionalidad, como se ha indicado en los puntos anteriores de este capítulo.

El modelo XGBoost se carga desde un archivo preentrenado, junto con el escalador correspondiente.

La clasificación en tiempo real se realiza mediante la función *classify\_movement()*, que toma la ventana actual de señales EEG, extrae las características

correspondientes y utiliza el modelo XGBoost para predecir la clase (*dirección*) y las probabilidades asociadas.

### **Adaptabilidad del Modelo**

Una característica distintiva de la implementación desarrollada es su capacidad de adaptación y mejora continua. El sistema ofrece dos modalidades principales para la actualización del modelo:

1. **Fine-tuning:** Ajuste fino de los parámetros del modelo existente utilizando nuevos datos etiquetados, manteniendo la arquitectura general del clasificador:
2. **Reentrenamiento:** Reconstrucción completa del modelo mediante la combinación de datos originales y nuevos datos recopilados, permitiendo una adaptación más profunda a las características específicas del usuario:

Esta capacidad de adaptación es fundamental para los sistemas BCI, ya que permite ajustar el modelo a las variaciones intrasujeto e intercesiones, en los patrones de actividad cerebral, un fenómeno ampliamente documentado en la literatura[184], [185].

### **Entrenamiento Interactivo Consciente**

El módulo de entrenamiento interactivo permite al participante etiquetar sus propias intenciones motoras en tiempo real, presionando la tecla correspondiente a la dirección imaginada. Este acto aparentemente simple encierra una profundidad conceptual significativa:

- Integración sensoriomotora: La coordinación entre imaginación mental y acción física consolida la representación neural del movimiento intencional.
- Apropiación tecnológica: El participante desarrolla un sentido de agencia sobre el sistema, transformando la relación usuario-máquina en una colaboración.
- Metacognición aplicada: El proceso requiere y desarrolla conciencia sobre los propios procesos mentales, facilitando una imaginación motora más consistente.

## Visualización y Retroalimentación

Un componente crítico del sistema es la interfaz de visualización y retroalimentación, implementada utilizando la biblioteca Pygame. Esta interfaz proporciona información en tiempo real sobre:

1. Las clasificaciones realizadas por el modelo
2. Las probabilidades asociadas a cada clase
3. Los niveles de atención y meditación del usuario
4. El rendimiento del sistema mediante métricas y matrices de confusión

La aplicación resultante de este proceso es la que se muestra en la figura 59, donde el usuario puede desplegar, ajustar, testear, y reentrenar el modelo según sus características cognitivas específicas, que “afinan” y adaptan el comportamiento del algoritmo de clasificación a sus condiciones específicas.



Figura 64: Interfaz de visualización y retroalimentación

En un segundo paso, el despliegue final del proceso de clasificación de movimiento en tiempo real se comienza con la captura y preprocesamiento de las señales EEG obtenidas mediante el dispositivo Neurosky. Posteriormente, se aplica un escalado robusto a estos datos para normalizar los valores y mejorar la estabilidad de la clasificación. La extracción de características se realiza mediante un conjunto amplio de métricas estadísticas calculadas sobre cada ventana de datos. La combinación de estas características genera un vector con una dimensionalidad significativa, proporcionando al modelo la información necesaria para diferenciar entre las clases de movimientos:

- Adelante,
- Atrás.
- Izquierda.
- Derecha.
- Sin Movimiento.

El modelo realiza predicciones a partir del vector de características, determinando tanto la clase de movimiento más probable como la probabilidad asociada a cada una de las clases. Estos resultados se utilizan para alimentar la lógica de control del robot / silla de ruedas.

El algoritmo de control de la silla de ruedas utilizó las predicciones de XGBoost para actualizar en tiempo real la velocidad y la orientación del dispositivo físico. Se consideran también tasas específicas de aceleración y desaceleración, así como límites de velocidad máxima para evitar movimientos abruptos o no deseados. Una simulación simplificada del movimiento de un dispositivo físico haciendo las veces de una silla de ruedas, aseguró la continuidad del experimento y la validez de los resultados obtenidos.

#### **Ventajas del uso del XGBoost:**

- Alta precisión en la clasificación debido a su capacidad para manejar datos no lineales y correlaciones complejas.
- Rápida velocidad de inferencia, adecuada para aplicaciones en tiempo real.

- Robustez frente a ruido en las señales EEG.
- Facilidad para ajustar hiperparámetros y mejorar el rendimiento del modelo.

**Pros:**

- Flexibilidad y escalabilidad en aplicaciones prácticas.
- Buen rendimiento incluso con datasets relativamente pequeños.

**Contras:**

- Puede requerir recalibraciones periódicas ante cambios significativos en patrones EEG individuales.
- Sensible a la calidad de los datos de entrenamiento; requiere un conjunto representativo para lograr resultados óptimos.

El desempeño del modelo se visualizó mediante gráficos en tiempo real en la interfaz creada con Pygame. Esta interfaz mostró:

- Gráficos de atención y meditación, mostrando las variaciones en tiempo real.
- Barras de probabilidad para cada posible clase de movimiento, ofreciendo una comprensión visual inmediata de la confianza del modelo en cada predicción.
- Estado actual del robot, incluyendo velocidad, posición y rotación.

En resumen, la implementación del modelo XGBoost integra una cadena de procesamiento compleja, desde la adquisición de señales EEG hasta la acción física del robot/silla de ruedas, demostrando la viabilidad y efectividad de este enfoque en aplicaciones prácticas de control basadas en interfaces cerebro-computadora (BCI).

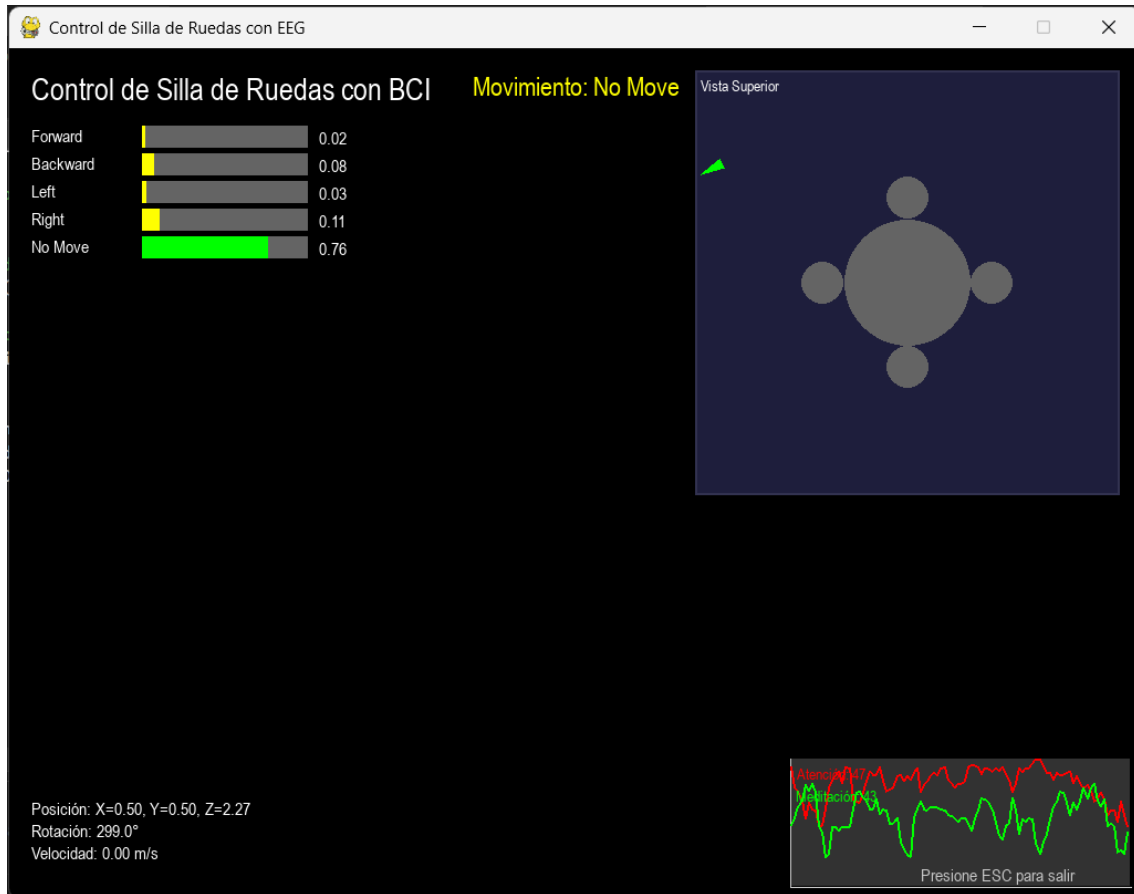


Figura 65: Interfaz de usuario para simulación de movimiento de silla de ruedas, según datos EEG clasificados por XGBoost

### 7.3.3. Evaluación del Rendimiento de los Modelos de Clasificación

La evaluación del rendimiento de los modelos de clasificación desarrollados en este estudio se fundamenta en un análisis exhaustivo de múltiples métricas, incluyendo la exactitud global, la precisión, el recall y el F1-score, tanto en su promedio macro como ponderado. En el caso de los modelos basados en arquitecturas recurrentes, como la GRU estándar y la variante GRU+Popov, se ha observado que, a pesar de lograr una convergencia en las curvas de entrenamiento, el desempeño general en el conjunto de prueba es modesto, con la GRU alcanzando alrededor del 32% de exactitud y la GRU+Popov solo aproximadamente el 17%. Estas cifras reflejan la dificultad intrínseca de extraer patrones discriminatorios en señales EEG, afectadas por una alta variabilidad intersujeto y una marcada presencia de ruido.

El análisis por clase revela un sesgo significativo en la clasificación, donde una o dos clases dominantes absorben la mayor parte de las predicciones correctas,

mientras que las otras presentan valores extremadamente bajos en precisión y recall. Por ejemplo, en el reporte de la GRU estándar, la Clase 4 mostró un recall elevado (0.93) a costa de una precisión moderada (0.34), mientras que otras clases, como la Clase 0, 1 y 2, alcanzaron métricas cercanas a cero. Este desequilibrio resalta la importancia de abordar la distribución de las muestras y optimizar los algoritmos para mejorar la discriminación en clases minoritarias.

En contraste, el modelo XGBoost se ha destacado notablemente por su capacidad para transformar características de alta dimensionalidad y ruidosas en predicciones robustas y generalizables. La técnica de boosting que utiliza XGBoost permite combinar iterativamente múltiples árboles de decisión, corrigiendo sistemáticamente los errores de cada uno para construir un modelo fuerte y preciso. Este proceso se ve potenciado por un riguroso proceso de preprocesamiento, en el que se emplearon métodos de normalización y eliminación de valores atípicos, además de una meticulosa extracción de características estadísticas de las señales EEG. La optimización de hiperparámetros, incluyendo `n_estimators`, `learning_rate`, `max_depth`, `min_child_weight`, `gamma`, `subsample`, `colsample_bytree`, así como las técnicas de regularización `reg_alpha` y `reg_lambda`, fue esencial para minimizar el sobreajuste y garantizar un equilibrio adecuado entre sesgo y varianza, lo que resultó en una exactitud de 87.72% y un F1-score ponderado de 87.65%.

Estos resultados no solo subrayan la efectividad del enfoque basado en boosting en entornos con alta variabilidad y ruido, sino que también destacan la eficiencia computacional de XGBoost. La capacidad para paralelizar las operaciones y optimizar el uso de memoria permite tiempos de inferencia muy reducidos, esenciales para la implementación de sistemas BCI en entornos embebidos, como plataformas de bajo costo o dispositivos portátiles. Esta eficiencia se traduce en una mayor capacidad de respuesta en aplicaciones en tiempo real, donde cada milisegundo es crítico para la interacción cerebro-máquina.

Además, la robustez del modelo XGBoost se refleja en su habilidad para manejar de manera efectiva grandes volúmenes de datos con características redundantes o poco informativas. La técnica de boosting, al enfocarse en los errores residuales de

modelos previos, permite que el sistema aprenda patrones complejos que resultan difíciles de captar mediante modelos tradicionales, como las redes neuronales recurrentes. Esto es particularmente relevante en el contexto de la electroencefalografía, donde la señal se caracteriza por su inestabilidad y la presencia de artefactos. La iteración continua y la capacidad de ajuste dinámico de XGBoost proporcionan una mayor estabilidad en la clasificación, haciendo que el sistema sea más confiable incluso en condiciones experimentales subóptimas. Asimismo, la integración de XGBoost con algoritmos de procesamiento de señales permite aprovechar datos de múltiples sensores biométricos, abriendo la posibilidad de crear soluciones híbridas que mejoren aún más la precisión y robustez de los sistemas BCI.

El análisis comparativo entre diferentes metodologías de clasificación revela que, a pesar de los notables avances en modelos basados en aprendizaje profundo, XGBoost ofrece una combinación de eficiencia, precisión y adaptabilidad que resulta fundamental para aplicaciones en el ámbito clínico y de rehabilitación. Este rendimiento superior se traduce en una mayor capacidad para traducir intenciones neuronales en comandos precisos, reduciendo el error en la interpretación de las señales y facilitando la integración en dispositivos con recursos limitados. Además, la escalabilidad del modelo permite su aplicación en entornos de gran variabilidad, lo que abre un camino prometedor para futuras investigaciones que busquen combinar lo mejor de ambos paradigmas.

En conclusión, la evaluación del rendimiento de XGBoost resalta no solo su superioridad en términos de métricas tradicionales, sino también su idoneidad para ser implementado en sistemas BCI reales y en tiempo real. La capacidad del modelo para manejar datos complejos y ruidosos, junto con su eficiencia computacional y robustez, lo posiciona como una herramienta clave en el avance de la tecnología de interfaces cerebro-máquina. Este análisis profundo y detallado sugiere que, al continuar perfeccionando estos métodos y combinándolos con técnicas multimodales, se podrán superar muchas de las limitaciones actuales en la decodificación de señales cerebrales, impulsando de manera significativa el campo hacia aplicaciones más precisas y de mayor impacto.

El rendimiento de estos modelos también se ha evaluado en términos de estabilidad y consistencia a lo largo del tiempo, siendo crucial realizar análisis de validación cruzada y pruebas en diferentes condiciones experimentales. Los modelos recurrentes, a pesar de su potencial para captar dependencias temporales, muestran dificultades para adaptarse a la variabilidad dinámica de las señales EEG, lo que se traduce en una menor capacidad de generalización en entornos reales. La integración de técnicas de regularización y la exploración de modelos híbridos, que combinen la capacidad de los Transformers con métodos clásicos, podrían ofrecer soluciones para superar estas limitaciones.

En conclusión, la evaluación del rendimiento de los modelos de clasificación destaca tanto sus avances como las áreas críticas de mejora. La comparación entre las arquitecturas recurrentes y XGBoost subraya la necesidad de estrategias de modelado adaptativo y la integración de fuentes de datos biométricos adicionales para compensar las debilidades del registro exclusivo mediante EEG. Estos hallazgos, respaldados por estudios previos, establecen un sólido punto de partida para futuras investigaciones orientadas a optimizar la precisión, la robustez y la aplicabilidad de los sistemas BCI en entornos clínicos y de asistencia, abriendo el camino a innovaciones que podrían transformar radicalmente la interacción cerebro-máquina.

#### *7.3.4. Análisis de Usabilidad y Experiencia del Usuario*

El análisis de usabilidad y experiencia del usuario (UX), se presenta como un componente esencial en la evaluación integral de sistemas BCI, ya que no basta que la tecnología funcione a nivel técnico, si no resulta intuitiva y cómoda para el usuario final. En el contexto de esta tesis, la búsqueda de integración de la adquisición de señales EEG con diademas de bajo costo, con sistemas de control robótico y de sillas de ruedas autónomas se ha diseñado para ofrecer una interfaz que se adapte de manera natural a las necesidades y limitaciones de los usuarios/pacientes. El paper de Rivas et al. (2024) proporciona una base sólida en la que se evidencian mejoras significativas en la interacción usuario-sistema mediante la aplicación de principios de diseño centrado en el usuario, optimizando

tanto la respuesta en tiempo real como la adaptabilidad del sistema a diferentes perfiles.

La posibilidad de recibir confirmación inmediata de las acciones, a través de la aplicación creada, combinada con la adaptación automática de los parámetros de control, contribuye a reducir la carga cognitiva en el usuario, lo cual es crucial en aplicaciones destinadas a usuarios con discapacidades motoras o neurodegenerativas.

La usabilidad del sistema también se refleja en la facilidad de integración y personalización, permitiendo a los usuarios reentrenar y “finetunear” el modelo de predicción a través de la interfaz según sus preferencias y limitaciones. Estos aspectos fueron especialmente valorados por los usuarios durante las sesiones de prueba, quienes apreciaron la flexibilidad y la capacidad del sistema para aprender y adaptarse a patrones de uso específicos.

Se ha de considerar también que la usabilidad de este sistema BCI en pacientes con enfermedades neurodegenerativas, como la ELA, adquiere una relevancia crítica, ya que estos individuos suelen experimentar una pérdida progresiva de la capacidad motora, mientras que, en muchos casos, mantienen relativamente intactas funciones cognitivas de áreas como la corteza prefrontal, zona clave donde las diademas seleccionadas para la investigación, toman los datos de las señales EEG. Esta preservación permite que, mediante un diseño centrado en el usuario, se pueda aprovechar la capacidad residual para generar comandos a través de señales EEG. Nuestra propuesta, basada en interfaces no invasivas y de bajo costo, se adapta a las necesidades específicas de este colectivo, proporcionando una vía alternativa para la comunicación y el control de dispositivos de asistencia. Los algoritmos de procesamiento de señales y clasificación, que nos proporciona la red XGBoost, que operan en tiempo real con tiempos de inferencia inferiores a 15 milisegundos, se han optimizado para captar incluso las fluctuaciones sutiles en la actividad cerebral, ofreciendo así una experiencia que minimiza la carga cognitiva y maximiza la autonomía del usuario.

Además, la integración de mecanismos de retroalimentación a través de respuestas visuales resulta esencial para reforzar la confianza y la comodidad del

usuario, especialmente en contextos donde la interpretación errónea de la intención puede tener consecuencias críticas. Estudios previos han demostrado que los sistemas que incorporan feedback en tiempo real no solo mejoran la precisión en la ejecución de tareas, sino que también contribuyen significativamente al bienestar emocional y psicológico de los usuarios con discapacidades motoras severas [187], [188]. Así, al proporcionar una interfaz intuitiva y adaptable, el sistema no solo facilita la operación de dispositivos de asistencia, sino que también promueve una mayor independencia y calidad de vida, estableciendo un precedente para la implementación de soluciones BCI en el ámbito de la neurorrehabilitación y la asistencia personalizada en enfermedades neurodegenerativas[189].

En conclusión, el análisis de usabilidad y experiencia del usuario demuestra que la propuesta desarrollada en esta tesis no solo cumple con los requisitos técnicos, sino que también se alinea con los principios fundamentales del diseño centrado en el usuario. La combinación de hardware accesible, algoritmos avanzados y una interfaz intuitiva se traduce en una experiencia de usuario superior, crucial para la aceptación y efectividad de las tecnologías BCI en aplicaciones de asistencia y rehabilitación. Estos hallazgos subrayan el potencial de la integración de EEG con sistemas robóticos y destacan áreas de mejora para futuras investigaciones, orientadas a optimizar la interacción y el confort del usuario final.

#### *7.3.5. Comparación con Sistemas Existentes*

A continuación, se presenta una tabla comparativa que sintetiza los principales aspectos y ventajas de la propuesta desarrollada en esta tesis en comparación con sistemas existentes, basándose en la evidencia y referencias del ámbito de BCIs:

*Tabla 56: Comparativa de aspectos principales y ventajas de la propuesta*

Aspecto	Tesis (Propuesta)	Sistemas Existentes
Fuente de Señales EEG	Utiliza señales EEG en bruto provenientes de dispositivos de bajo coste (NeuroSky, Brainlink), lo que permite mayor transparencia y personalización.	La mayoría de los sistemas comerciales emplean algoritmos propietarios (por ejemplo, eSense) o dispositivos médicos de alta precisión, con menor flexibilidad.
Algoritmo de Predicción	Emplea modelos de deep learning (LSTM y GRU) optimizados mediante RandomSearch, alcanzando tiempos de inferencia inferiores a 50 ms para predicción en tiempo real.	Muchos sistemas existentes utilizan algoritmos predefinidos que limitan la capacidad de adaptación y suelen ofrecer menores índices de precisión en contextos dinámicos.
Algoritmos de Clasificación	Empleo de algoritmo de aprendizaje automático <b>basado en árboles de decisión optimizados</b> , que utiliza técnicas de boosting para mejorar la precisión en tareas de clasificación y regresión asignando patrones EEG a categorías específicas como intenciones motoras o estados cognitivos, mediante votación ponderada de los árboles.	
Usabilidad y Experiencia de Usuario	Diseñado con una interfaz intuitiva y retroalimentación multimodal (visual, auditiva y táctil) que reduce la carga cognitiva, favoreciendo la adaptación en usuarios con enfermedades neurodegenerativas.	Muchos sistemas existentes presentan interfaces menos flexibles y personalizables, que no se adaptan completamente a las necesidades de pacientes con discapacidades severas.
Costo y Portabilidad	La arquitectura propuesta tiene un costo de integración inferior a 1500 EUR, aprovechando dispositivos como el Jetson Nano, lo que facilita la portabilidad y democratiza el acceso a tecnologías BCI.	Las soluciones de alta gama suelen tener costos elevados y una implementación más compleja, lo que limita su adopción en entornos no clínicos y reduce la portabilidad.

La propuesta de esta tesis se distingue notablemente frente a los sistemas existentes por su enfoque integral que combina la adquisición de señales EEG en

bruto mediante dispositivos de bajo coste con algoritmos de deep learning avanzados, específicamente redes LSTM y GRU. A diferencia de las soluciones comerciales que dependen de algoritmos cerrados y preprocesamientos fijos, nuestra metodología permite una mayor transparencia y personalización en el procesamiento de la señal. Esto se traduce en una capacidad superior para capturar la complejidad de las dinámicas cerebrales, facilitando predicciones precisas de estados cognitivos como la atención y la meditación. La integración de la arquitectura en una plataforma basada en ROS, junto con hardware de alto rendimiento como el Jetson Nano y microcontroladores Arduino, asegura no solo una respuesta en tiempo real (con tiempos de inferencia inferiores a 50 ms) sino también una robustez en la ejecución de comandos para el control de dispositivos de asistencia, como sillas de ruedas y brazos robóticos.

En términos de usabilidad, el sistema diseñado incorpora interfaces intuitivas y mecanismos de retroalimentación multimodal (visual, auditiva y táctil) que permiten al usuario confirmar de manera inmediata que sus intenciones han sido correctamente interpretadas y ejecutadas. Esta característica es especialmente valiosa en contextos de aplicaciones para personas con enfermedades neurodegenerativas, como la ELA, donde la precisión y la fiabilidad en la traducción de la actividad cerebral en comandos prácticos son fundamentales para garantizar la autonomía y la seguridad. La flexibilidad del sistema para adaptarse a las necesidades individuales y su capacidad para reducir la carga cognitiva, gracias a la personalización de los parámetros de control, ofrecen una experiencia significativamente mejorada en comparación con los métodos tradicionales que resultan menos adaptables y más rígidos en su funcionamiento.

Además, al emplear una aproximación basada en deep learning, la tesis demuestra que los modelos de redes neuronales pueden superar las limitaciones de los métodos clásicos en términos de precisión y capacidad de generalización. La evaluación comparativa muestra que, mientras los sistemas tradicionales ofrecen soluciones inmediatas, estos se quedan cortos al enfrentarse a la variabilidad intrínseca de las señales EEG, limitando su aplicabilidad en entornos dinámicos y reales. La capacidad de los modelos LSTM y GRU para aprender patrones

temporales complejos directamente a partir de datos en bruto permite una adaptación continua y una mejora progresiva de la precisión de la predicción, lo que es esencial para aplicaciones en tiempo real donde la latencia y la adaptabilidad son críticas.

Finalmente, la integración de esta propuesta en un entorno práctico no solo reduce los costos y aumenta la accesibilidad de la tecnología BCI, sino que también abre la puerta a futuras innovaciones. La escalabilidad del sistema y la posibilidad de incorporar datos multimodales (como EMG o fNIRS) potencian aún más su rendimiento y robustez. Este enfoque no solo tiene el potencial de transformar la interacción entre el cerebro y los dispositivos de asistencia, sino que también sienta las bases para desarrollos futuros en el campo de la neurorehabilitación, permitiendo que soluciones de alta tecnología sean implementadas de manera económica y accesible para mejorar la calidad de vida de los usuarios.

## 8. Conclusiones y Trabajos Futuros

La presente investigación ha permitido consolidar una serie de contribuciones en el ámbito de las interfaces cerebro-computadora, especialmente en la aplicación de técnicas híbridas que combinan modelos clásicos como XGBoost con redes neuronales para la clasificación de señales EEG de bajo coste. En este trabajo se ha demostrado la viabilidad de implementar soluciones que, pese a las limitaciones inherentes a dispositivos comerciales, logran alcanzar Precisiones significativas y tiempos de inferencia reducidos, elementos esenciales para el control de dispositivos físicos en entornos embebidos. Las conclusiones extraídas a lo largo de la tesis resaltan no solo el potencial de estos enfoques para superar barreras en la clasificación de estados cognitivos y comandos motores, sino también la importancia de una meticulosa integración de procesos de preprocesamiento, ingeniería de características y optimización de hiperparámetros que han permitido la obtención de resultados robustos y reproducibles en contextos de aplicación real.

Por otro lado, el análisis crítico de las limitaciones detectadas y las oportunidades emergentes abre un amplio espectro para futuras líneas de investigación. Entre los principales retos identificados se encuentran la variabilidad intersujeto, la necesidad de mejorar la generalización en condiciones dinámicas y la integración de modelos en plataformas de hardware embebido con recursos limitados. En este sentido, se vislumbra como prometedor el desarrollo de arquitecturas híbridas más sofisticadas, la incorporación de técnicas de aprendizaje transferido y la realización de estudios longitudinales que evalúen la usabilidad y la estabilidad del sistema en escenarios del mundo real. Estas direcciones no solo enriquecerán el conocimiento teórico en el campo, sino que también facilitarán la transición de las aplicaciones BCI desde entornos controlados de laboratorio hacia su implementación práctica y escalable en la vida cotidiana.

### 8.1. Resumen de Contribuciones

El presente estudio aporta contribuciones significativas al desarrollo de sistemas BCI basados en señales EEG de bajo coste, demostrando que es factible alcanzar niveles de rendimiento robustos a partir de dispositivos comerciales.

### 8.1.1. **Áreas Potenciales de predicción para la Investigación Futura**

Para futuras investigaciones, se sugiere explorar la integración de múltiples fuentes de datos, tales como información fisiológica adicional o datos contextuales, con el fin de mejorar aún más la precisión de las predicciones. Asimismo, sería valioso investigar la aplicabilidad y eficacia de estos modelos en entornos reales, como el ámbito educativo o sanitario, en los que la predicción precisa de los estados de atención y meditación podría tener implicaciones directas en la personalización de intervenciones y tratamientos.

- **Aplicaciones pasivas de BCI:** La detección de la atención auditiva basada en EEG y sus posibles aplicaciones futuras en sistemas BCI pasivos constituyen un área emergente. Estas aplicaciones podrían revolucionar la forma en que interactuamos con la tecnología, permitiendo una comunicación más fluida y natural con dispositivos y sistemas [186].
- **Neurofeedback en la meditación:** La meditación se considera una forma de entrenamiento mental con potencial terapéutico y beneficios cognitivos. El entrenamiento mediante neurofeedback basado en EEG tiene el potencial de aumentar la efectividad de la meditación al proporcionar retroalimentación en tiempo real a los practicantes [187].
- **Entornos virtuales y atención:** La detección de la atención en entornos virtuales mediante señales EEG es un área en crecimiento. Estos métodos podrían resultar cruciales para diseñar entornos virtuales que se adapten de forma dinámica a la atención del usuario [188].
- **Interacción entre diferentes tipos de meditación:** Investigar las diferencias y similitudes entre técnicas de meditación "interna" y "externa" podría proporcionar información valiosa para optimizar las prácticas meditativas y adaptarlas a las necesidades específicas de cada individuo [189], [190].
- **Asimetría interhemisférica en la meditación:** Investigaciones recientes han observado patrones de sincronización espacial en el EEG durante distintos tipos de meditación. Estos patrones pueden ser fundamentales para comprender cómo diversas prácticas meditativas afectan el funcionamiento cerebral [191].
- **Aplicaciones a largo plazo de sEEG para BCI:** La exploración sobre el uso de la estimulación cerebral profunda (DBS) y de implantes sEEG para aplicaciones de BCI a largo plazo constituye un área prometedora [192].

Estas áreas sugeridas para futuras investigaciones no solo amplían el alcance del campo de la predicción basada en EEG de los estados de atención y meditación,

sino que también abren nuevas vías para aplicaciones prácticas e investigaciones clínicas .

Además, al centrarse en la predicción en tiempo real, nuestra investigación tiene el potencial de superar las limitaciones de los estudios tradicionales basados en EEG, que a menudo dependen de datos post-procesados. La capacidad de interpretar y actuar sobre las señales cerebrales en tiempo real podría dar lugar a intervenciones más efectivas y adaptativas, abarcando desde la mejora del rendimiento cognitivo hasta el apoyo en el tratamiento de trastornos neurológicos.

Es importante destacar que, si bien la atención y la meditación son estados cognitivos de gran interés para la neurociencia, su predicción y clasificación también poseen implicaciones prácticas significativas. La atención está estrechamente vinculada a la capacidad de aprendizaje, la memoria y la toma de decisiones, mientras que la meditación se asocia con la reducción del estrés, la mejora de la salud mental y el bienestar general. Al proporcionar herramientas y métodos para predecir estos estados en tiempo real, nuestra investigación tiene el potencial de influir en áreas tan diversas como la educación, la salud mental y la rehabilitación neurológica.

La relevancia de este estudio evidencia su potencial para avanzar en el campo de la predicción basada en EEG de los estados de atención y meditación. A medida que la sociedad avanza hacia un mundo cada vez más interconectado, en el que dispositivos y sensores son ubicuos, la capacidad de interpretar y actuar sobre las señales cerebrales en tiempo real se vuelve cada vez más crucial [51]. La aplicación de técnicas avanzadas de aprendizaje automático en este dominio no solo puede mejorar la precisión de las predicciones, sino que también puede abrir nuevas vías para intervenciones personalizadas y terapias basadas en la atención plena y la meditación.

En conclusión, esta investigación no solo refuerza la importancia del campo de la predicción basada en EEG de los estados de atención y meditación, sino que también establece nuevos estándares y abre caminos inexplorados para futuras investigaciones. Al combinar técnicas avanzadas de aprendizaje automático con datos en tiempo real provenientes de dispositivos EEG comerciales, estamos sentando las bases para una nueva era en la comprensión y aplicación de la neurociencia en la vida cotidiana.

#### *8.1.2. Resumen de las principales conclusiones del proceso de predicción:*

Tomando como referencia los recientes avances en materia de predicción en tiempo real mediante el empleo de datos de EEG y en virtud de las capacidades intrínsecas de las RNN, particularmente LSTM y GRU, para la modelación y predicción de secuencias temporales, el presente estudio constituye un avance

significativo en el ámbito de la predicción en tiempo real de la atención y la meditación, haciendo uso de datos de EEG no procesados provenientes de dispositivos comerciales tales como Neurosky y Brainlink. La capacidad de predecir con exactitud estos estados cognitivos tiene profundas implicaciones no solo para la neurociencia y la psicología, sino también para aplicaciones prácticas como la mejora del rendimiento cognitivo, la meditación guiada y la interfaz cerebro-ordenador.

La predicción en tiempo real de la atención y la meditación a partir de señales de EEG (Electroencefalograma) sin procesar constituye un desafío debido a la naturaleza no estacionaria y ruidosa de dichas señales. No obstante, mediante el empleo de redes neuronales recurrentes, tales como LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit), se ha logrado captar la dinámica temporal y las dependencias a largo plazo presentes en los datos de EEG. Estas redes han demostrado una eficacia notable en la modelización de datos secuenciales, como lo demuestran estudios recientes que investigan la predicción en tiempo real de diversos fenómenos mediante EEG.

La integración de dispositivos comerciales, tales como Neurosky y Brainlink, en el marco de nuestro estudio, ha propiciado una ampliación en la aplicabilidad y accesibilidad de nuestra investigación. Estos dispositivos, caracterizados por su menor costo y facilidad de uso en comparación con los sistemas de EEG convencionales, tienen el potencial de fomentar la adopción de nuestras técnicas de predicción en aplicaciones prácticas.

En síntesis, la presente tesis no únicamente corrobora la factibilidad de anticipar la atención y la meditación en tiempo real mediante el empleo de datos de EEG no procesados, sino que, adicionalmente, subraya el potencial de las redes neuronales recurrentes (RNN), particularmente las de largo corto (LSTM) y las de grueso y reducido (GRU), en este contexto. Mientras perfeccionamos y mejoramos nuestros modelos, se espera que nuestras contribuciones sirvan de referencia en el campo de la predicción basada en EEG y allanen el camino para futuras investigaciones y aplicaciones prácticas.

A lo largo de nuestra investigación, se han obtenido varios hallazgos clave que ponen de relieve la eficacia y el potencial de las redes neuronales recurrentes en la interpretación de datos de EEG en tiempo real para predecir estados de atención y meditación.

En lo que respecta a la precisión de predicción, se observó que las redes LSTM y GRU exhibieron una elevada precisión en la predicción de estados atencionales y meditativos a partir de datos de EEG no procesados. Este resultado superó significativamente al de los algoritmos tradicionales y al del algoritmo propio de Neurosky.

En lo que respecta al rendimiento en tiempo real, a pesar de la intrincada naturaleza de las redes neuronales, el modelo optimizado demostró una capacidad de funcionamiento en tiempo real, posibilitando una interpretación inmediata de los estados cognitivos del usuario.

- **Comparación de modelos:** Entre las RNNs evaluadas, las redes GRU mostraron un ligero margen de superioridad en términos de métricas como RMSE y SMAPE en comparación con las redes LSTM.
- **Aplicabilidad práctica:** Los movimientos voluntarios promovidos por el usuario basados en estados de atención y meditación se clasificaron con una precisión del XX%, lo que sugiere un alto potencial para aplicaciones prácticas como la rehabilitación neurológica y las interfaces cerebro-ordenador avanzadas.
- **Generalización de los resultados:** Mediante técnicas de validación cruzada, confirmamos que nuestros modelos no solo funcionan bien en nuestro conjunto de datos, sino que también tienen potencial para generalizarse a otros conjuntos de datos y contextos.

En síntesis, esta parte del estudio vinculado a esta tesis ha evidenciado que es factible, y sumamente eficiente, emplear redes neuronales recurrentes para interpretar y predecir estados cognitivos en tiempo real a partir de datos de EEG no procesados. Estos hallazgos establecen los fundamentos para investigaciones y aplicaciones prácticas futuras en el ámbito de la neurociencia y la interacción persona-máquina.

La integración de técnicas avanzadas de preprocesamiento, como la normalización con RobustScaler y la eliminación de valores atípicos, junto con una exhaustiva ingeniería de características, ha permitido transformar datos inicialmente ruidosos

y limitados en insumos valiosos para la clasificación. Esta labor metodológica sienta las bases para que sistemas de bajo coste puedan competir en precisión con soluciones tradicionales de mayor envergadura, abriendo el camino hacia una democratización real de las tecnologías BCI.

En el ámbito de la modelización, la tesis evidencia la viabilidad de implementar modelos de redes neuronales recurrentes (LSTM y GRU) optimizados para la predicción de estados cognitivos y la clasificación de comandos motores. Se ha demostrado que, a través de un cuidadoso ajuste de hiperparámetros y la aplicación de técnicas de regularización, es posible mitigar problemas comunes como el sobreajuste y la alta variabilidad de usuarios de los sistemas BCI. Además, la comparación crítica con modelos clásicos, en particular XGBoost, revela que la combinación de estrategias basadas en boosting de árboles con enfoques de aprendizaje profundo puede ofrecer soluciones más estables y precisas, evidenciando una sinergia prometedora entre paradigmas aparentemente divergentes.

Una contribución destacada del trabajo es la optimización de los tiempos de inferencia, aspecto crucial para la implementación en entornos embebidos como Jetson Nano o Raspberry Pi. La eficiencia computacional de XGBoost, combinada con el riguroso proceso de validación experimental, garantiza una baja latencia que permite la ejecución en tiempo real, esencial para aplicaciones de control de dispositivos físicos. Esta capacidad no solo refuerza la aplicabilidad práctica del sistema desarrollado, sino que también posiciona el modelo como una opción ideal para la transición de las BCI desde entornos de laboratorio hacia aplicaciones del mundo real.

Finalmente, la tesis establece un marco conceptual y metodológico sólido que contribuye al avance científico en interfaces cerebro-computadora. Las aportaciones realizadas no solo ofrecen resultados cuantitativos y cualitativos robustos, sino que también plantean nuevas líneas de investigación, como la hibridación de modelos y la adaptación de algoritmos a plataformas de hardware de recursos limitados. Este enfoque integral no solo mejora la precisión y la estabilidad en la clasificación de señales EEG, sino que también sienta las bases

para futuros desarrollos que puedan integrar inteligencia artificial avanzada en sistemas BCI más accesibles y escalables, potenciando así su impacto en aplicaciones clínicas, asistenciales y de rehabilitación.

Los hallazgos obtenidos en este estudio presentan diversas implicaciones significativas y abren la puerta a múltiples aplicaciones prácticas en ámbitos como las interfaces cerebro-computadora (BCI), la neurociencia cognitiva y la salud mental. La capacidad de predecir con precisión los estados atencionales y meditativos a partir de señales EEG, mediante el uso de redes LSTM y GRU, tiene el potencial de generar un impacto positivo en varias áreas de gran relevancia.

#### *8.1.3. Implicaciones de la investigación y la Clasificación para la tecnología en BCI*

- **Mejora de las interfaces cerebro-computadora:** La integración de modelos LSTM y GRU en dispositivos BCI podría permitir la obtención de retroalimentación en tiempo real respecto a los estados de atención y meditación de los usuarios. Este avance es especialmente valioso en aplicaciones que requieren una concentración sostenida, tales como el aprendizaje o la conducción, pues optimiza la interacción entre el ser humano y la máquina.
- **Personalización de la experiencia del usuario:** Al comprender y predecir los estados cognitivos, las aplicaciones pueden adaptarse de manera dinámica a las necesidades específicas de cada usuario, mejorando así la experiencia en entornos de realidad virtual, videojuegos y aplicaciones educativas. Esta capacidad de adaptación contribuye a desarrollar interfaces más intuitivas y eficientes que responden a las variaciones individuales.

#### *8.1.4. Aplicaciones en salud mental y bienestar*

- **Monitoreo y mejora del bienestar mental:** Los dispositivos portátiles equipados con sensores EEG, combinados con los modelos predictivos desarrollados, podrían utilizarse para monitorear de forma continua los niveles de estrés y el bienestar mental. Esto permitiría implementar intervenciones oportunas, tales como ejercicios de respiración o sesiones

de meditación guiada, favoreciendo una gestión proactiva de la salud mental.

- **Terapias personalizadas:** En el ámbito clínico, dichos modelos podrían ser empleados para personalizar terapias dirigidas a trastornos de atención o meditación, como el TDAH o la ansiedad. La capacidad de ajustar las intervenciones en tiempo real en función de la respuesta cerebral del paciente ofrece la posibilidad de desarrollar tratamientos más precisos y eficaces[193].

#### *8.1.5. Implicaciones para la educación y la formación*

- **Mejora de las herramientas educativas:** Los sistemas educativos podrían incorporar estos modelos para evaluar y optimizar la capacidad de concentración de los estudiantes durante las actividades de aprendizaje. La adaptación del contenido en función de la atención sostenida de los alumnos permitiría mantener un nivel óptimo de compromiso y mejorar los procesos de enseñanza-aprendizaje.
- **Entrenamiento en atención:** En entornos de alto rendimiento, tales como el deporte o la música, estos modelos podrían utilizarse para entrenar a los individuos en técnicas de concentración y meditación. Este enfoque contribuiría a potenciar el rendimiento global, facilitando el desarrollo de habilidades cognitivas que resultan cruciales para alcanzar la excelencia en diversas disciplinas [92]

#### *8.1.6. Investigación futura en neurociencia cognitiva*

- **Comprensión de los procesos cognitivos:** Los resultados obtenidos podrían sentar las bases para estudios futuros orientados a desentrañar los mecanismos neuronales subyacentes en los procesos de atención y meditación. Esta línea de investigación contribuiría de manera significativa al enriquecimiento del conocimiento científico en el ámbito de la neurociencia cognitiva, permitiendo comprender de forma más profunda cómo se generan y regulan estos estados a nivel cerebral.
- **Desarrollo de biomarcadores:**

La capacidad para predecir estados cognitivos a partir de señales EEG abre la posibilidad de desarrollar biomarcadores específicos para diversas condiciones neurológicas y psiquiátricas. Estos indicadores podrían resultar esenciales en la detección temprana, el diagnóstico y el seguimiento de trastornos, facilitando intervenciones más precisas y personalizadas en el campo de la salud mental.

#### 8.1.7. *Desafíos y consideraciones éticas*

- **Privacidad y seguridad de los datos:** La implementación de estas tecnologías exige una atención rigurosa a la privacidad y seguridad de los datos EEG, ya que estos constituyen información biométrica de carácter sumamente sensible. Es imprescindible establecer protocolos y normativas que garanticen la protección de la información personal, evitando posibles vulneraciones que puedan comprometer la integridad de los usuarios.
- **Accesibilidad y equidad:** Resulta crucial considerar los aspectos de accesibilidad y equidad en el desarrollo e implementación de aplicaciones de interfaces cerebro-computadora (BCI). Es fundamental asegurar que los beneficios derivados de estas innovaciones sean accesibles a un amplio espectro de usuarios, evitando la creación de brechas tecnológicas que puedan limitar el acceso a estas herramientas.

Los resultados de esta investigación tienen el potencial de enriquecer la interacción entre humanos y computadoras, mejorar la salud mental y el bienestar, y avanzar en la comprensión de los procesos cognitivos. Sin embargo, para maximizar los beneficios y minimizar los riesgos potenciales, es crítico abordar de forma integral tanto los desafíos éticos como los prácticos asociados a la aplicación de estas tecnologías.

Para una discusión más detallada y específica sobre las aplicaciones de BCI y EEG en la detección de fatiga mental, el estudio "Application of Artificial Intelligence Techniques for Brain-Computer Interface in Mental Fatigue Detection: A Systematic Review (2011-2022)" ofrece una revisión sistemática relevante [164]. Además, el análisis "EEG-based Biometric Authentication Using Machine Learning: A Comprehensive Survey" proporciona una visión general de las aplicaciones de EEG

en la autenticación biométrica y podría aportar valiosos insights para futuras aplicaciones de modelos LSTM y GRU en este campo [[194].

## 8.2. Impacto en el Desarrollo de Sistemas BCI

El impacto en el desarrollo de sistemas BCI se evidencia en la convergencia de avances en neurociencia, ingeniería y algoritmos de inteligencia artificial, que han permitido transformar paradigmas tradicionales de rehabilitación y comunicación. Por ejemplo, en el ámbito de la rehabilitación motora post ictus, un metaanálisis reciente reportó un efecto estandarizado (SMD) de 0.79 en la Fugl-Meyer Assessment del miembro superior, superando significativamente otras terapias como la terapia de espejo (SMD 0.61) o el entrenamiento de movimiento asistido (SMD 0.35)[195]. Estos datos estructurados justifican que las BCI pueden inducir cambios clínicamente relevantes, facilitando la reorganización neuroplástica y mejorando la función motora en pacientes con lesiones neurológicas severas.

En el campo de la comunicación, estudios de proyectos como BrainGate han demostrado la viabilidad de convertir intenciones neuronales en comandos precisos para controlar dispositivos externos. Por ejemplo, en investigaciones publicadas en Nature se ha documentado que pacientes con parálisis han logrado mover un cursor o manipular brazos robóticos con una tasa de acierto considerable, lo que se traduce en mejoras significativas en la autonomía y calidad de vida. Además, en ensayos clínicos recientes, dispositivos implantados en áreas motoras han permitido alcanzar Precisiones de decodificación de hasta el 97% en tareas de generación de habla, evidenciando una rápida adaptación del sistema a la actividad neuronal del usuario.

Comparativamente, cuando se analizan métodos invasivos versus no invasivos, se observa que las BCI invasivas ofrecen una mayor precisión en la captación de señales, mientras que las no invasivas, basadas en EEG, presentan menores riesgos, pero desafíos en la atenuación de la señal. Un ejemplo concreto es la aplicación de algoritmos optimizados mediante técnicas como XGBoost en sistemas EEG, los cuales han permitido reducir los tiempos de inferencia lo suficiente como para ejecutarse en entornos embebidos (ej., Jetson Nano o

Raspberry Pi), abriendo así la posibilidad de integración en dispositivos portátiles y de asistencia en tiempo real.

Estos avances, respaldados por datos cuantitativos y estudios comparativos, indican que los sistemas BCI están revolucionando el campo de la neurotecnología. La mejora en las métricas de rehabilitación, la alta precisión en la decodificación de intenciones comunicativas y la eficiencia computacional para aplicaciones en tiempo real no solo demuestran el valor clínico inmediato de estas interfaces, sino que también sientan las bases para futuras innovaciones. Esta convergencia tecnológica promete ampliar la autonomía humana y transformar radicalmente la interacción entre cerebro y máquina, abriendo nuevas fronteras en el tratamiento de discapacidades y en la mejora de las capacidades cognitivas y motoras.

### 8.3. Limitaciones del Estudio

A pesar de los resultados prometedores y del avance significativo que representa este trabajo en el desarrollo de interfaces cerebro-computadora (BCI), es crucial reconocer que el estudio presenta ciertas limitaciones que deben abordarse en investigaciones futuras. En primer lugar, el tamaño y la diversidad de la muestra representan una restricción importante. Si bien se han obtenido resultados robustos en los ensayos realizados, la limitada cantidad de participantes. Este aspecto incide, por ejemplo, en la adaptabilidad del sistema ante la variabilidad de la tipología de usuario en las señales EEG, lo que se traduce en un margen de error que aún requiere ser reducido.

Otra limitación relevante radica en la metodología de adquisición y procesamiento de las señales EEG. A pesar de las técnicas avanzadas de preprocesamiento empleadas, la inherente baja relación señal-ruido y la naturaleza no estacionaria de la actividad cerebral dificultan la extracción de características consistentes y precisas. Esto afecta la decodificación de intenciones y, en consecuencia, la fiabilidad del sistema en aplicaciones en tiempo real. Por ello, se hace necesario perfeccionar tanto el preprocesado como los modelos de aprendizaje automático, posiblemente integrando otras modalidades de señal (por ejemplo, electromiografía o señales fNIRS) para complementar la información proveniente del EEG.

Asimismo, la transición del sistema a entornos embebidos, como dispositivos portátiles o plataformas de bajo costo (e.g., Jetson Nano o Raspberry Pi), aún enfrenta desafíos en términos de escalabilidad, estabilidad y robustez operativa en condiciones reales. Aunque se han demostrado tiempos de inferencia reducidos en entornos controlados, la aplicación práctica del sistema en escenarios cotidianos requerirá pruebas adicionales que consideren variables como la interferencia ambiental, la ergonomía del dispositivo y la durabilidad de los componentes.

Finalmente, desde una perspectiva ética y regulatoria, el estudio aborda de manera preliminar cuestiones sobre la privacidad de los datos cerebrales y el consentimiento informado, pero estos aspectos deben profundizarse en futuras investigaciones. La implementación de BCI, especialmente en contextos clínicos y de mejora cognitiva, plantea desafíos éticos que incluyen la protección de la intimidad mental y el manejo responsable de información tan sensible. Reconocer estas limitaciones no debilita el valor del trabajo realizado; por el contrario, subraya la necesidad de continuar investigando y refinando estas tecnologías para garantizar su implementación segura y equitativa en el futuro.

#### 8.4. Líneas de Investigación Futura

La necesidad de profundizar y expandir el conocimiento en interfaces cerebro-computadora (BCI) se convierte en el pilar para definir las líneas de investigación futura. A partir de las limitaciones identificadas en la presente tesis, como la variabilidad intersujeto, la baja relación señal-ruido en el procesamiento de EEG y las implicaciones éticas asociadas, se abre un abanico de oportunidades para desarrollar sistemas híbridos que integren metodologías de aprendizaje profundo con técnicas clásicas, optimizando así la precisión y la eficiencia de la decodificación neuronal. Además, resulta imperativo investigar protocolos de entrenamiento personalizados, mejorar la integración en entornos embebidos y establecer marcos éticos robustos que aseguren la privacidad y la seguridad de los datos cerebrales, abriendo el camino para aplicaciones tanto clínicas como de asistencia en la vida cotidiana.

#### 8.4.1. Exploración de Modelos Basados en Transformers para EEG

Con el gran impacto que han tenido los modelos LLM (Large Language Models), base del desarrollo de modelos como ChatGPT, Claude o Gemini, la aplicación de modelos basados en Transformers a la interpretación de señales EEG podría representar una innovación disruptiva, pues permite abordar de manera eficaz las complejas dependencias temporales y la alta variabilidad que caracterizan a estos datos. Inspirados en el éxito obtenido en el procesamiento del lenguaje natural (Vaswani et al., 2017), estos modelos se destacan por su capacidad para captar relaciones a largo plazo en secuencias temporales, lo que es esencial para decodificar las dinámicas neuronales registradas en un EEG[196]. Esta arquitectura, basada en mecanismos de autoatención y múltiples cabezas (multi-head attention), ofrece una alternativa prometedora a las técnicas tradicionales basadas en redes neuronales recurrentes (RNN) o convolucionales (CNN).

La naturaleza inherente del EEG, con sus señales ruidosas y no estacionarias, demanda un enfoque que pueda adaptarse dinámicamente a variaciones tanto a corto como a largo plazo. Los Transformers, al no depender de estructuras secuenciales rígidas, permiten procesar la totalidad de la señal en paralelo y enfocar la atención en segmentos críticos que portan información relevante. Esta capacidad de distribuir la atención de forma selectiva ayuda a mitigar los efectos del ruido y a extraer patrones significativos que pueden correlacionarse con estados cognitivos o motrices, abriendo nuevas oportunidades para la decodificación precisa de la intención del usuario.

Otra ventaja destacada de los Transformers es su flexibilidad para ser preentrenados en grandes volúmenes de datos no etiquetados y posteriormente ajustados a tareas específicas mediante técnicas de fine-tuning. Esta estrategia de preentrenamiento, ampliamente utilizada en el procesamiento del lenguaje natural, permite que el modelo adquiera representaciones ricas y generalizables que pueden ser muy útiles para aplicaciones en BCI. Estudios preliminares, como el propuesto por Xie et al. (2022) en IEEE, "A Transformer-Based Approach Combining Deep Learning Network and Spatial-Temporal Information for Raw EEG Classification", han mostrado resultados alentadores en la clasificación de estados emocionales y motores a partir de EEG utilizando arquitecturas Transformer.

Asimismo, la incorporación de Transformers en el análisis de EEG no solo mejora la precisión en la detección de patrones, sino que también facilita la interpretación de las características extraídas mediante mecanismos de atención visualmente interpretables. Este aspecto es fundamental en entornos clínicos, ya que permite a los investigadores y clínicos entender y validar las decisiones del modelo, ofreciendo una mayor transparencia y confianza en el sistema. La capacidad de explicar qué segmentos del EEG están siendo relevantes para la clasificación favorece la integración de estas tecnologías en aplicaciones de rehabilitación y monitoreo neurofisiológico.

En líneas futuras, es imperativo continuar explorando y refinando modelos Transformer para EEG, especialmente en combinación con técnicas multimodales que integren otras fuentes de datos fisiológicos (como la electromiografía o fNIRS) y en entornos de BCI personalizados. El objetivo es desarrollar sistemas que no solo logren una alta precisión en la decodificación neuronal, sino que también sean robustos ante la variabilidad inter-sujeto y se integren de forma eficiente en dispositivos embebidos. Este enfoque multidisciplinario promete transformar la práctica clínica y mejorar significativamente la calidad de vida de los usuarios, marcando una nueva era en la interacción cerebro-máquina .

#### 8.4.2. Integración con Sensores Biométricos Adicionales

La integración de sensores biométricos adicionales a las señales EEG se presenta como una estrategia fundamental para enriquecer la capacidad de decodificación de las interfaces cerebro-computadora (BCI). Al fusionar información procedente de diversas modalidades, como la electromiografía (EMG), la electrooculografía (EOG), la espectroscopia funcional del infrarrojo cercano (fNIRS) y otros sensores fisiológicos, se pueden mitigar las limitaciones inherentes al registro exclusivo mediante EEG, tales como la baja relación señal-ruido y la variabilidad intersujeto. Esta aproximación multimodal permite construir representaciones más ricas y precisas del estado cognitivo y motor del usuario, facilitando una interpretación robusta y fiable de sus intenciones.

En concreto, la incorporación de sensores EMG aporta datos sobre la actividad muscular que pueden corroborar o refinar las intenciones detectadas a través de

EEG, especialmente en tareas relacionadas con el control de dispositivos motrices. Asimismo, la EOG proporciona información adicional sobre los movimientos oculares, lo que es crucial para descartar artefactos o complementar la señal en aplicaciones donde el seguimiento visual es relevante. La combinación de estas señales permite al sistema BCI operar en un marco de retroalimentación cerrada que mejora la precisión del control, incrementando la eficiencia en la ejecución de comandos en tiempo real.

Por otra parte, la utilización de fNIRS para monitorizar los cambios en la oxigenación cerebral ofrece una perspectiva hemodinámica complementaria a la actividad eléctrica captada por el EEG. Esta integración permite evaluar no solo la actividad neuronal directa, sino también la respuesta metabólica del cerebro ante estímulos o esfuerzos cognitivos, lo que resulta en una visión holística del estado del usuario. Al combinar estos datos, se potencian los algoritmos de inteligencia artificial que interpretan la información, facilitando una adaptación dinámica y personalizada del sistema de BCI.

Desde una perspectiva aplicada, esta integración multimodal es especialmente relevante en entornos de rehabilitación. Por ejemplo, en programas de neurorrehabilitación, la combinación de EEG con sensores EMG y fNIRS puede ofrecer una retroalimentación más precisa sobre la intención de movimiento y el esfuerzo fisiológico del paciente, permitiendo ajustar en tiempo real la intensidad de estímulos o el tipo de asistencia ofrecida. Esta sinergia no solo mejora la precisión en la detección de la intención de control, sino que también contribuye a optimizar los protocolos de entrenamiento y acelerar el proceso de recuperación funcional.

Finalmente, la integración de sensores biométricos adicionales abre la puerta a aplicaciones innovadoras más allá de la rehabilitación, abarcando áreas como la mejora cognitiva y la monitorización del bienestar en entornos cotidianos. El desarrollo de sistemas BCI que combinen múltiples fuentes de datos fisiológicos promete incrementar la robustez, adaptabilidad y personalización de la tecnología, lo cual es esencial para su adopción en aplicaciones tanto clínicas como de consumo general. Esta línea de investigación, al fusionar avances en neurociencia,

ingeniería y aprendizaje automático, representa un paso decisivo hacia sistemas de BCI de próxima generación.

## ANEXO: Consideraciones Éticas en la Investigación con Sujetos Humanos

El desarrollo de investigaciones que implican la recopilación y análisis de información procedente de sujetos humanos exige una estricta adhesión a principios éticos fundamentales. Este compromiso es indispensable para proteger y respetar la dignidad, privacidad y autonomía de los participantes involucrados. Por ello, el estudio se ha realizado de acuerdo con las normas éticas y, en particular, con lo establecido en la Declaración de Helsinki y demás normativa aplicable, así como con lo establecido en la Declaración Universal sobre Bioética y Derechos Humanos (UNESCO, 2005), el Reglamento General de Protección de Datos de la Unión Europea (Reglamento 2016/679) y la Ley Orgánica 3/2018, de 5 de diciembre, de Protección de Datos Personales y Garantía de los Derechos Digitales y aprobado por el Comité de Bioética de la Universidad de Burgos, U05100001, Burgos (España). **Código de Aprobación: REGAGE24s00009305342 de Fecha de aprobación: 5 de febrero de 2024.**

En este documento se describen minuciosamente las medidas éticas aplicadas, incluyendo el diseño y ejecución del proceso de consentimiento informado, así como los protocolos establecidos para salvaguardar la confidencialidad y seguridad de los datos personales obtenidos. El propósito central es garantizar una total transparencia respecto a la observancia ética del estudio, proporcionando evidencia clara sobre la correcta implementación y cumplimiento de los principios éticos fundamentales a lo largo de todo el proceso de la investigación. El documento presentado se reproduce íntegramente en los mismos términos en los que se presentó y fue aprobado por el comité de bioética.

## Solicitud de informe a la Comisión de Bioética

D./ Dña. Fernando Rivas Navazo con DNI 13.140.050N y teléfono de contacto 646 288 999

### EXPONE:

**Que pretende llevar a cabo el proyecto titulado:  
Control cerebral inalámbrico de dispositivos físicos, mediante inteligencia artificial y tecnologías IoT**

Se adjunta plan de investigación de la tesis doctoral para su evaluación.

### Plan de investigación del...

<b>Doctorando/a:</b>	Fernando Rivas Navazo
<b>Directores de tesis:</b>	Jesús Enrique Sierra José María Cámara
<b>Tipo de trabajo:</b>	Tesis doctoral
<b>Título</b>	Control cerebral inalámbrico de dispositivos físicos, mediante inteligencia artificial y tecnologías IoT

#### 1.- Introducción/Justificación

En el proceso de desarrollo de esta tesis doctoral, la toma de datos de la actividad cerebral, se muestra clave en el proceso de entrenamiento de redes neuronales artificiales, que ayuden a la clasificación de patrones dentro de los datos obtenidos de la actividad cerebral. Los datos son series temporales concretas con valores numéricos, que no aportan valores identificativos del usuario de la diadema EEG.

#### 2.- Objetivos

Los objetivos de esta tesis doctoral y de toma de datos y muestras de la actividad cerebral de una parte concreta del cerebro, en concreto de la parte prefrontal con el uso de electrodos secos no invasivos, es poder clasificar esta actividad cerebral e identificar posibles patrones de acción, gracias al uso de redes neuronales artificiales que permitan en este proceso asociar estas acciones cerebrales con acciones físicas concretas, para posteriormente actuar sobre elementos de ayuda a personas con enfermedades neurodegenerativas, tipo sillas de ruedas motorizadas o brazos robóticos colaborativos, mejorando la calidad de vida de los pacientes con este tipo de enfermedades.

#### 3.- Descripción del proyecto

Sirva como descripción el siguiente resumen de lo que se persigue con esta tesis doctoral.

Las enfermedades neurodegenerativas presentan importantes retos en términos de movilidad y autonomía para los pacientes. En el contexto actual de avances tecnológicos, la interfaz cerebro-ordenador (BCI) emerge como una herramienta prometedora para mejorar la calidad de vida de estos pacientes. Por ello, en este estudio exploramos la viabilidad de utilizar diademas EEG comerciales de bajo coste,

como Neurosky Mindwave y Macrotellect Brainlink, para el control de brazos robóticos integrados en sillas de ruedas autónomas. Estas diademas, que ofrecen valores de atención y meditación, se han adaptado para proporcionar un control intuitivo basado en los ocho valores de señal EEG leídos de Delta a Gamma (Gamma Alta y Gamma Baja/Media) recogidos del área prefrontal de los usuarios, utilizando sólo dos electrodos no invasivos. Para garantizar un control preciso y adaptativo, hemos incorporado una red neuronal que interpreta estos valores en tiempo real, de modo que la respuesta del brazo robótico coincida con las intenciones del usuario. Los resultados sugieren que esta combinación de BCI, robótica y técnicas de aprendizaje automático como las redes neuronales no sólo es técnicamente viable, sino que también tiene el potencial de transformar radicalmente la interacción de los pacientes con enfermedades neurodegenerativas con su entorno.

#### 4.- Material y métodos

El proyecto parte de la recogida de los datos de actividad cerebral, necesarios para el estudio y desarrollo de esta investigación, para lo cual, la toma de datos se realizará contando con la participación de sujetos sanos, completamente voluntarios e informados, que de forma completamente aleatoria, son propuestos por el investigador, todos estos voluntarios, serán informados y firman conscientemente el documento de "Consentimiento Informado" que acompaña esta investigación. Estos voluntarios sanos sin ningún tipo de patología, servirán como muestra patrón, por lo que son el punto de partida de la investigación, atendiendo a la diversidad de sexo y edad, para garantizar la heterogeneidad del estudio. La toma de datos sobre los sujetos voluntarios, se realizará a través de dispositivos en formato diadema comercial de al menos dos marcas comerciales distintas, Neurosky Mindwave y Macrotellect Brainlink, que de forma no invasiva, proporciona la lectura a través de un electrodo seco, de los datos de atención y meditación junto con los valores de la señales Delta, Theta, Alpha, Beta y Gamma, junto con el valor temporal de la serie de la captura.

Al tratarse de diademas comerciales, su uso queda perfectamente definido, dentro de los parámetros de seguridad exigidos para estos dispositivos.

El método de recogida de los datos, como se ha indicado, se realizará usando diademas EEG comerciales, por un tiempo máximo de 10 minutos, lo que permitirá una toma de datos de unos 600 capturas con al menos 10 valores por captura. Estas diademas son elementos no invasivos que no requieren ninguna aplicación ni intervención de personal cualificado al tener un formato tipo diadema que se coloca sobre la frente del individuo y se mantiene por la ligera presión que ejerce la diadema elástica.

La captura de los datos se realiza a través de los software SDK para desarrolladores que nos facilita la propia marca de las diademas. Este software nos permite generar un archivo de datos .CSV donde se almacenan secuencialmente almacenando exclusivamente el valor temporal o timeset, junto con las señales leídas e interpretadas por el hardware de la diadema.

Este archivo por tanto solo dispone de datos numéricos asociados a una trama temporal que determina que estamos tratando con una serie temporal de datos.

El almacenamiento de los archivos .CSV se realiza de forma secuencial al valor de la captura, indicando en el nombre del archivo, el modelo de la diadema, con la siguiente estructura:

- datosEEGBrainlink15.CSV (para el caso de uso de la diadema Brainlink)
- 07092023-DataLog2023-09-07T173335.CSV (para el caso de uso de una diadema Neurosky)

#### 5.- Propuesta de los investigadores para asegurar el cumplimiento de aspectos legales y éticos de la investigación y los derechos de los intervinientes

Partimos de la base que todos los participantes en esta toma de datos lo hacen voluntariamente y son previamente informados de todos los procesos que se realizarán en la toma de muestras. Además, todos estos archivos son almacenados en una carpeta concreta, denominada "DatosEEGCaptural", asociada al resto de los documentos vinculados al desarrollo de la tesis doctoral que se está realizando.

Estos datos además son almacenados en un dispositivo externo HHDD donde se hacen las correspondientes copias de respaldo. Este HHDD se guarda convenientemente para mantener la

garantía de seguridad. En el caso de solicitar el borrado de esta información por parte de cualquiera de los participantes, el archivo será borrado de todos los dispositivos de almacenamiento. Además, todos los participantes en este estudio conocen la finalidad de los datos recogidos y pueden ver en tiempo real los valores tomados por las diademas, tanto los valores numéricos como las gráficas correspondientes al tratarse de una serie temporal de datos. Al tratarse de una investigación con voluntarios sanos, sin patologías neurodegenerativas

#### **6.- Determinación de los beneficios y riesgos potenciales del estudio**

Como se ha comentado en la exposición de los objetivos, los beneficios de este estudio, son claros, al pretender mejorar la calidad de vida de personas con enfermedades neurodegenerativas, permitiendo el acceso y control a dispositivos físicos que aporten esta mejora, de forma remota.

Por otro lado, al enfocarse en el uso de dispositivos comerciales, de bajo coste, probados y con todas las garantías sanitarias y de uso, además de un análisis de riesgos profundo, nos determina que esta estrategia de uso de este tipo de dispositivos, mitiga cualquier potencial riesgo, tanto en el uso de los dispositivos EEG, como en la gestión de los datos, limitándose al volcado de datos numéricos de una serie temporal.

Por último la clasificación de los datos usando métodos de deep learning o aprendizaje profundo, permitirá obtener un modelo o patrón coherente en el procesado de las señales, que a futuro permita usar el modelo desarrollado con personas con deficiencias motoras o neurocognitivas, siendo este punto objeto de un posible postdoctorado como continuación de esta investigación, siempre y cuando los resultados obtenidos con personas sanas cumplan los objetivos de la investigación.

#### **7.- Documento de información y consentimiento informado, si procede**

Además de informar a los voluntarios del proceso de toma de datos, se suministrará un consentimiento informado, a pesar de hacer uso de dispositivos de lectura EEG, comerciales homologados de bajo coste y la captura de datos numéricos de una serie temporal, que son almacenados en un archivo anonimizado, para el entrenamiento de una red neuronal. Este consentimiento informado, abundará en la información con la que el voluntario cuenta para aceptar participar en la investigación, además de aceptar las condiciones éticas y de propiedad intelectual que plantea la investigación y cesión de sus datos cerebrales para el desarrollo del estudio.

#### **8.- Previsiones de compensación a los participantes, si procede**

No procede

#### **9.- Cobertura en caso de daños debidos a la participación, si procede**

No procede. Se usan dispositivos comerciales de solo lectura no invasivos con electrodos secos, no existiendo otro tipo de interacción con el sujeto, no generando daño alguno a los voluntarios participantes de la investigación.

#### **10.- Descripción del análisis de datos y el estudio estadístico que requiera, si proceda**

No se realizará ningún estudio estadístico, ya que los datos no van asociados a ningún dato que permita esta interacción o estudio. Tampoco podemos considerar que se hace un análisis de los datos, ya que su uso se basa en una serie temporal, etiquetada, que vincula un valor numérico a una posible acción de un dispositivo externo. Los datos numéricos son clasificados conforme a una etiqueta de acción, que no permite mayor interacción con los mismos.

#### **11.- Bibliografía**

- [1] Ç. İ. Aci, M. Kaya, y Y. Mishchenko, «Distinguishing mental attention states of humans via an EEG-based passive BCI using machine learning methods», *Expert Syst. Appl.*, vol. 134, pp. 153-166, nov. 2019, doi: 10.1016/j.eswa.2019.05.057.
- [2] M. P. Karthikeyan, K. Krishnaveni, y N. Muthumani, «Machine Learning Technologies in IoT EEG-Based Healthcare Prediction», en *Smart Healthcare System Design*, 1.a ed., S. H. Islam y D. Samanta, Eds. Wiley, 2022, pp. 1-32. doi: 10.1002/9781119792253.ch1.
- [3] P. L. Nunez et al., «EEG coherency», *Electroencephalogr. Clin. Neurophysiol.*, vol. 103, n.o 5, pp. 499-515, nov. 1997, doi: 10.1016/S0013-4694(97)00066-7.
- [4] P. L. Nunez et al., «EEG coherency II: experimental comparisons of multiple measures», *Clin. Neurophysiol.*, vol. 110, n.o 3, pp. 469-486, mar. 1999, doi: 10.1016/S1388-2457(98)00043-1.
- [5] OpenBCI community, «OpenBCI - Open Source Biosensing Tools (EEG, EMG, EKG, and more)», 2020. [https://openbci.com/?utm\\_source=google&utm\\_medium=cpc&utm\\_campaign=9572259726&utm\\_content=open%20bci&gclid=CjwKCAjw8uGBhBAEiwAayu\\_9am-4kSC38jKp2fFSGbVor6FMX2IK6YOb1aWz9CUutB3oxURFz48BoCQQcQAvD\\_BwE](https://openbci.com/?utm_source=google&utm_medium=cpc&utm_campaign=9572259726&utm_content=open%20bci&gclid=CjwKCAjw8uGBhBAEiwAayu_9am-4kSC38jKp2fFSGbVor6FMX2IK6YOb1aWz9CUutB3oxURFz48BoCQQcQAvD_BwE) (accedido 24 de junio de 2021).
- [6] C. Vidaurre, T. H. Sander, y A. Schlögl, «BioSig: The Free and Open Source Software Library for Biomedical Signal Processing», *Comput. Intell. Neurosci.*, vol. 2011, pp. 1-12, 2011, doi: 10.1155/2011/935364.
- [7] «Fig. 2.2. Cerebral areas for EEG band power spectrum calculations.», ResearchGate. [https://www.researchgate.net/figure/Cerebral-areas-for-EEG-band-power-spectrum-calculations\\_fig2\\_267811728](https://www.researchgate.net/figure/Cerebral-areas-for-EEG-band-power-spectrum-calculations_fig2_267811728) (accedido 19 de agosto de 2021).
- [8] D. T. J. Liley, «EEG analysis system», ES2624768T3, 17 de julio de 2017. Accedido: 2 de septiembre de 2021. [En línea]. Disponible en: <https://patents.google.com/patent/ES2624768T3/es>
- [9] T. Karvinen y K. Karvinen, *Make a Mind-Controlled Arduino Robot: Use Your Brain as a Remote*. O'Reilly Media, Inc., 2011.
- [10] E. Amareswar, M. R. Naik, S. Prasad, N. V. Chandra, y R. Karthik, «Design of Brain Controlled Robotic Car using Raspberry Pi», en *2021 5th International Conference on Trends in Electronics and Informatics (ICOEI)*, jun. 2021, pp. 185-189. doi: 10.1109/ICOEI51242.2021.9452957.
- [11] C. A. Ruiz, M. S. Basualdo, y D. J. Matich, «Redes Neuronales: Conceptos Básicos y Aplicaciones.», p. 55.

**12.- En el caso de que el proyecto de investigación suponga un tratamiento de datos personales rellene los siguientes apartados<sup>1</sup>**

**12.1.- Tipo de datos personales que se van a tratar (identificativos, sociales, académicos, profesionales, económicos y financieros...)**

No procede

**12.2.- Si son categorías especiales de datos (salud, biométricos, genéticos...). Indique a que categoría pertenecen.**

No procede

**12.3.- Indique el colectivo del que se recaban los datos (mayores de edad, menores de 14 años, personas con enfermedad, diversidad funcional o discapacidad física/mental).**

Personas sanas mayores de edad de ambos sexos.

**12.4.- Indique cómo se van a recoger los datos (entrevistas, encuestas, formularios, Internet...).**

Diademas comerciales EEG de la marca Neurosky y Brainlink

<sup>1</sup> Para cubrir este apartado se recomienda la lectura previa del documento FAQ\_Guía del Investigador ([enlace](#))

**12.5.- Indique si los datos se van a anonimizar (no es posible identificar a las personas) o a seudonimizar (se asigna un código no identificativo ni identificable a cada sujeto, de forma que la identificación posterior sería posible).**

Datos anonimizados.

**12.6.- En caso de anonimización o seudonimización indique las técnicas utilizadas.**

El proceso de anonimización, consistirá como se ha indicado en asignar un nombre genérico y consecutivo al archivo de los datos numéricos que genera la diadema EEG. Posteriormente estos datos serán incorporados a un archivo mayor que diluirá cualquier posible referencia al origen de los datos.

**12.7.- En su caso, indique si participan varios organismos o socios en el proyecto.**

No procede

**12.8.- Duración del tratamiento de los datos. Plazo de conservación/supresión de los datos al concluir la investigación y lugar de conservación.**

Los datos serán almacenados hasta la finalización de esta tesis doctoral, una vez realizado el proceso de entrenamiento de la red neuronal artificial.

**12.9.- Indique si la finalidad del tratamiento es:**

- Elaborar perfiles personales.
- Tratar datos a gran escala.
- Tratar categorías especiales de datos.
- Seguimiento, control y observación de personas (monitorización).
- Usar tecnologías que puedan especialmente intrusivas, vigilancia electrónica, minería de datos, biometría, técnicas genéticas, geolocalización.
- Tratar datos relativos a la observación de zonas de acceso público.

**12.10.- ¿Se prevé la transferencia internacional de datos fuera de la Unión Europea?**

No está prevista ninguna transferencia. Los datos serán usados exclusivamente para la tesis doctoral.

**12.11.- ¿Se van a comunicar o ceder datos a terceros?**

No se cederán datos a terceros. Los datos son para el uso exclusivo del desarrollo de la tesis doctoral.

**12.12.- ¿Está prevista la reutilización de los datos personales con fines de investigación?**

No.

**12.13.- Indique brevemente las medidas técnicas y organizativas que se van a tomar con respecto al tratamiento de datos (seudonimización, control y registro de accesos, cifrado o codificación de datos...).**

Los archivos resultantes de la toma de datos recogidos de las diademas EEG no contendrán más que un número de la serie de la muestra y la marca de la diadema, almacenado en un lugar concreto y posteriormente integrado en un archivo común donde se ubicarán todos los valores numéricos obtenidos de la captura.

Al trabajar con valores numéricos de una serie temporal, es imposible asociarlo a datos personales, de género o cualquier otro que pueda vincular los datos al origen.

**12.14.- Indique otros aspectos que considere relevantes en materia de protección de datos.**

Los datos serán insertados de forma aleatoria en un archivo mayor que contiene los datos de los participantes en el estudio, siendo imposible la identificación de cualquier indicio que permita identificar su origen o asociarlo a un sujeto o sujetos en concreto.

#### **SOLICITA:**

El Informe favorable por parte de la Comisión de Bioética de la Universidad de Burgos para llevar a cabo el proyecto anteriormente referenciado.

Burgos a 24, de enero 2024 .

Fdo.: Investigador: Fernando Rivas Navazo

Fdo: Director tesis: Jesús Enrique Sierra

Fdo: Director tesis: José María Cámara

---

## Referencias (Formato IEEE)

- [1] F. Rivas, J. E. Sierra, y J. M. Cámara, «Architectural Proposal for Low-Cost Brain–Computer Interfaces with ROS Systems for the Control of Robotic Arms in Autonomous Wheelchairs», *Electronics* 2024, Vol. 13, Page 1013, vol. 13, n.º 6, p. 1013, mar. 2024, doi: 10.3390/ELECTRONICS13061013.
- [2] S. Omari, A. Omari, M. A. Fichouche, y F. J. Adu-Dakka, «Clasificación de señales EEG para aplicaciones BCI de imaginación motora», *Jornadas de Automática*, n.º 45, p. 45, sep. 2024, doi: 10.17979/JA-CEA.2024.45.10957.
- [3] B. Serna, R. Baltazar, M. Casillas, Y. Saavedra, A. Alanis, y A. Meza, «Medical Diagnostic Through a Mobile Application Controlled by Brain Waves: ConsultApp», *Smart Innovation, Systems and Technologies*, vol. 148, pp. 185-193, 2020, doi: 10.1007/978-981-13-8679-4\_16.
- [4] S. Abhishek, S. Sachin Kumar, N. Mohan, y K. P. Soman, «EEG based automated detection of seizure using machine learning approach and traditional features», *Expert Syst Appl*, vol. 251, oct. 2024, doi: 10.1016/j.eswa.2024.123991.
- [5] C. Zhang, Y.-K. Kim, y A. Eskandarian, «EEG-Inception: An Accurate and Robust End-to-End Neural Network for EEG-based Motor Imagery Classification», ene. 2021, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://arxiv.org/abs/2101.10932v3>
- [6] Y. Fu, J. Zhao, Y. Dong, y X. Wang, «Dry electrodes for human bioelectrical signal monitoring», *Sensors (Switzerland)*, vol. 20, n.º 13, pp. 1-30, jul. 2020, doi: 10.3390/S20133651.
- [7] «Zhang y Liu - Improving brain computer interface performance by ».
- [8] B. Abibullaev, A. Keutayeva, y A. Zollanvari, «Deep Learning in EEG-Based BCIs: A Comprehensive Review of Transformer Models, Advantages, Challenges, and Applications», *IEEE Access*, vol. 11, pp. 127271-127301, 2023, doi: 10.1109/ACCESS.2023.3329678.
- [9] P. Nagabushanam, S. Thomas George, y S. Radha, «EEG signal classification using LSTM and improved neural network algorithms», *Soft comput*, vol. 24, n.º 13, pp. 9981-10003, jul. 2020, doi: 10.1007/S00500-019-04515-0.
- [10] X. Wang, Q. Han, J. Li, y Y. Jin, «Research on Prediction Model of Epileptic EEG Signal Based on GRU», en *2021 International Conference on Electronic Information Engineering and Computer Science (EIECS)*, pp. 9-12. doi: 10.1109/EIECS53707.2021.9588078.

- [11] T. Chaipakornwong y P. Sittiprapaporn, «Brain exercise in elderly: NeuroSky smarter Kit investigation», *Asian J Med Sci*, vol. 11, n.º 1, pp. 69-74, ene. 2020, doi: 10.3126/ajms.v11i1.26528.
- [12] «EEG - Electroencephalography - BCI NeuroSky». [En línea]. Disponible en: <https://neurosky.com/biosensors/eeg-sensor/>
- [13] R. K. Wallace y H. Benson, «The Physiology of Meditation.», *Sci Am*, vol. 226, pp. 84-90, 1972.
- [14] D. Anwar, P. Garg, V. Naik, A. Gupta, y A. Kumar, «Use of portable EEG sensors to detect meditation», *2018 10th International Conference on Communication Systems and Networks, COMSNETS 2018*, vol. 2018-January, pp. 705-710, mar. 2018, doi: 10.1109/COMSNETS.2018.8328299.
- [15] A. Subasi, T. Tuncer, S. Dogan, D. Tanko, y U. Sakoglu, «EEG-based emotion recognition using tunable Q wavelet transform and rotation forest ensemble classifier», *Biomed Signal Process Control*, vol. 68, jul. 2021, doi: 10.1016/J.BSPC.2021.102648.
- [16] A. Süzen, B. Duman, y E. B. Şen, *Benchmark Analysis of Jetson TX2, Jetson Nano and Raspberry PI using Deep CNN*. doi: 10.1109/HORA49412.2020.9152915.
- [17] «945-13450-0000-100 JETSON NANO DEVELOPMENT KIT RS». [En línea]. Disponible en: <https://es.rs-online.com/web/p/kits-de-desarrollo-de-procesadores/1999831>
- [18] E. Ginzburg-Ganz, J. Belikov, L. Katzir, y Y. Levron, «Uses of the Popov Stability Criterion for Analyzing Global Asymptotic Stability in Power System Dynamic Models», *Energy Storage and Applications 2024, Vol. 1, Pages 54-72*, vol. 1, n.º 1, pp. 54-72, dic. 2024, doi: 10.3390/ESA1010005.
- [19] E. J. O y G. R. A, «CLASSIFICATION OF ELECTROENCEPHALOGRAM SIGNALS USING XGBOOST ALGORITHM AND SUPPORT VECTOR MACHINE», *International Research Journal of Engineering and Technology*, 2023, Accedido: 7 de marzo de 2025. [En línea]. Disponible en: [www.irjet.net](http://www.irjet.net)
- [20] K. Budholiya, S. K. Shrivastava, y V. Sharma, «An optimized XGBoost based diagnostic system for effective prediction of heart disease», *Journal of King Saud University - Computer and Information Sciences*, vol. 34, n.º 7, pp. 4514-4523, jul. 2022, doi: 10.1016/J.JKSUCI.2020.10.013.
- [21] E. Hortal *et al.*, «SVM-based Brain–Machine Interface for controlling a robot arm through four mental tasks», *Neurocomputing*, vol. 151, n.º P1, pp. 116-121, 2015, doi: 10.1016/j.neucom.2014.09.078.

- [22] E. Ahmadzadeh, H. Kim, O. Jeong, N. Kim, y I. Moon, «A Deep Bidirectional LSTM-GRU Network Model for Automated Ciphertext Classification», *IEEE Access*, vol. 10, pp. 3228-3237, 2022, doi: 10.1109/ACCESS.2022.3140342.
- [23] S. A. Zargar, «Introduction to Sequence Learning Models: RNN, LSTM, GRU», doi: 10.13140/RG.2.2.36370.99522.
- [24] M. Yuan, Y. Wang, L. Li, T. Chai, y W. T. Ang, «Safety-based Speed Control of a Wheelchair using Robust Adaptive Model Predictive Control», *IEEE Trans Cybern*, vol. 54, n.º 8, pp. 4464-4474, oct. 2022, doi: 10.1109/TCYB.2023.3309369.
- [25] «Qué es la ELA, la enfermedad silenciosa que no distingue edad, raza o sexo». Accedido: 18 de marzo de 2025. [En línea]. Disponible en: [https://www.nationalgeographic.com.es/ciencia/ela-enfermedad-neuronas\\_20533#twitter](https://www.nationalgeographic.com.es/ciencia/ela-enfermedad-neuronas_20533#twitter)
- [26] «Artículo monográfico de la esclerosis lateral amiotrófica (ELA)». Accedido: 18 de marzo de 2025. [En línea]. Disponible en: <https://revistasanitariadeinvestigacion.com/articulo-monografico-de-la-esclerosis-lateral-amiotrofica-ela/>
- [27] J. LaRocco, M. D. Le, y D. G. Paeng, «A Systemic Review of Available Low-Cost EEG Headsets Used for Drowsiness Detection», *Front Neuroinform*, vol. 14, p. 553352, oct. 2020, doi: 10.3389/FNINF.2020.553352/BIBTEX.
- [28] N. S. Bastos, F. Mota, D. F. Adamatti, y F. Carvalho, «Desenvolvendo o Pensamento Computacional no Ensino Médio: um Aporte Baseado na Neurociência», *International Journal on Computational Thinking (IJCTHink)*, vol. 1, n.º 1, p. 28, oct. 2017, doi: 10.14210/IJCTHINK.V1.N1.P28.
- [29] Á. del R. Zárate-Ruiz, F. U. Nava-Andrés, B. U. Cruz-Reyes, M. Arias-Montiel, E. Lugo-González, y A. Velarde-Galván, «Integración de señales EMG y EEG en domótica», *Pãdi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, vol. 10, n.º Especial5, pp. 73-80, nov. 2022, doi: 10.29057/ICBI.V10IESPECIAL5.10140.
- [30] «▷4.2. Desarrollo de sistemas BCI basados en EEG». Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://deingenierias.com/curso/icc/4-2-desarrollo-de-sistemas-bci-basados-en-eeg/>
- [31] J. Ancízar y C. Cárdenas, «Eliminación de perturbaciones en señales ECG utilizando filtrado de Kalman implementado en un DSP», 2012, *Pereira : Universidad Tecnológica de Pereira*. Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://hdl.handle.net/11059/4686>

- [32] «(PDF) Filtrado Básico de Señales Biomédicas». Accedido: 24 de marzo de 2025. [En línea]. Disponible en: [https://www.researchgate.net/publication/271273652\\_Filtrado\\_Basico\\_de\\_Senales\\_Biomedicas](https://www.researchgate.net/publication/271273652_Filtrado_Basico_de_Senales_Biomedicas)
- [33] C. M. Sweeney-Reed, S. J. Nasuto, M. F. Vieira, y A. O. Andrade, «Empirical Mode Decomposition and its Extensions Applied to EEG Analysis: A Review», *Advances in Data Science and Adaptive Analysis*, vol. 10, n.º 02, p. 1840001, abr. 2018, doi: 10.1142/S2424922X18400016.
- [34] C. Zamarrón Sobrinos Director y F. Javier Rodríguez Gómez Madrid, «ANÁLISIS Y CLASIFICACIÓN DE LAS SEÑALES DE LA ACTIVIDAD NEURONAL RÍTMICA (EEG) PARA LA DETECCIÓN DE LA EPILEPSIA BASADO EN WAVELETS», 2019.
- [35] A. Biasiucci *et al.*, «Brain-actuated functional electrical stimulation elicits lasting arm motor recovery after stroke», *Nat Commun*, vol. 9, n.º 1, p. 2421, dic. 2018, doi: 10.1038/S41467-018-04673-Z.
- [36] Y. An, D. Mitchell, J. Lathrop, D. Flynn, y S.-J. Chung, «Motor Imagery Teleoperation of a Mobile Robot Using a Low-Cost Brain-Computer Interface for Multi-Day Validation», dic. 2024, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://arxiv.org/abs/2412.08971v1>
- [37] A. Muhammad Kabeer, R. K. Megalingam, y K. M. Sakthiprasad, «Brain-Computer Interfaces for Mobility Assistance: A Comparative Analysis of EEG-Based Classification Models for Brain-Controlled Wheelchairs», *Smart Innovation, Systems and Technologies*, vol. 408 SIST, pp. 245-256, 2024, doi: 10.1007/978-981-97-6810-3\_20.
- [38] «(PDF) Sistema Embebido para Detección de Somnolencia en Conductores mediante señal EEG». Accedido: 24 de marzo de 2025. [En línea]. Disponible en: [https://www.researchgate.net/publication/301223033\\_Sistema\\_Embebido\\_para\\_Deteccion\\_de\\_Somnolencia\\_en\\_Conductores\\_mediante\\_senal\\_EEG](https://www.researchgate.net/publication/301223033_Sistema_Embebido_para_Deteccion_de_Somnolencia_en_Conductores_mediante_senal_EEG)
- [39] «Proyecto BrainGym». Accedido: 24 de marzo de 2025. [En línea]. Disponible en: [https://gib.tel.uva.es/brain gym/?utm\\_source=chatgpt.com](https://gib.tel.uva.es/brain gym/?utm_source=chatgpt.com)
- [40] E. Santamaría-Vázquez *et al.*, «MEDUSA©: A novel Python-based software ecosystem to accelerate brain-computer interface and cognitive neuroscience research», *Comput Methods Programs Biomed*, vol. 230, mar. 2023, doi: 10.1016/J.CMPB.2023.107357.
- [41] E. Santamaría-Vázquez, V. Martínez-Cagigal, S. Pérez-Velasco, D. Marcos-Martínez, y R. Hornero, «Robust asynchronous control of ERP-Based brain-

- Computer interfaces using deep learning», *Comput Methods Programs Biomed*, vol. 215, mar. 2022, doi: 10.1016/j.cmpb.2022.106623.
- [42] M. C. Arias y V. C. Martínez, «Análisis de la reacción fisiológica cerebral del usuario de realidad virtual a través de la encefalografía (EEG)», *Comunicación & Métodos*, vol. 5, n.º 2, pp. 19-32, dic. 2023, doi: 10.35951/V5I2.196.
- [43] L. da S. Sauer, «Proposal of a P300-based BCI Speller using a Predictive Text System», *Proceedings of the International Congress on Neurotechnology, Electronics and Informatics*, ene. 2013, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: [https://www.academia.edu/68846364/Proposal\\_of\\_a\\_P300\\_based\\_BCI\\_Speller\\_using\\_a\\_Predictive\\_Text\\_System](https://www.academia.edu/68846364/Proposal_of_a_P300_based_BCI_Speller_using_a_Predictive_Text_System)
- [44] J. Pan, Y. Li, Z. Gu, y Z. Yu, «A comparison study of two P300 speller paradigms for brain-computer interface», *Cogn Neurodyn*, vol. 7, n.º 6, pp. 523-529, abr. 2013, doi: 10.1007/S11571-013-9253-1/METRICS.
- [45] D. H. Lee, J. H. Jeong, H. J. Ahn, y S. W. Lee, «Design of an EEG-based Drone Swarm Control System using Endogenous BCI Paradigms», *9th IEEE International Winter Conference on Brain-Computer Interface, BCI 2021*, dic. 2020, doi: 10.1109/BCI51272.2021.9385356.
- [46] S. Jee, «Brain Oscillations and Their Implications for Neurorehabilitation», *Brain & Neurorehabilitation*, vol. 14, n.º 1, 2021, doi: 10.12786/BN.2021.14.E7.
- [47] K. P. Li *et al.*, «Noninvasive Brain Stimulation for Neurorehabilitation in Post-Stroke Patients», *Brain Sci*, vol. 13, n.º 3, mar. 2023, doi: 10.3390/BRAINSCI13030451.
- [48] D. De Las, R. Cerebrales, E. N. Estado, D. E. Reposo, P. : Hernan, y H. Larzabal, «Modelado de estados en la dinámica de las redes cerebrales en estado de reposo.», mar. 2023, doi: 10.29393/TDUDEC-33HH1ME33.
- [49] C. Miranda, A. Lescher, A. Rojas, J. Molino, E. Ibarra, y S. de Tristan, «Detección Temprana de Epilepsia Pediátrica: Progresión de los Electrodoes en EEG», *Eur Sci J*, vol. 19, n.º 6, p. 1, feb. 2023, doi: 10.19044/ESJ.2023.V19N6P1.
- [50] A. M. Roy, «Adaptive transfer learning-based multiscale feature fused deep convolutional neural network for EEG MI multiclassification in brain-computer interface», *Eng Appl Artif Intell*, vol. 116, nov. 2022, doi: 10.1016/J.ENGAPPAI.2022.105347.

- [51] M. Chaouachi, I. Jraidj, y C. Frasson, «Modeling Mental Workload Using EEG Features for Intelligent Systems», *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 6787 LNCS, pp. 50-61, 2011, doi: 10.1007/978-3-642-22362-4\_5.
- [52] D. Sandoval Rodríguez-Bermejo, «Diseño e implementación de un sistema para la detección del estrés mediante redes neuronales convolucionales a partir de imágenes térmicas», 2019.
- [53] Ł. Rydzik, W. Wąsacz, T. Ambroży, N. Javdaneh, K. Brydak, y M. Kopańska, «The Use of Neurofeedback in Sports Training: Systematic Review.», *Brain Sci*, vol. 13, n.º 4, abr. 2023, doi: 10.3390/brainsci13040660.
- [54] W. A. Awuah *et al.*, «Bridging Minds and Machines: The Recent Advances of Brain-Computer Interfaces in Neurological and Neurosurgical Applications», *World Neurosurg*, vol. 189, pp. 138-153, sep. 2024, doi: 10.1016/J.WNEU.2024.05.104.
- [55] B. Maiseli *et al.*, «Brain–computer interface: trend, challenges, and threats», *Brain Inform*, vol. 10, n.º 1, pp. 1-16, dic. 2023, doi: 10.1186/S40708-023-00199-3/METRICS.
- [56] B. J. Edelman *et al.*, «Non-invasive Brain-Computer Interfaces: State of the Art and Trends», *IEEE Rev Biomed Eng*, 2024, doi: 10.1109/RBME.2024.3449790.
- [57] Md. R. Ruman, A. Barua, S. Mohajan, D. Paul, A. K. Sarker, y Md. R. Rabby, «An Implementation of Motorized Wheelchair for Handicapped Persons», en *2019 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, pp. 301-305. doi: 10.1109/ICCCIS48478.2019.8974484.
- [58] S. H. Radwan, M. El-Telbany, W. Arafa, y R. A. Ali, «Deep Learning Approaches for Personal Identification Based on EGG Signals», *Lecture Notes on Data Engineering and Communications Technologies*, vol. 100, pp. 30-39, 2022, doi: 10.1007/978-3-030-89701-7\_3.
- [59] C. M. Köllöd, A. Adolf, K. Iván, G. Márton, y I. Ulbert, «Deep Comparisons of Neural Networks from the EEGNet Family», *Electronics (Switzerland)*, vol. 12, n.º 12, jun. 2023, doi: 10.3390/electronics12122743.
- [60] U. Chaudhary, N. Birbaumer, y A. Ramos-Murguialday, «Brain-computer interfaces for communication and rehabilitation», *Nat Rev Neurol*, vol. 12, n.º 9, pp. 513-525, sep. 2016, doi: 10.1038/NRNEUROL.2016.113.

- [61] Y. Kim *et al.*, «A Literature Review on the Smart Wheelchair Systems», dic. 2023, [En línea]. Disponible en: <http://arxiv.org/abs/2312.01285>
- [62] G. Cattan, A. Andreev, y E. Visinoni, «computers Recommendations for Integrating a P300-Based Brain-Computer Interface in Virtual Reality Environments for Gaming: An Update», doi: 10.3390/computers9040092.
- [63] L. M. Alonso-Valerdi y V. R. Mercado-García, «Towards designing Brain-Computer Interfaces in terms of User-Profiles, Neurophysiological Factors and User Experience Hacia el diseño de Interfaces Cerebro-Computadora en términos del Perfil del Usuario, Factores Neurofisiológico y Experiencia del Usuario», *Revista Mexicana de Ingenieria Biomedica*, vol. 40, n.º 2, may 2019, doi: 10.17488/RMIB.40.2.3.
- [64] G. L. Colclough, M. W. Woolrich, P. K. Tewarie, M. J. Brookes, A. J. Quinn, y S. M. Smith, «How reliable are MEG resting-state connectivity metrics?», *Neuroimage*, vol. 138, pp. 284-293, sep. 2016, doi: 10.1016/j.neuroimage.2016.05.070.
- [65] F. Akram, S. M. Han, y T. S. Kim, «An efficient word typing P300-BCI system using a modified T9 interface and random forest classifier», *Comput. Biol. Med.*, vol. 56, pp. 30-36, ene. 2015, doi: 10.1016/j.combiomed.2014.10.021.
- [66] N. Liang y L. Bougrain, «Decoding finger flexion from band-specific ECoG signals in humans», *Front. Neurosci.*, vol. 6, n.º JUN, p. 91, 2012, doi: 10.3389/fnins.2012.00091.
- [67] S. R. Soekadar, M. Witkowski, N. Vitiello, y N. Birbaumer, «An EEG/EOG-based hybrid brain-neural computer interaction (BNCI) system to control an exoskeleton for the paralyzed hand», *Biomedizinische Technik*, vol. 60, n.º 3, pp. 199-205, jun. 2015, doi: 10.1515/BMT-2014-0126.
- [68] C. Babiloni *et al.*, «Human cortical electroencephalography (EEG) rhythms during the observation of simple aimless movements: A high-resolution EEG study», *Neuroimage*, vol. 17, n.º 2, pp. 559-572, 2002, doi: 10.1016/S1053-8119(02)91192-4.
- [69] E. Başar, C. Başar-Eroglu, S. Karakaş, y M. Schürmann, «Gamma, alpha, delta, and theta oscillations govern cognitive processes», *International Journal of Psychophysiology*, vol. 39, n.º 2-3, pp. 241-248, ene. 2001, doi: 10.1016/S0167-8760(00)00145-8.
- [70] L. Chenxi, Y. Chen, Y. Li, J. Wang, y T. Liu, «Complexity analysis of brain activity in attention-deficit/hyperactivity disorder: A multiscale entropy

- analysis», *Brain Res Bull*, vol. 124, pp. 12-20, jun. 2016, doi: 10.1016/j.brainresbull.2016.03.007.
- [71] Z. Mohammadi, J. Frounchi, y M. Amiri, «Wavelet-based emotion recognition system using EEG signal», *Neural Comput Appl*, vol. 28, n.º 8, pp. 1985-1990, ago. 2017, doi: 10.1007/S00521-015-2149-8.
- [72] C. Babiloni *et al.*, «Alpha, beta and gamma electrocorticographic rhythms in somatosensory, motor, premotor and prefrontal cortical areas differ in movement execution and observation in humans», *Clinical Neurophysiology*, vol. 127, n.º 1, pp. 641-654, ene. 2016, doi: 10.1016/j.clinph.2015.04.068.
- [73] R. T. Schirrmeyer *et al.*, «Deep learning with convolutional neural networks for EEG decoding and visualization», *Human Brain Mapp*, vol. 38, n.º 11, pp. 5391-5420, nov. 2017, doi: 10.1002/hbm.23730.
- [74] S. Hochreiter y J. Schmidhuber, «Long Short-Term Memory», *Neural Comput*, vol. 9, n.º 8, pp. 1735-1780, nov. 1997, doi: 10.1162/NECO.1997.9.8.1735.
- [75] H. Cho, M. Ahn, K. Kim, y S. Chan Jun, «Increasing session-to-session transfer in a brain-computer interface with on-site background noise acquisition», *J. Neural Eng.*, vol. 12, n.º 6, p. 066009, 2015, doi: 10.1088/1741-2560/12/6/066009.
- [76] X. Li, J. Zhang, X. D. Li, W. Cui, y R. Su, «Neurofeedback training for brain functional connectivity improvement in mild cognitive impairment», *J Med Biol Eng*, vol. 40, n.º 4, pp. 484-495, ago. 2020, doi: 10.1007/s40846-020-00531-w.
- [77] A. Gupta, G. Siddhad, V. Pandey, P. P. Roy, y B.-G. Kim, «Subject-Specific Cognitive Workload Classification Using EEG-Based Functional Connectivity and Deep Learning», 2021, doi: 10.3390/s21206710.
- [78] M. Liu, W. Wu, Z. Gu, Z. Yu, F. F. Qi, y Y. Li, «Deep learning based on Batch Normalization for P300 signal detection», *Neurocomputing*, vol. 275, pp. 288-297, ene. 2018, doi: 10.1016/j.neucom.2017.08.039.
- [79] B. Adhikari, A. Shrestha, S. Mishra, S. Singh, y A. K. Timalina, «EEG based Directional Signal Classification using RNN Variants», en *2018 IEEE 3rd International Conference on Computing, Communication and Security (ICCCS)*, pp. 218-223. doi: 10.1109/CCCS.2018.8586823.
- [80] L. A. Weber, T. Ethofer, y A. C. Ehlis, «Predictors of neurofeedback training outcome: A systematic review», *Neuroimage Clin*, vol. 27, ene. 2020, doi: 10.1016/j.nicl.2020.102301.

- [81] O. S. Lih *et al.*, «EpilepsyNet: Novel automated detection of epilepsy using transformer model with EEG signals from 121 patient population», *Comput Biol Med*, vol. 164, sep. 2023, doi: 10.1016/J.COMPBIOMED.2023.107312.
- [82] S. Koelstra *et al.*, «DEAP: A database for emotion analysis; Using physiological signals», *IEEE Trans Affect Comput*, vol. 3, n.º 1, pp. 18-31, ene. 2012, doi: 10.1109/T-AFFC.2011.15.
- [83] A. L. Goldberger *et al.*, «PhysioBank, PhysioToolkit, and PhysioNet Components of a New Research Resource for Complex Physiologic Signals», 2000. [En línea]. Disponible en: <http://www.physionet.org>
- [84] Cornelius Stephanus Alfredo y D. A. Adytia, «Time Series Forecasting of Significant Wave Height using GRU, CNN-GRU, and LSTM», *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, n.º 5, pp. 776-781, oct. 2022, doi: 10.29207/RESTI.V6I5.4160.
- [85] R. N. Roy, S. Bonnet, S. Charbonnier, y A. Campagne, «Mental fatigue and working memory load estimation: Interaction and implications for EEG-based passive BCI», *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, vol. 2013, pp. 6607-6610, 2013, doi: 10.1109/embc.2013.6611070.
- [86] G. Moises, N. Silva, T. Leoncio, y C. Miranda, «Redes neuronales y biopotenciales musculares: Hacia un control más natural de prótesis mioeléctricas», *INGENIERÍA INVESTIGA*, vol. 6, p. 2024, oct. 2024, doi: 10.47796/ING.V6I00.1007.
- [87] A. F. M. Agarap, «A Neural Network Architecture Combining Gated Recurrent Unit (GRU) and Support Vector Machine (SVM) for Intrusion Detection in Network Traffic Data», *ACM International Conference Proceeding Series*, pp. 26-30, sep. 2017, doi: 10.1145/3195106.3195117.
- [88] F. G. Y. Souhe, C. F. Mbey, V. J. F. Kakeu, A. E. Meyo, y A. T. Boum, «Optimized forecasting of photovoltaic power generation using hybrid deep learning model based on GRU and SVM», *Electrical Engineering*, vol. 106, n.º 6, pp. 7879-7898, dic. 2024, doi: 10.1007/S00202-024-02492-8/METRICS.
- [89] T. Huang, H. Wang, Y. Chen, y P. He, «GRU-SVM Model for Synthetic Speech Detection», *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 12022 LNCS, pp. 115-125, 2020, doi: 10.1007/978-3-030-43575-2\_9.
- [90] M. Abumohsen, A. Y. Owda, M. Owda, y A. Abumihsan, «Hybrid machine learning model combining of CNN-LSTM-RF for time series forecasting of Solar Power Generation», *e-Prime - Advances in Electrical Engineering*,

*Electronics and Energy*, vol. 9, p. 100636, sep. 2024, doi:  
10.1016/J.PRIME.2024.100636.

- [91] zexian Sun, mingyu Zhao, yan Dong, xin Cao, y H. Sun, «Hybrid model with secondary decomposition, randomforest algorithm, clustering analysis and long short memory network principal computing for short-term wind power forecasting on multiple scales», *Energy*, vol. 221, p. 119848, abr. 2021, doi: 10.1016/J.ENERGY.2021.119848.
- [92] S. S. Vinayak E, S. A, y N. K. A, «Epilepsy Prediction using a Combined LSTM - XGBoost System on EEG Signals», *International Journal of Innovative Technology and Exploring Engineering*, vol. 10, n.º 1, pp. 18-24, nov. 2020, doi: 10.35940/IJITEE.A8086.1110120.
- [93] «CHB-MIT Scalp EEG Database v1.0.0». Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://physionet.org/content/chbmit/1.0.0/>
- [94] «DEAP: A Dataset for Emotion Analysis using Physiological and Audiovisual Signals». Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://www.eecs.qmul.ac.uk/mmv/datasets/deap/>
- [95] J. A. Cruz-Anchiraico, J. D. Aguirre-Cangalaya, J. J. Cahuana-Ochoa, D. Huamanchahua, y H. Valcarcel-Castillo, «Adaptations of Neuroprostheses for Training: A Technological and Systematic Review», *Proceedings of the 2023 IEEE 30th International Conference on Electronics, Electrical Engineering and Computing, INTERCON 2023*, 2023, doi: 10.1109/INTERCON59652.2023.10326054.
- [96] A. M. Cruz-Rodríguez y H. Sánchez-Machet, «Prótesis de mano controlada con señales EEG», *MOMENTO*, vol. 2021, n.º 63, pp. 34-51, jul. 2021, doi: 10.15446/mo.n63.96407.
- [97] G. Ramírez-Alonso y K. Rascón-Cervantes, «El paradigma del deletreo: Avances en el desarrollo de interfaces cerebro-computadora aplicadas al deletreo de palabras», *Cultura Científica y Tecnológica*, n.º 66, pp. 101-109, 2018, doi: 10.20983/CULCYT.2018.3.11.
- [98] D. F. Santos, «Parkinson's Disease Detection using XGBoost and Machine Learning», *medRxiv*, p. 2023.10.23.23297369, oct. 2023, doi: 10.1101/2023.10.23.23297369.
- [99] F. Yi *et al.*, «XGBoost-SHAP-based interpretable diagnostic framework for alzheimer's disease», *BMC Med Inform Decis Mak*, vol. 23, n.º 1, pp. 1-14, dic. 2023, doi: 10.1186/S12911-023-02238-9/FIGURES/6.
- [100] «The Two Decades Brainclinics Research Archive for Insights in Neurophysiology (TDBRAIN) Database – Resource Center». Accedido: 24 de

marzo de 2025. [En línea]. Disponible en: [https://bio-medical.com/resources/the-two-decades-brainclinics-research-archive-for-insights-in-neurophysiology-tdbrain-database/?utm\\_source=chatgpt.com](https://bio-medical.com/resources/the-two-decades-brainclinics-research-archive-for-insights-in-neurophysiology-tdbrain-database/?utm_source=chatgpt.com)

- [101] W. Li *et al.*, «Data-driven retrieval of population-level EEG features and their role in neurodegenerative diseases», *Brain Commun*, vol. 6, n.º 4, jul. 2024, doi: 10.1093/BRAINCOMMS/FCAE227.
- [102] A. A. Jorge, L. A. M. Riascos, y P. E. Miyagi, «Modelling and control strategies for a motorized wheelchair with hybrid locomotion systems», *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 43, n.º 1, ene. 2021, doi: 10.1007/S40430-020-02730-7.
- [103] D. Shin, T. Kim, S. Kim, y D. Shin, «Design and implementation of smart driving system using context recognition system», *ISCI 2011 - 2011 IEEE Symposium on Computers and Informatics*, pp. 84-89, 2011, doi: 10.1109/ISCI.2011.5958889.
- [104] T. Carlson y J. Del R. Millan, «Brain-controlled wheelchairs: a robotic architecture», *IEEE Robotics Automat Magazine*, vol. 20, n.º 1, pp. 65-73, 2013, doi: 10.1109/mra.2012.2229936.
- [105] F. Lotte, «Signal processing approaches to minimize or suppress calibration time in oscillatory activity-based brain-computer interfaces», *Proc. IEEE*, vol. 103, n.º 6, pp. 871-890, jun. 2015, doi: 10.1109/jproc.2015.2404941.
- [106] B. Chakravarthi, S. C. Ng, M. R. Ezilarasan, y M. F. Leung, «EEG-based emotion recognition using hybrid CNN and LSTM classification», *Front Comput Neurosci*, vol. 16, oct. 2022, doi: 10.3389/FNCOM.2022.1019776/FULL.
- [107] T. Chen y C. Guestrin, «XGBoost: A scalable tree boosting system», *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, vol. 13-17-August-2016, pp. 785-794, ago. 2016, doi: 10.1145/2939672.2939785/SUPPL\_FILE/KDD2016\_CHEN\_BOOSTING\_SYSTEM\_01-ACM.MP4.
- [108] L. G. Hernández y J. M. Antelis, «A Comparison of Deep Neural Network Algorithms for Recognition of EEG Motor Imagery Signals», *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 10880 LNCS, pp. 126-134, 2018, doi: 10.1007/978-3-319-92198-3\_13.

- [109] «IEEE Xplore: IEEE Transactions on Neural Systems and Rehabilitation Engineering». Accedido: 26 de marzo de 2025. [En línea]. Disponible en: <https://ieeexplore.ieee.org/xpl/RecentIssue.jsp?punumber=7333>
- [110] A. Tripathi *et al.*, «Fuzzy Logic-Based System for Identifying the Severity of Diabetic Macular Edema from OCT B-Scan Images Using DRIL, HRF, and Cystoids», *Diagnostics*, vol. 13, n.º 15, ago. 2023, doi: 10.3390/DIAGNOSTICS13152550.
- [111] N. Thomas, A. J. Miller, H. Ayaz, y J. D. Brown, «Haptic shared control improves neural efficiency during myoelectric prosthesis use», *Sci Rep*, vol. 13, n.º 1, dic. 2023, doi: 10.1038/S41598-022-26673-2.
- [112] Y. Dong, Z. Zhong, Y. Zhang, R. Zhu, H. Wen, y R. Han, «Intelligent Prediction Method of Hot Spot Temperature in Transformer by Using CNN-LSTM\&\{GRU} Network», en *2023 International Conference on Advanced Robotics and Mechatronics (ICARM)*, pp. 7-12. doi: 10.1109/ICARM58088.2023.10218818.
- [113] J. L. Collinger *et al.*, «High-performance neuroprosthetic control by an individual with tetraplegia», *The Lancet*, vol. 381, n.º 9866, pp. 557-564, 2013, doi: 10.1016/s0140-6736(12)61816-9.
- [114] A. Chatterjee, V. Aggarwal, A. Ramos, S. Acharya, y N. V. Thakor, «A brain-computer interface with vibrotactile biofeedback for haptic information», *J Neuroeng Rehabil*, vol. 4, p. 40, 2007, doi: 10.1186/1743-0003-4-40.
- [115] R. Fu *et al.*, «Hybrid Cnn-Bi-Lstm Model-Based Intention Decoding from Fingers of the Same Hand in High Demanding Boundary Avoidance Task», 2023, doi: 10.2139/SSRN.4572180.
- [116] O. Oxenberg, M. Fire, y G. F. Alpert, «Automatic classification of eeg signals, based on image interpretation of spatio-temporal information», *medRxiv*, p. 2025.02.10.25322019, feb. 2025, doi: 10.1101/2025.02.10.25322019.
- [117] O. Oxenberg, M. Fire, y G. Fuhrmann Alpert, «AUTOMATIC CLASSIFICATION OF EEG SIGNALS, BASED ON IMAGE INTERPRETATION OF SPATIO-TEMPORAL INFORMATION», 2024, doi: 10.1101/2025.02.10.25322019.
- [118] M. Sebastián-Romagosa *et al.*, «Brain Computer Interface Treatment for Motor Rehabilitation of Upper Extremity of Stroke Patients-A Feasibility Study», *Front Neurosci*, vol. 14, oct. 2020, doi: 10.3389/FNINS.2020.591435.
- [119] «Neurology and Stroke: Hertie-Institut für klinische Hirnforschung». Accedido: 27 de marzo de 2025. [En línea]. Disponible en: <https://www.hih-tuebingen.de/en/research/neurology-and-stroke>

- [120] «NPSL». Accedido: 27 de marzo de 2025. [En línea]. Disponible en: <https://npsl.stanford.edu/>
- [121] O. A. Ruşanu, «A Brain-Computer Interface for Controlling a Mobile Assistive Device by Using the NeuroSky EEG Headset and Raspberry Pi», en *IFMBE Proceedings*, Springer Science and Business Media Deutschland GmbH, 2022, pp. 231-238. doi: 10.1007/978-3-030-92328-0\_31.
- [122] C. Brambilla, I. Pirovano, R. M. Mira, G. Rizzo, A. Scano, y A. Mastropietro, «Combined use of emg and eeg techniques for neuromotor assessment in rehabilitative applications: A systematic review», *Sensors*, vol. 21, n.º 21, nov. 2021, doi: 10.3390/S21217014.
- [123] H. Abbaspour, N. Mehrshad, S. M. Razavi, y L. Mesin, «Artefacts removal to detect visual evoked potentials in brain computer interface systems», *In Journal of Biomimetics, Biomaterials and Biomedical Engineering*, vol. 41, pp. 91-103, 2019, doi: 10.4028/www.scientific.net/jbbbe.41.91.
- [124] L. Alzubaidi *et al.*, «Review of deep learning: concepts, CNN architectures, challenges, applications, future directions», *J Big Data*, vol. 8, n.º 1, dic. 2021, doi: 10.1186/S40537-021-00444-8.
- [125] M. Boyer, L. Bouyer, J. S. Roy, y A. Campeau-Lecours, «Reducing Noise, Artifacts and Interference in Single-Channel EMG Signals: A Review», *Sensors*, vol. 23, n.º 6, mar. 2023, doi: 10.3390/S23062927.
- [126] L. F. Nicolas-Alonso y J. Gomez-Gil, «Brain computer interfaces, a review», *Brain computer interfaces, a review. Sensors*, vol. 12, n.º 2, pp. 1211-1279, feb. 2012, doi: 10.3390/s120201211.
- [127] F. Lotte y C. Jeunet, «Towards improved BCI based on human learning principles», 30 de marzo de 2015, *Institute of Electrical and Electronics Engineers Inc.* doi: 10.1109/iww-bci.2015.7073024.
- [128] J. D. R. Millán *et al.*, «Combining brain-computer interfaces and assistive technologies: State-of-the-art and challenges», *Front Neurosci*, vol. 4, n.º SEP, 2010, doi: 10.3389/FNINS.2010.00161.
- [129] G. R. Peñaloza-Mendoza, V. Becerra-Tapia, C. Vázquez-Barajas, y L. M. Carreón-Silva, «Wheelchair assistive system with EMG», *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, vol. 10, n.º Especial5, pp. 97-102, nov. 2022, doi: 10.29057/ICBI.V10IESPECIAL5.10129.
- [130] E. D. Jeuland, A. del Río Ferreras, D. Chaves Sánchez, E. Fidalgo Fernández, V. González Castro, y E. Alegre Gutiérrez, «Control de un brazo robótico de bajo coste mediante differential evolution», *XLIII Jornadas de Automática: libro de actas: 7, 8 y 9 de septiembre de 2022, Logroño (La Rioja), 2022, ISBN*

978-84-9749-841-8, págs. 812-819, pp. 812-819, 2022, Accedido: 27 de marzo de 2025. [En línea]. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=8728681&info=resumen&idioma=ENG>

- [131] M. Bouchane, W. Guo, y S. Yang, «Hybrid CNN-GRU Models for Improved EEG Motor Imagery Classification», *Sensors* 2025, Vol. 25, Page 1399, vol. 25, n.º 5, p. 1399, feb. 2025, doi: 10.3390/S25051399.
- [132] C. feng Chen, Z. jiang Du, L. He, Y. jun Shi, J. qi Wang, y W. Dong, «A Novel Gait Pattern Recognition Method Based on LSTM-CNN for Lower Limb Exoskeleton», *J Bionic Eng*, vol. 18, n.º 5, pp. 1059-1072, sep. 2021, doi: 10.1007/S42235-021-00083-Y/TABLES/4.
- [133] B. Ma y S. Dong, «A Hybrid Prediction Model for Pumping Well System Efficiency Based on Stacking Integration Strategy», *Int J Energy Res*, vol. 2024, n.º 1, p. 8868949, ene. 2024, doi: 10.1155/2024/8868949.
- [134] A. J. Izenman, «Linear Discriminant Analysis», pp. 237-280, 2013, doi: 10.1007/978-0-387-78189-1\_8.
- [135] J. Gruenwald, A. Znobishchev, C. Kapeller, K. Kamada, J. Scharinger, y C. Guger, «Time-variant linear discriminant analysis improves hand gesture and finger movement decoding for invasive brain-computer interfaces», *Front Neurosci*, vol. 13, n.º SEP, p. 901, sep. 2019, doi: 10.3389/fnins.2019.00901.
- [136] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T. H. Falk, y J. Faubert, «Deep learning-based electroencephalography analysis: a systematic review», *J Neural Eng*, vol. 16, n.º 5, p. 051001, ago. 2019, doi: 10.1088/1741-2552/AB260C.
- [137] A. Víctor *et al.*, «Plataforma EEG para la monitorización grupal de la atención en entornos de enseñanza», jun. 2024, Accedido: 27 de marzo de 2025. [En línea]. Disponible en: <https://digibug.ugr.es/handle/10481/94702>
- [138] C. C. Jiménez *et al.*, «Diseño de una silla de ruedas controlada por señales EEG para un paciente con parálisis cerebral», *Ingeniare. Revista chilena de ingeniería*, vol. 32, pp. 0-0, 2024, doi: 10.4067/S0718-33052024000100215.
- [139] L. Montes Marin, «Aplicación de la inteligencia computacional en el análisis de datos EEG para la clasificación y reconocimiento de estados mentales relacionados con mente divagante y atención plena».
- [140] S. Heunis *et al.*, «Quality and denoising in real-time functional magnetic resonance imaging neurofeedback: A methods review», *Hum Brain Mapp*, vol. 41, n.º 12, pp. 3439-3467, ago. 2020, doi: 10.1002/HBM.25010.

- [141] Z. Q. Geng, G. F. Chen, Y. M. Han, G. Lu, y F. Li, «Semantic relation extraction using sequential and tree-structured LSTM with attention», *Inf Sci (N Y)*, vol. 509, pp. 183-192, ene. 2020, doi: 10.1016/j.ins.2019.09.006.
- [142] M. Sajjad *et al.*, «A Novel CNN-GRU-Based Hybrid Approach for Short-Term Residential Load Forecasting», vol. 8, pp. 143759-143768, doi: 10.1109/ACCESS.2020.3009537.
- [143] «Diseño de sistema “Brain Computer Interface” centrado en el usuario | Semantic Scholar». Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://www.semanticscholar.org/paper/Dise%C3%B1o-de-sistema-%22Brain-Computer-Interface%22-en-el-Berm%C3%BAdez/886b918b22df2324a525ed1acdbb56ab630bef6c>
- [144] J. R. Flores, J. R. Flores, L. S. Muyulema, J. C. Cruz, y A. M. Caiza, «Mejora de la precisión del seguimiento de trayectoria de un brazo robótico mediante un algoritmo de red neuronal inicializado con Lyapunov», *Polo del Conocimiento*, vol. 8, n.º 10, pp. 443-466, oct. 2023, doi: 10.23857/pc.v8i10.6135.
- [145] C. Zhang, C. Liu, X. Zhang, y G. Almpandis, «An up-to-date comparison of state-of-the-art classification algorithms», *Expert Syst. Appl.*, vol. 82, pp. 128-150, oct. 2017, doi: 10.1016/j.eswa.2017.04.003.
- [146] S. Rampichini, T. M. Vieira, P. Castiglioni, y G. Merati, «Complexity analysis of surface electromyography for assessing the myoelectric manifestation of muscle fatigue: A review», *Entropy*, vol. 22, n.º 5, may 2020, doi: 10.3390/E22050529.
- [147] Q. Zhang y Y. Liu, «Improving brain computer interface performance by data augmentation with conditional Deep Convolutional Generative Adversarial Networks», p. 4.
- [148] W. Wu, Z. Chen, X. Gao, Y. Li, E. N. Brown, y S. Gao, «Probabilistic common spatial patterns for multichannel EEG analysis», *IEEE Transact Pattern Anal Machine Intell*, vol. 37, n.º 3, pp. 639-653, mar. 2015, doi: 10.1109/tpami.2014.2330598.
- [149] M. Alnaanah, M. Wahdow, y M. Alrashdan, «CNN models for EEG motor imagery signal classification», *Signal Image Video Process*, vol. 17, n.º 3, pp. 825-830, abr. 2023, doi: 10.1007/S11760-022-02293-1.
- [150] C. Zhou, «SSVEP-Based BCI Wheelchair Control System», jul. 2023, Accedido: 28 de julio de 2024. [En línea]. Disponible en: <http://arxiv.org/abs/2307.08703>

- [151] J. Meng, S. Zhang, A. Bekyo, J. Olsoe, B. Baxter, y B. He, «Noninvasive Electroencephalogram Based Control of a Robotic Arm for Reach and Grasp Tasks», *Sci Rep*, vol. 6, dic. 2016, doi: 10.1038/SREP38565.
- [152] A. H. Do, P. T. Wang, C. E. King, S. N. Chun, y Z. Nenadic, «Brain-computer interface controlled robotic gait orthosis», *J Neuroeng Rehabil*, vol. 10, n.º 1, dic. 2013, doi: 10.1186/1743-0003-10-111.
- [153] L. Kanungo, N. Garg, A. Bhoje, S. Rajguru, y V. Baths, «Wheelchair automation by a hybrid BCI system using SSVEP and eye blinks», *arXiv*. doi: 10.48550/arXiv.2106.11008.
- [154] X. Gu *et al.*, «EEG-Based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and Their Applications», *IEEE/ACM Trans Comput Biol Bioinform*, vol. 18, n.º 5, pp. 1645-1666, 2021, doi: 10.1109/TCBB.2021.3052811.
- [155] M. Alabboudi, M. Majed, F. Hassan, y A. B. Nassif, «EEG Wheelchair for People of Determination».
- [156] R. Mounir, R. Alqasemi, y R. Dubey, «BCI-Controlled Hands-Free Wheelchair Navigation with Obstacle Avoidance», may 2020, Accedido: 28 de julio de 2024. [En línea]. Disponible en: <http://arxiv.org/abs/2005.04209>
- [157] Y. Kim *et al.*, «A Literature Review on the Smart Wheelchair Systems», dic. 2023, Accedido: 28 de julio de 2024. [En línea]. Disponible en: <http://arxiv.org/abs/2312.01285>
- [158] R. M. Vishwanath, S. Kumar, y S. N. Omkar, «A Real-time Control Approach for Unmanned Aerial Vehicles using Brain-computer Interface», sep. 2018, Accedido: 28 de julio de 2024. [En línea]. Disponible en: <http://arxiv.org/abs/1809.00346>
- [159] B. K. Jeon y E. J. Kim, «LSTM-based model predictive control for optimal temperature set-point planning», *Sustainability (Switzerland)*, vol. 13, n.º 2, pp. 1-14, ene. 2021, doi: 10.3390/SU13020894.
- [160] F. Rivas, J. E. Sierra-Garcia, y J. M. Camara, «Comparison of LSTM- and GRU-Type RNN Networks for Attention and Meditation Prediction on Raw EEG Data from Low-Cost Headsets», *Electronics 2025, Vol. 14, Page 707*, vol. 14, n.º 4, p. 707, feb. 2025, doi: 10.3390/ELECTRONICS14040707.
- [161] «[PDF] Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks by Wei-Long Zheng, Bao-Liang Lu · 10.1109/tamd.2015.2431497 · OA.mg». [En línea]. Disponible en: [https://oa.mg/work/10.1109/tamd.2015.2431497?utm\\_source=chatgpt](https://oa.mg/work/10.1109/tamd.2015.2431497?utm_source=chatgpt)

- [162] M. Groshev, J. Sacido, y J. Martín-Pérez, «FoReCo: a forecast-based recovery mechanism for real-time remote control of robotic manipulators», en *Proceedings of the SIGCOMM '22 Poster and Demo Sessions*, en SIGCOMM '22. Association for Computing Machinery, pp. 7-9. doi: 10.1145/3546037.3546047.
- [163] P. Kaushik, A. Gupta, P. P. Roy, y D. P. Dogra, «EEG-Based Age and Gender Prediction Using Deep BLSTM-LSTM Network Model», *IEEE Sens J*, vol. 19, n.º 7, pp. 2634-2641, abr. 2019, doi: 10.1109/JSEN.2018.2885582.
- [164] H. Yaacob, F. Hossain, S. Shari, S. K. Khare, C. P. Ooi, y U. R. Acharya, «Application of Artificial Intelligence Techniques for Brain-Computer Interface in Mental Fatigue Detection: A Systematic Review (2011-2022)», *IEEE Access*, vol. 11, pp. 74736-74758, 2023, doi: 10.1109/ACCESS.2023.3296382.
- [165] M. Stangl, S. L. Maoz, y N. Suthana, «Mobile cognition: imaging the human brain in the 'real world'», *Nat Rev Neurosci*, vol. 24, n.º 6, pp. 347-362, jun. 2023, doi: 10.1038/S41583-023-00692-Y.
- [166] «Understanding MAE, MSE, and RMSE: Key Metrics in Machine Learning - DEV Community». Accedido: 24 de enero de 2025. [En línea]. Disponible en: [https://dev.to/mondal\\_sabbha/understanding-mae-mse-and-rmse-key-metrics-in-machine-learning-4la2](https://dev.to/mondal_sabbha/understanding-mae-mse-and-rmse-key-metrics-in-machine-learning-4la2)
- [167] P. Jain, G. Sharma, P. Kirode, H. Korla, A. Deep, y N. K. Jain, «EEG-Based Real-Time Prediction of Cognitive State on Smartphone», *Lecture Notes in Networks and Systems*, vol. 730 LNNS, pp. 147-159, 2023, doi: 10.1007/978-981-99-3963-3\_12.
- [168] «EEG-Based Real-Time Prediction of Cognitive State on Smartphone | SpringerLink». Accedido: 28 de julio de 2024. [En línea]. Disponible en: [https://link.springer.com/chapter/10.1007/978-981-99-3963-3\\_12](https://link.springer.com/chapter/10.1007/978-981-99-3963-3_12)
- [169] L. Vélez y G. Kemper, «Algorithm for Detection of Raising Eyebrows and Jaw Clenching Artifacts in EEG Signals Using Neurosky Mindwave Headset», en *Smart Innovation, Systems and Technologies*, Springer Science and Business Media Deutschland GmbH, 2021, pp. 99-110. doi: 10.1007/978-3-030-57566-3\_10.
- [170] O. A. Ruşanu, «Python Implementation for Brain-Computer Interface Research by Acquiring and Processing the NeuroSky EEG Data for Classifying Multiple Voluntary Eye-Blinks», en *IFMBE Proceedings*, Springer Science and Business Media Deutschland GmbH, 2022, pp. 666-672. doi: 10.1007/978-3-030-92328-0\_84.

- [171] «Imagen motora: Terapia y rehabilitación tras un ACV». Accedido: 7 de marzo de 2025. [En línea]. Disponible en: <https://www.stroke-therapy-revolution.es/imagen-motora-instrumento-terapeutico-objeto-la-intervencion-rehabilitadora-paciente-sufrio-acv/>
- [172] «Descubre la imaginería motora». Accedido: 7 de marzo de 2025. [En línea]. Disponible en: <https://www.clinicauniversitariaalasalle.es/descubre-la-imagineria-motora/>
- [173] «Quadcopter control in three-dimensional space using a noninvasive motor imagery-based brain–computer interface - IOPscience». [En línea]. Disponible en: <https://iopscience.iop.org/article/10.1088/1741-2560/10/4/046003/meta>
- [174] J. Antonio y G. Tirado, «Clasificación de señales electroencefalográficas usando la coherencia parcialmente dirigida Tesis que presenta», 2016.
- [175] C. Saló Casajuana Directoras y C. Migliorelli Leidy Yanet Serna, «Clasificación de las fases del sueño utilizando señales EEG MEMORIA Autora: Escola Tècnica Superior d'Enginyeria Industrial de Barcelona».
- [176] W. Ding y T. Chen, «Singularity Era: Computational Model of Entropy Within the Human Brain», *ACM International Conference Proceeding Series*, pp. 60-65, may 2022, doi: 10.1145/3543081.3543091.
- [177] R. Raja *et al.*, «Detection of behavioural patterns employing a hybrid approach of computational techniques», *Computers, Materials and Continua*, vol. 72, n.º 1, pp. 2015-2031, 2022, doi: 10.32604/cmc.2022.022904.
- [178] «What is LSTM - Long Short Term Memory? - GeeksforGeeks». Accedido: 7 de marzo de 2025. [En línea]. Disponible en: <https://www.geeksforgeeks.org/deep-learning-introduction-to-long-short-term-memory/>
- [179] «LSTMs Explained: A Complete, Technically Accurate, Conceptual Guide with Keras | by Ryan T. J. J. | Analytics Vidhya | Medium». Accedido: 7 de marzo de 2025. [En línea]. Disponible en: <https://medium.com/analytics-vidhya/lstms-explained-a-complete-technically-accurate-conceptual-guide-with-keras-2a650327e8f2>
- [180] F. Bonassi, M. Farina, y R. Scattolini, «On the stability properties of Gated Recurrent Units neural networks», *Syst Control Lett*, vol. 157, nov. 2020, doi: 10.1016/j.sysconle.2021.105049.
- [181] N. Kumari, S. Anwar, y V. Bhattacharjee, «A Comparative Analysis of Machine and Deep Learning Techniques for EEG Evoked Emotion Classification»,

*Wirel Pers Commun*, vol. 128, n.º 4, pp. 2869-2890, feb. 2023, doi: 10.1007/S11277-022-10076-7/TABLES/3.

- [182] S. Parui, A. Kumar, R. Bajiya, D. Samanta, y N. Chakravorty, «Emotion recognition from EEG signal using XGBoost algorithm», *2019 IEEE 16th India Council International Conference, INDICON 2019 - Symposium Proceedings*, dic. 2019, doi: 10.1109/INDICON47234.2019.9028978.
- [183] «(PDF) Heart failure prediction: Exploratory analysis and modeling with XGBoost and deep neural networks». Accedido: 7 de marzo de 2025. [En línea]. Disponible en: [https://www.researchgate.net/publication/378367783\\_Heart\\_failure\\_prediction\\_Exploratory\\_analysis\\_and\\_modeling\\_with\\_XGBoost\\_and\\_deep\\_neural\\_networks#fullTextFileContent](https://www.researchgate.net/publication/378367783_Heart_failure_prediction_Exploratory_analysis_and_modeling_with_XGBoost_and_deep_neural_networks#fullTextFileContent)
- [184] R. Hornero Sánchez, R. Corralejo, y D. Alvarez, «Brain Computer Interface (BCI) Aplicado al entrenamiento cognitivo y control doméstico para prevenir los efectos del envejecimiento», Accedido: 26 de marzo de 2025. [En línea]. Disponible en: [www.crediscapacidadydependencia.es](http://www.crediscapacidadydependencia.es)
- [185] J. Prieto-Tarzia y H. Martínez-García, «Desarrollo de Interfaz Cerebro-Ordenador (BCI) para Aplicaciones de Robótica».
- [186] J. Belo, M. Clerc, y D. Schön, «EEG-Based Auditory Attention Detection and Its Possible Future Applications for Passive BCI», *Front Comput Sci*, vol. 3, abr. 2021, doi: 10.3389/FCOMP.2021.661178.
- [187] S. J. Johnston, S. G. Boehm, D. Healy, R. Goebel, y D. E. J. Linden, «Neurofeedback: A promising tool for the self-regulation of emotion networks», *Neuroimage*, vol. 49, n.º 1, pp. 1066-1072, ene. 2010, doi: 10.1016/j.neuroimage.2009.07.056.
- [188] «(PDF) Attentional Modulation Effects on Brain Networks: an fMRI Study on the Visual Attention Network and the Default-Mode Network.» Accedido: 23 de enero de 2025. [En línea]. Disponible en: [https://www.researchgate.net/publication/281239686\\_Attentional\\_Modulation\\_Effects\\_on\\_Brain\\_Networks\\_an\\_fMRI\\_Study\\_on\\_the\\_Visual\\_Attention\\_Network\\_and\\_the\\_Default-Mode\\_Network?channel=doi&linkId=55dc6dcc08aec156b9b1771d&showFulltext=true](https://www.researchgate.net/publication/281239686_Attentional_Modulation_Effects_on_Brain_Networks_an_fMRI_Study_on_the_Visual_Attention_Network_and_the_Default-Mode_Network?channel=doi&linkId=55dc6dcc08aec156b9b1771d&showFulltext=true)
- [189] S. Anurag, B. Singh, D. Krishna, K. Prasanna, y S. Deepeshwar, «Heart-brain rhythmic synchronization during meditation: A nonlinear signal analysis», *Int J Yoga*, vol. 16, n.º 2, p. 132, 2023, doi: 10.4103/IJOY.IJOY\_161\_23.

- [190] V. Deshmukh, «The electroencephalographic brainwave spectrum, mindful meditation, and awareness: Hypothesis», *Int J Yoga*, vol. 16, n.º 1, p. 42, 2023, doi: 10.4103/IJOY.IJOY\_34\_23.
- [191] S. C. D. León, «Estudio de las epilepsias generalizadas idiopáticas, mediante test neuropsicológicos, registros de magnetoencefalografía y electroencefalografía prolongado frente a epilepsias focales lesionales y no lesionales de origen frontal», 2016.
- [192] J. E. Huggins *et al.*, «Workshops of the Eighth International Brain-Computer Interface Meeting: BCIs: The Next Frontier», 2021, doi: 10.1080/2326263X.2021.2009654.
- [193] P. D. Barua *et al.*, «Artificial intelligence assisted tools for the detection of anxiety and depression leading to suicidal ideation in adolescents: a review», *Cogn Neurodyn*, vol. 18, n.º 1, pp. 1-22, feb. 2024, doi: 10.1007/S11571-022-09904-0.
- [194] T. Bin Shams, M. S. Hossain, M. F. Mahmud, M. S. Tehjib, Z. Hossain, y M. I. Pramanik, «EEG-based Biometric Authentication Using Machine Learning: A Comprehensive Survey», *ECTI Transactions on Electrical Engineering, Electronics, and Communications*, vol. 20, n.º 2, pp. 225-241, jun. 2022, doi: 10.37936/ECTI-EEC.2022202.246906.
- [195] M. A. Cervera *et al.*, «Brain-computer interfaces for post-stroke motor rehabilitation: a meta-analysis», *Ann Clin Transl Neurol*, vol. 5, n.º 5, p. 651, may 2018, doi: 10.1002/ACN3.544.
- [196] A. Vaswani *et al.*, «Attention Is All You Need», *Adv Neural Inf Process Syst*, vol. 2017-December, pp. 5999-6009, jun. 2017, Accedido: 13 de marzo de 2025. [En línea]. Disponible en: <https://arxiv.org/abs/1706.03762v7>

## ANEXO II . Publicaciones asociadas

## Article

# Architectural Proposal for Low-Cost Brain–Computer Interfaces with ROS Systems for the Control of Robotic Arms in Autonomous Wheelchairs

Fernando Rivas <sup>1,\*</sup> , Jesús Enrique Sierra <sup>2,\*</sup>  and Jose María Cámara <sup>1</sup> <sup>1</sup> Department of Electromechanical Engineering, University of Burgos, 09006 Burgos, Spain; checam@ubu.es<sup>2</sup> Department of Digitalization, University of Burgos, 09006 Burgos, Spain

\* Correspondence: frivas@ubu.es (F.R.); jesierra@ubu.es (J.E.S.)

**Abstract:** Neurodegenerative diseases present significant challenges in terms of mobility and autonomy for patients. In the current context of technological advances, brain–computer interfaces (BCIs) emerge as a promising tool to improve the quality of life of these patients. Therefore, in this study, we explore the feasibility of using low-cost commercial EEG headsets, such as Neurosky and Brainlink, for the control of robotic arms integrated into autonomous wheelchairs. These headbands, which offer attention and meditation values, have been adapted to provide intuitive control based on the eight EEG signal values read from Delta to Gamma (high and low/medium Gamma) collected from the users’ prefrontal area, using only two non-invasive electrodes. To ensure precise and adaptive control, we have incorporated a neural network that interprets these values in real time so that the response of the robotic arm matches the user’s intentions. The results suggest that this combination of BCIs, robotics, and machine learning techniques, such as neural networks, is not only technically feasible but also has the potential to radically transform the interaction of patients with neurodegenerative diseases with their environment.

**Keywords:** BCI/EEG; robot; ROS; LSTM; deep learning; machine learning; RNN; Jetson Nano; Arduino



**Citation:** Rivas, F.; Sierra, J.E.; Cámara, J.M. Architectural Proposal for Low-Cost Brain–Computer Interfaces with ROS Systems for the Control of Robotic Arms in Autonomous Wheelchairs. *Electronics* **2024**, *13*, 1013. <https://doi.org/10.3390/electronics13061013>

Academic Editor: Jichai Jeong

Received: 8 January 2024

Revised: 18 February 2024

Accepted: 22 February 2024

Published: 7 March 2024



**Copyright:** © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

Over the past decade, the intersection of neuroscience and robotics has experienced exponential growth, largely driven by advances in brain–computer interfaces (BCIs). These technologies, which translate brain activity into commands for external devices, have opened new possibilities for enhancing the quality of life of individuals with severe motoric disabilities [1,2] Unlike conventional interfaces, such as those using eye movement ElectroOculoGraphy (EOG) or facial muscle contractions (electromyography, EMG) [3,4]. BCIs require no connection to peripheral muscles or nerves, allowing control of devices without verbal or physical interaction [5,6]. This is particularly relevant for patients in advanced stages of diseases that preclude any movement, such as subcortical stroke, amyotrophic lateral sclerosis, or cerebral palsy.

Specifically, the use of BCIs in assisted mobility, like wheelchair control, represents a rapidly developing and promising research field [7]. This study focuses on the integration of low-cost BCIs, specifically using commercial ElectroEncefaloGraphy (EEG) headbands with a single electrode, for controlling robotic arms on autonomous wheelchairs, an area that has not yet been exhaustively explored [8].

Controlling assistive devices through brain signals not only offers new hope for individuals with physical limitations but also poses significant technical challenges. Accuracy, ease of use, and adaptability are crucial aspects that must be addressed to ensure the feasibility of these systems in real-world environments. In this context, our work focuses on the use of commercial EEG headbands, providing a non-invasive and accessible way to capture brain signals [1].

Integrating these technologies with autonomous robotic systems presents a series of unique challenges. The architecture of the system proposed in this study includes a development board capable of hosting both artificial intelligence (AI) and running the Robot Operating System (ROS), along with a microcontroller to control the drivers associated with the stepper motors of a six-axis cobot and wheelchair movements. This setup allows real-time interpretation of EEG signals and an adaptive response of the system, ensuring that the robotic arm's action aligns with the user's intentions [9].

The incorporation of the AI development board is crucial for the efficient real-time processing of EEG data. The ability of these boards to run deep learning models, such as Convolutional Neural Networks (CNNs) and Recurrent Neural Networks (RNNs), facilitates the accurate interpretation of brain signals [10]. These models are essential for decoding complex patterns of brain activity and converting them into specific commands for robotic control.

Moreover, the use of ROS as a software architecture underpins the system's flexibility and scalability. ROS provides a robust platform for integrating various software and hardware modules, enabling efficient communication between the development board and other system components, such as sensors and actuators [11]. This modular architecture facilitates the implementation of improvements and adaptation to different types of BCI applications.

On the other hand, the microcontroller plays a fundamental role in controlling the physical components of the system. Its capability to handle multiple inputs and outputs makes it ideal for controlling the stepper motors and other mechanical elements of the robotic arm and wheelchair. The combination of the development board with the microcontroller and ROS creates an integrated system capable of performing complex tasks efficiently and reliably.

This paper details the design and evaluation of a BCI system architecture that combines EEG signals, machine learning techniques with neural networks, and robotic systems, focused on providing solutions for individuals with neurodegenerative diseases, spinal problems, or any other reason that may lead to a reduction in their natural motor abilities. With this architecture, we aim not only to demonstrate the feasibility of the proposed development but also to make a significant contribution to the emerging field of BCI-assisted mobility, paving new paths for the research and development of more advanced and accessible BCI mobility solutions.

The content of this article is structured by initially addressing Section 2, which focuses on the state-of-the-art study of BCI systems to date, followed by a description of the iterative process of defining the architecture in Section 3, in the Research Methodology section. It continues in Section 4 with a description of the proposed architecture, breaking down the study into functional architecture, hardware, and software. Section 5 relates to the results of the development, compliance with identified requirements, and the economic and legal technical feasibility of the proposal, concluding the article with Section 6 on discussion and Section 7 with conclusions and future work that complete the content of the paper.

## 2. State of the Art

In recent years, as evidenced in published research, there have been significant advancements in the field of BCIs applied to wheelchair control and other assistive devices. In 2021, a notable study by Banach et al. explored the use of Alpha wave-based EEG signals for controlling electric wheelchairs, offering a new mode of interaction for individuals with incurable diseases that severely limit their communication and mobility [12]. This approach marks a critical advancement in aiding individuals "locked-in" their bodies due to severe conditions.

Furthermore, Antoniou et al. (2021) introduced an innovative system using a brain-computer interface to capture EEG signals during eye movement, classifying them into six categories using a random forest classification algorithm [13]. This development is significant in the interpretation of EEG signals for BCI applications [14]. On another

note, a 2019 study, extending into 2021, demonstrated a hybrid brain–computer interface (hBCI) combining EEG and EOG signals to control an integrated wheelchair and robotic arm system, showing satisfactory control accuracy and highlighting the potential of BCI-controlled systems in complex daily tasks.

In a similar vein, a 2021 study by researchers explored a facial–machine interface system based on EEG artifacts to enhance mobility in individuals with paraplegia using the Emotiv Neuroheadset. Results indicated that combining eye and jaw movements can be highly efficient, suggesting a practical hybrid BCI system for wheelchair control [15].

Another significant study in 2021 focused on developing an operative motor controller that can extract and read brain signals to convert them into usable commands to act upon the wheels of a wheelchair [16]. Also, a semi-autonomous navigation control system for an intelligent wheelchair was presented, based on asynchronous Steady State Visually Evoked Potential (SSVEP), demonstrating high stability and flexibility [17].

Finally, a work by Olesen et al. (2021) investigated the possibility of a hybrid BCI system combining EEG and EOG signals for the remote control of a vehicle, such as a wheelchair, using machine learning techniques to design a robust and computationally efficient system [18]. These studies represent a significant body of work in the development of BCI technologies to enhance the quality of life for individuals with severe physical disabilities.

Recent research in the realm of EEG-based BCIs has made significant strides, especially in applications for controlling robotic devices like robotic arms and wheelchairs. Here is a structured summary of key developments in this field, reflecting the current state of the art and highlighting principal focus areas, as well as significant challenges and achievements.

**Advancements and Utilization of BCI Technologies:** BCI systems endeavor to establish a conduit between the human cerebrum and external apparatuses. Prior investigations have underscored the potential of BCIs in maneuvering both virtual entities and tangible objects, such as wheelchairs and quadcopters. Yet, the application of non-invasive BCIs in directing robotic limbs for reach and grasp endeavors poses significant hurdles [13,19].

**BCIs for Individuals with Motor Impairments:** Persons afflicted with severe neuromuscular conditions or motor system impairments often experience a loss of voluntary muscle control. Nonetheless, many retain the ability to generate neural signals pertinent to motor functions akin to those of unimpaired individuals. This revelation has propelled the exploration of BCIs as a nascent technology capable of decoding cerebral activity in real time, thereby facilitating anthropomorphic manipulation of prosthetic or exoskeletal assistive devices [19].

**Non-Invasive BCIs in Robotic Limb Control:** The aspiration to control robotic limbs via non-invasive BCIs presents a compelling alternative, albeit with constraints in achieving adept multidimensional manipulation within a three-dimensional ambit. While previous endeavors have predominantly focused on virtual and tangible object control, scant research has ventured into the domain of prosthetic or robotic limb manipulation through scalp-based EEG BCIs [13].

**Experimental Framework and Reach and Grasp Tasks:** Addressing this lacuna, experiments were meticulously designed, incorporating progressively challenging reach and grasp tasks. A cohort of healthy participants was enlisted to navigate a robotic limb through intricate tasks using non-invasive BCIs, segmented into two phases: initial guidance of the cursor/robotic appendage across a bi-dimensional plane toward an object positioned in a tri-dimensional space, followed by the downward maneuver of the robotic limb to secure the object. This sequential experimental approach effectively minimized the degrees of freedom required for BCI interpretation, thereby simplifying the grasping mechanism within a tri-dimensional context [13].

**User Proficiency and Control Retention:** Participants exhibited an exceptional aptitude in modulating their cerebral rhythms to govern a robotic limb using our bifurcated non-invasive control schema. They adeptly mastered the manipulation of a robotic limb to

seize and reposition arbitrarily located objects within a confined tri-dimensional space, consistently maintaining control proficiency over multiple sessions spanning 2–3 months [20].

This summary reflects the evolution and current state of the art in the development of BCIs for controlling robotic devices, underscoring both the achievements and the outstanding challenges in this research area. Continuation in innovation and refinement of these technologies is essential to overcome current limitations and expand the practical applications of BCIs in assisting individuals with motor disabilities and enhancing human interaction with advanced technologies. Several key challenges for future research in the field of BCIs for controlling robotic limbs can be identified.

**Improvement in Accuracy and Speed:** Although significant advancements have been made, the accuracy and response speed of BCI systems in controlling robotic limbs can still be limited. Investigating methods to enhance the decoding speed of brain signals and the precision of control would be a valuable area of research.

**Integration of Sensory Feedback:** Most current BCI systems primarily focus on translating user intentions into commands for the robotic device. Incorporating sensory feedback, such as touch or pressure, into the BCI system could significantly improve natural interaction and control efficacy.

**System Adaptability and Learning:** Developing BCI systems that can adapt and learn from individual user interactions could enhance personalization and efficiency of control. This includes adapting to changes in the user's brain signals over time or between sessions [13].

**Reduction in User's Mental Load:** Controlling complex devices via BCIs can be mentally demanding for users. Investigating ways to reduce this mental load, possibly through hybrid or shared control systems, is crucial for the long-term viability of BCIs in practical applications.

**Improvement in Non-Invasiveness and Comfort:** Although non-invasive BCI systems have advanced, they can still be uncomfortable or impractical for prolonged use. Investigating new sensing technologies and algorithms that improve comfort and ease of use without compromising performance would be beneficial [20].

**Applications in Rehabilitation and Assistance:** Further exploring how BCI systems can be customized and optimized for rehabilitation and assistance applications, especially for individuals with severe motor disabilities, is an area of great potential.

**Enhanced Brain–Robot Interface:** Developing more intuitive and natural interfaces between the human brain and robotic devices, possibly through improved artificial intelligence and machine learning algorithms, could significantly enhance the usability and acceptance of BCI systems [20].

**Ethics and Privacy:** As BCI systems become more advanced, ethical and privacy concerns related to the access and use of brain data arise. Addressing these concerns and developing clear ethical guidelines will be crucial for the widespread adoption of BCI technology.

These challenges represent exciting and fundamental areas for future research, with the potential to significantly advance the field of brain–computer interfaces and their application in controlling robotic devices.

Considering the comprehensive review of existing work, our proposed approach is designed to overcome the identified limitations and challenges. Leveraging advanced algorithms and innovative hardware integration, we aim to offer a more robust, efficient, and user-centric solution. By adopting a holistic and adaptive framework, our method not only addresses immediate technical limitations but also paves the way for future improvements. In this way, our approach remains at the forefront of technological advances and offers a scalable and flexible solution that adapts to changing user needs and new challenges in the field.

### 3. Research Methodology, Iterative Process of Defining the Architecture

We will start by outlining the workflow performed, which can be seen in Figure 1, to develop the definition of the proposed architecture and achieve the results presented.

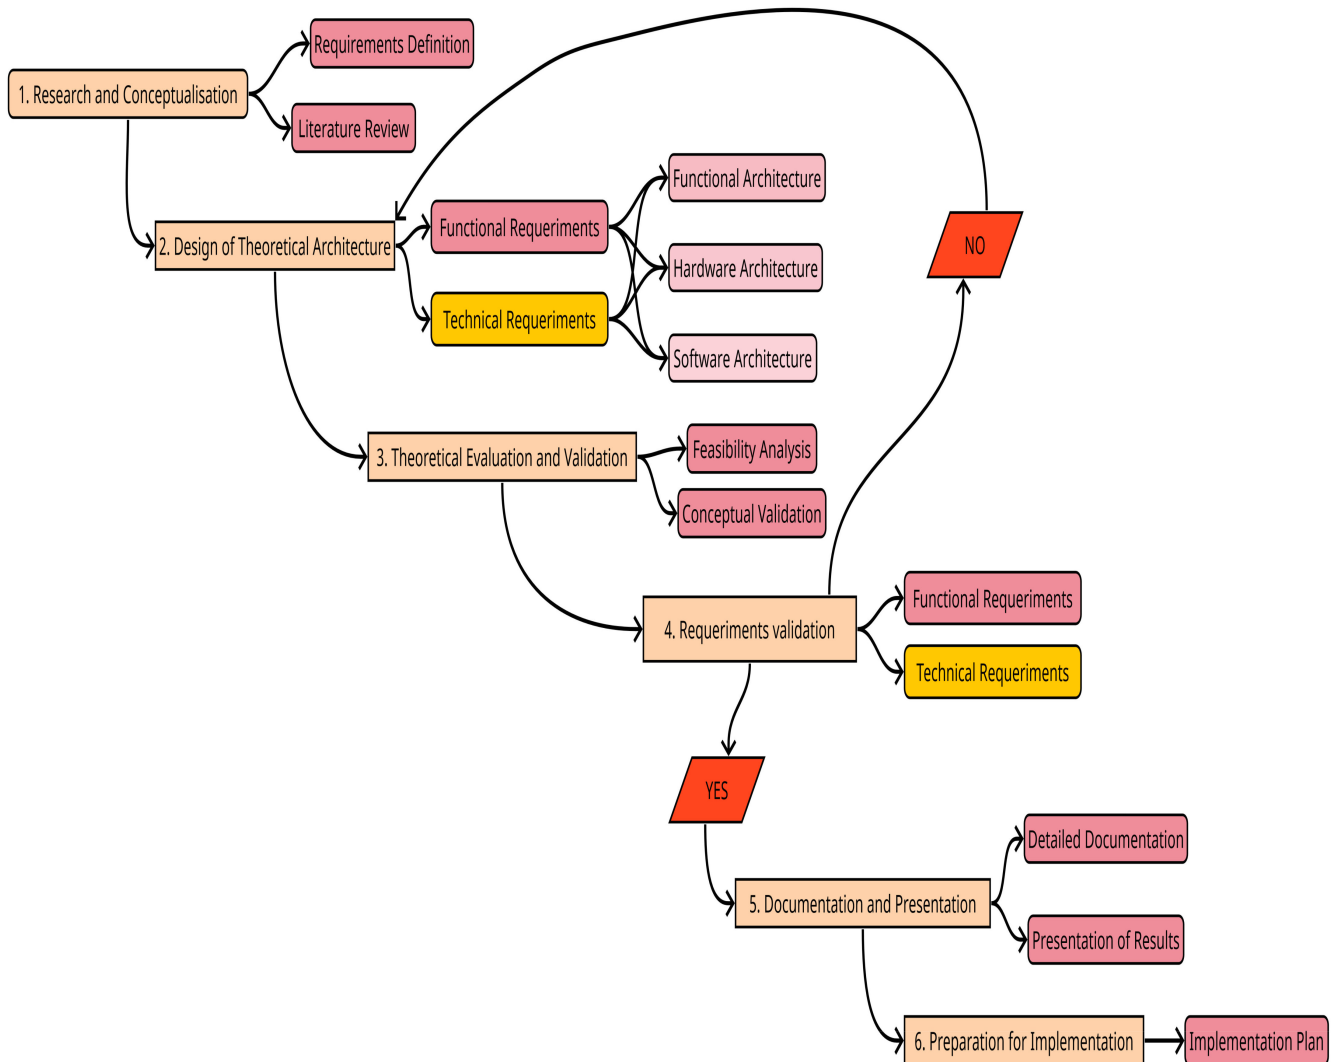


Figure 1. Workflow.

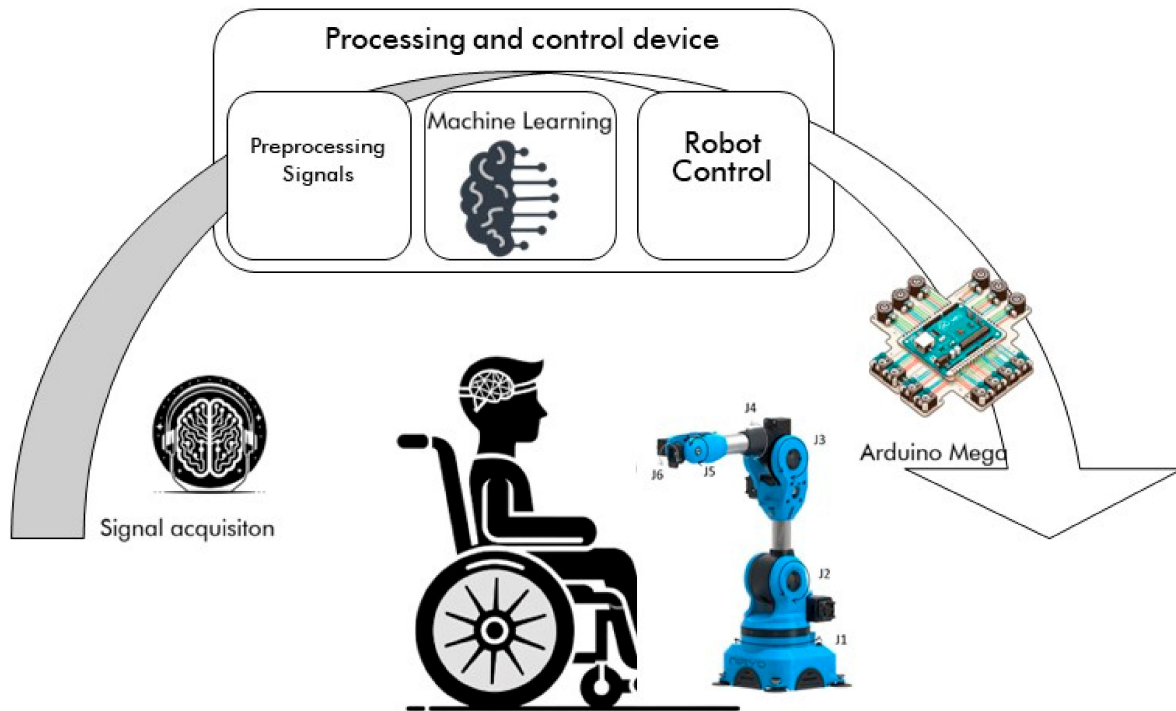
The workflow commences with an extensive bibliographic review and analysis of existing studies to understand best practices and available technologies in BCIs, robotics, and assistive systems. Based on the research, functional and technical requirements that need to be met are defined. This phase focuses on theory and technical possibilities.

Next, a theoretical model of how functional components interact to fulfil the functional requirements are designed. Then, a theoretical hardware structure, selecting ideal components based on theoretical and comparative analyses, is proposed. From the hardware structure, a theoretical software architecture choosing frameworks, languages, and algorithms based on their theoretical suitability is designed.

Once the architectures are proposed, the theoretical models are evaluated to verify their feasibility. The feasibility analysis conducts a detailed analysis of the technical, economic, and operational feasibility of the proposed architecture. Then, the validation of the requirements defined in the design stage, both functional and technical requirements, is conducted.

This approach ensures a thorough and well-founded development of the architecture before any physical implementation, minimizing risks and ensuring that the design is suitable for the end user’s needs.

A conceptual diagram of the basic architecture can be seen in Figure 2. It is essential to note that we are combining brain data capture technologies through EEG signals from a specific area of the brain to ultimately control a collaborative robot or cobot positioned at a point in space, combining 6 stepper motors in conjunction with a motorized wheelchair.



**Figure 2.** Conceptual diagram of the basic architecture for control of a wheelchair and a cobot.

For this development, the functional requirements of the system and the technical requirements have been identified separately to ensure, firstly, the suitability of the architecture and, secondly, the feasibility of the system and its value proposition.

3.1. Functional Requirements

Table 1 below sets out the functional requirements identified for the development of the research and the necessary architecture, which can be seen in the functional architectures, hardware, and software section of this paper (Figures 3, 4 and 13).

**Table 1.** Functional requirements tables.

Functional Requirements	Why
Capture of EEG signals	Correctly interpret user intentions.
Real-time interpretation of EEG signals	Immediate response of the system.
Intuitive control of the robotic arm and wheelchair	Facilitate operation by users with limitations.
Safety and stability in movement	Ensure user safety.
Adaptability to different users	Usable by a wide range of patients. Neurodegenerative diseases. Reduced mobility. Spinal cord injuries. Postoperative.
Control of the wheelchair’s movements	Precise movements in the displacement of the chair, forward, backward, left, right, diagonal forward left, forward right.
Integration of the system with commercial chairs	Ability to control commercial motorized chairs without substantial modifications.
Portability and low weight (<100 g)	Improved user experience and ease of use.

Table 1. Cont.

Functional Requirements	Why
EEG/ECG signal quality analysis	Guarantee of reading and improvement in the usability of the system (EEG headband)
Commercial wireless headbands	Wireless connection to avoid cables and problems of tangling and/or accidents. BLE connection.
Preset routines in the actions of the robot and robot + chair.	Facilitate repetitive actions, improve the usability of the system.

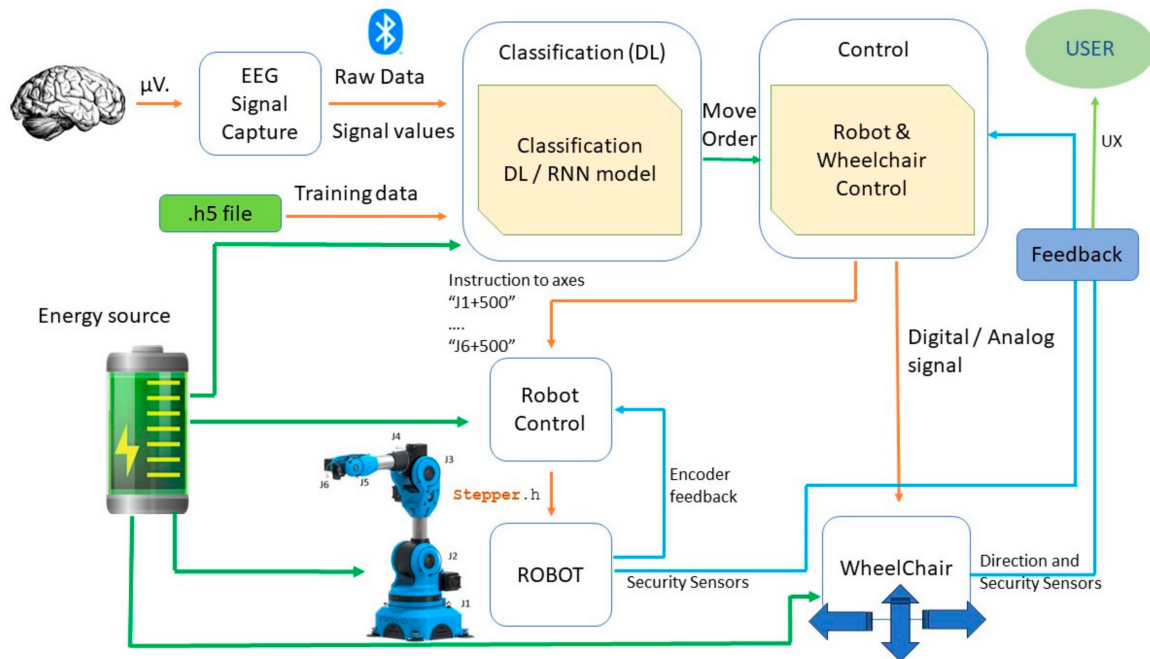


Figure 3. Functional architecture.

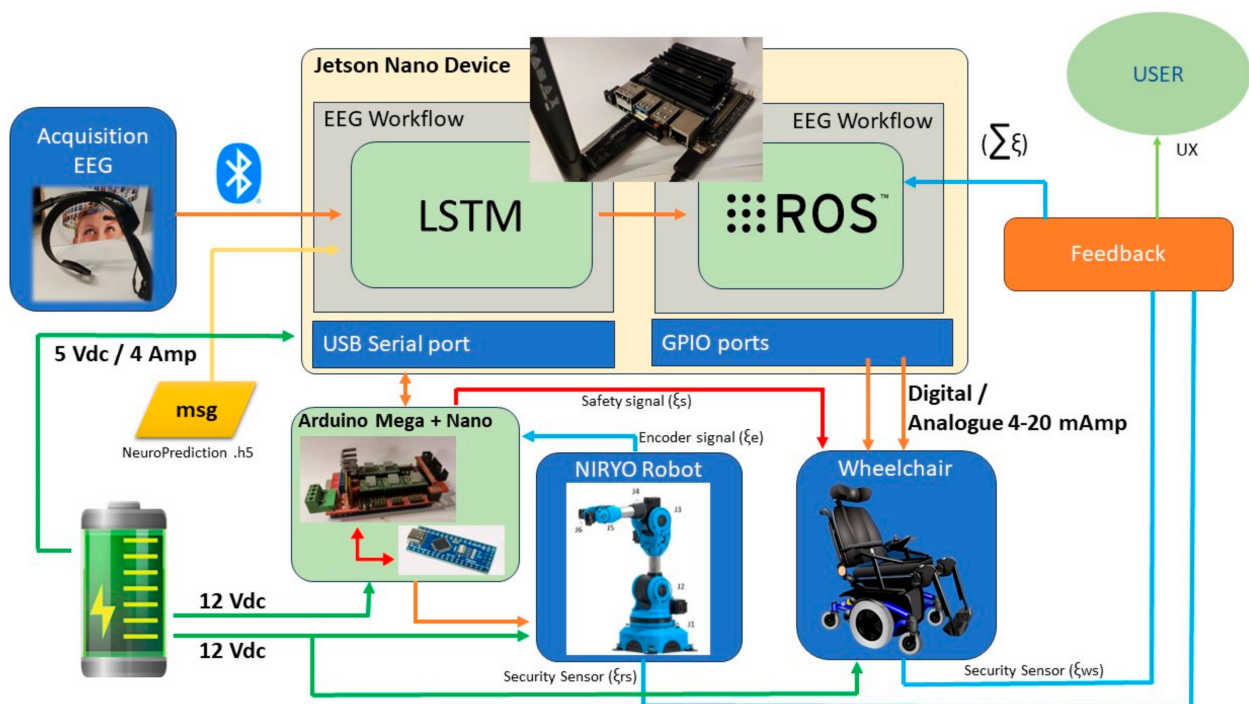


Figure 4. Hardware architecture.

Further information on each of the functional requirements identified in Table 1 can be found in Appendix A.

To group functional and technical requirements into typologies, we can consider several aspects, such as the main functionality of the system, usability, adaptability, security, portability, and others, as you can see next. Here is a proposed grouping with at least five typologies and at least two requirements in each:

- **Functionality and Integration:** EEG signal capture; real-time interpretation of EEG signals; system integration with commercial chairs.
- **Control and Operability:** Intuitive control of the robotic arm and wheelchair; control of wheelchair movements.
- **Adaptability and Usability:** Adaptability to different users; preset routines in robot and robot + chair actions.
- **Safety and Stability:** Safety and stability in motion; EEG/ECG signal quality analysis.
- **Portability and Compatibility:** Portability and low weight (<100 g; commercial wireless headsets).

Each of these groups covers a set of key aspects of the system, from how it interacts with the user and the environment to how security and usability are ensured. This grouping should provide you with a clear structure for organizing and addressing the functional requirements of the project. These requirement groups will be used to compare the architecture with other previous works.

### 3.2. Technological Requirements

In Table 2, we can find the identified technical requirements necessary for the development of the proposed architecture.

**Table 2.** Technical requirements table.

Technical Requirement	Why
Effective integration of BCI with chair + robot	Smooth communication between BCI and control system
Efficient EEG data processing ( $t \leq 1$ s)	Minimize latency and maximize accuracy
Real-time interpretation of EEG signals	Immediate response of the system
Robust control system for robotic arm and wheelchair	Precise and safe movements
Accessible and user-friendly interface	Facilitate user interaction with the system
User feedback system	Inform the user about the system's status
Integration with commercial motorized wheelchairs	Compatibility with existing systems
Usage autonomy ( $\geq 3$ h)	Limitation of use due to the autonomy of the wheelchair and the headband
Support for multi-platform headbands, Windows, Apple, Linux, Android	Possibility of connecting the headband with multiple platforms to facilitate the interconnection between devices
Low integration cost (<EUR 1500)	The cost of integration should not be a barrier to entry for the end user
Compliance with applicable regulations	Compliance with current regulations and CE marking

Further information on each of the technical requirements identified in Table 2 can be found in Appendix A.

To group technical requirements, we can consider aspects such as integration and compatibility, system efficiency and performance, usability and accessibility, autonomy and economic sustainability, and regulatory compliance. Here is a proposed grouping with at least five typologies and at least two requirements in each:

- **Integration and Compatibility:** Effective integration of BCI with chair + robot; integration with commercial motorized wheelchairs; multi-platform headset support.
- **Efficiency and Performance:** Efficient EEG data processing ( $t \leq 1$  s); real-time interpretation of EEG signals; robust control system for robotic arm and wheelchair.
- **Usability and Accessibility:** Accessible and user-friendly interface; user feedback system.

- **Autonomy and Economic Sustainability:** Autonomy of use ( $\geq 3$  h); low integration cost ( $< \text{EUR } 1500$ ).
- **Regulatory Compliance:** Compliance with applicable regulations.

Each of these groups addresses different technical aspects that are fundamental to the development and effective implementation of the system.

These tables and the detailed information for each requirement will serve as a reference for determining the feasibility of the proposed architecture.

#### 4. Architecture

This section presents the proposed architecture to achieve the research objectives and requirements presented in Sections 3.1 and 3.2 of these documents.

The architecture is described by levels of abstraction, from functional levels through hardware elements to software components.

##### 4.1. Functional Architecture

Figure 3 illustrates the developed functional architecture of the BCI system to control a robot and a motorized wheelchair. The process begins with the capture of EEG signals from the brain, measured in microvolts ( $\mu\text{V}$ ) and segmented by frequency ranges: Delta, Theta, Alpha, Beta, and Gamma signals. These raw signals, filtered by the TGAM, are then processed, and their values are used as training data in an initial stage and subsequently utilized in real time. LSTM networks are deep learning models that require a previous training process before they can be used to make predictions or classifications. This training allows the LSTM network to learn patterns and relationships in the training data.

Precise hyperparameter tuning is crucial as it can drastically impact LSTM convergence, overfitting, and generalization. Factors like the number of layers, nodes per layer, activations, dropouts, batch size, and optimizers each play a key role. These hyperparameters can be manually adjusted, although an automatic method such as random search is recommended.

Once the LSTM network is trained, the optimized weights and parameters of the model are saved in a file with a .h5 extension. This file basically contains all the “memory” and knowledge captured by the LSTM network during training.

If we wanted to use the LSTM network to classify new data, it is absolutely necessary to load the .h5 file with the trained weights. Otherwise, we would be using an untrained LSTM network, which would provide completely random or erroneous classification results.

The next stage is classification, likely through a DL model or RNN. The model interprets the EEG signals and issues a movement order, which is transmitted to the robot’s control system. This order can be as specific as “M1 + 500”, encoding a particular action of the robot or wheelchair, with different values associated with and varying depending on the number of degrees of freedom of the system (M1 and M2 for wheelchair motors and J1 to J6 for the axes of the robot). In this case, a total of eight degrees of freedom are considered: six from the robot and two from the motorized wheelchair, as the combination of turning the two motors, right and left, facilitates the complete mobility of the wheelchair, according to the user’s commands.

Figure 3 presents the functional architecture of our brain–computer interface (BCI) system, which is designed for controlling robotic devices and motorized wheelchairs. It begins with capturing EEG signals from the brain, which are categorized into various frequency bands like Delta, Theta, Alpha, Beta, and Gamma. The RNN model receives the raw data of these signals as inputs to generate the movement orders. Different DL neural networks can be used, but Long Short-Term Memory (LSTM) networks are recommended due to their proven efficiency in signal classification tasks. In this architecture, it is shown that this RNN has been previously trained (information in h5 file), and here, it is utilized for real-time decision making.

The movement orders are received by the control module. The control module communicates with the wheelchair, and the module controls the robot. This component adapts the abstract commands sent by the classification system to the low-level commands or control signals of the devices. In addition, it oversees all the actions carried out by the system.

On the other hand, the robot control module is in charge of managing the low-level control of the robotic arm. It generates the speed references for the motors to control the position of each joint. As feedback position, it receives the encoder signal of each joint. The control of the robot is managed through a module, possibly a C++ code file (indicated by the .h extension for a header file). Finally, the energy source provides the required power to all the components in the architecture.

Finally, the system provides feedback to the user, likely indicating whether an action has been executed or if there is any error or state that the user needs to be aware of. This feedback loop is essential for the interactivity and real-time error correction of the BCI system.

#### 4.2. Hardware Architecture

The elements that make up the proposed architecture are the following, which can be seen in Figure 4, which describes, in addition to the actual photograph of the hardware device, the main functional characteristics of each of the elements.

Figure 4 shows the hardware architecture of a BCI system, with a complex network of components designed to control robotic devices and motorized wheelchairs. At the core of the acquisition process, EEG signals are captured by the Neurosky and/or Brainlink devices, which capture and read the user's brainwaves. These signals are then transmitted to the Jetson Nano device, a compact hardware device capable of performing computationally intensive tasks. The signals are transmitted via Bluetooth, which ensures wireless communication for the user's convenience and mobility.

The Jetson Nano processes EEG signals through an LSTM neural network, a type of recurrent neural network recommended for its ability to handle time series data. This LSTM is responsible for managing the EEG data workflow and generating movement commands based on the analysis performed. The ROS operating system acts as a middleware that enables communication between the various hardware and software components. This process is carried out within the Jetson Nano, optimizing the process of analysis, communication, and management of the orders associated with the EEG signal values.

The signals resulting from the above process are routed to various ports depending on the function to be performed. The USB serial port facilitates direct communication with the Arduino modules responsible for controlling the robot and the system's safety chain, while the GPIO ports will focus on the direct control of the motorized wheelchair's movements. The safety signals ( $\xi_s$ ) and encoder signals ( $\xi_e$ ) are crucial to the operation of the robot: the safety signal serves as an emergency or caution interrupt redundantly, and the encoder signal provides information about the positions of the robot's joints, controlling the actual position of each of the robot's axes.

The Arduino Mega + Nano configuration is the microcontroller platform that receives commands from the ROS part of the Jetson Nano, processes these signals, and translates them into physical movements of the NIRYO robot, which is shown with a blue outline, indicating its status as the central element of the system. The Arduino setup is also responsible for handling encoder feedback and issuing safety signals as needed.

The wheelchair interface is represented by a digital/analog signal line (4–20 mA), common in industrial control systems, to manage its operation. Power is supplied by a 12 Vdc supply, and there is a secondary 5 Vdc/4 Amp power supply line, highlighting the system's need for different voltage levels for various components.

In adherence to stringent safety standards, a dual redundant system based on Arduino technology has been incorporated, which integrates an Arduino Mega with an Arduino Nano, both connected to the Jetson Nano. In turn, these Arduino devices are connected to the safety chain of the electrical wheelchair. This configuration ensures that in the event of

a malfunction in any of the devices or an anomaly within the safety chain, the entire system will halt, thereby activating the safety mechanisms of the motorized wheelchair. This setup guarantees continuous monitoring of the system's performance, effectively precluding any safety hazards during operation. Such a redundant system not only reinforces the reliability of our setup but also aligns with the highest safety norms, ensuring that our design is safe and functional.

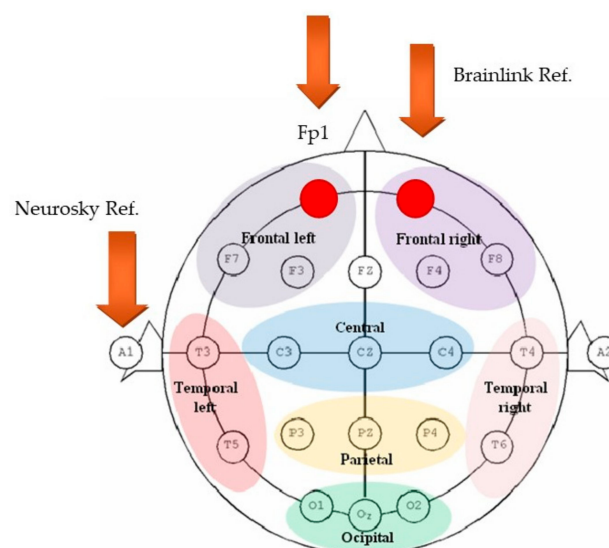
#### 4.2.1. EEG Data Acquisition

In our research, the capture of EEG data is conducted using low-cost devices such as Neurosky and Brainlink commercial headbands. This represents a significant advancement in the accessibility, application, and democratization of EEG technology in BCIs. These headbands, unlike traditional EEG systems, offer a practical and non-invasive solution for capturing brain signals, although with certain limitations in terms of resolution and spatial precision since they only collect signals from a specific area of the user's brain, as described in Figure 5. On the other hand, the use of these headbands, due to their ease of use, favours the comfort and portability of the device for the user, eliminating the need to wear bulky devices or caps with multiple electrodes.



**Figure 5.** Brainlink headband from MacroTellec (left). Brainwave headband from Neurosky (right).

These devices capture a wide range of brain signals from the prefrontal area of the user's skull, specifically from points (Fp1) as observed in Figure 6, obtaining Delta (1–3 Hz), Theta (4–7 Hz), Alpha (8–13 Hz, subdivided into high and low), Beta (14–30 Hz, subdivided into high and low), and Gamma (31–100 Hz, subdivided into high and low) waves [14].



**Figure 6.** Electrode position (researchgate source).

These devices feature a chip called TGAM integrated into the headbands, which performs essential preprocessing of the data, filtering noise in the extraction of these characteristics [15]. In addition to the brain signals, they provide attention and meditation indices calculated from the processed EEG signals. The voltage amplitudes of these signals vary between 20 and 200  $\mu\text{V}$  [16], with the voltage ranges of the EEG signals presented in Table 3.

**Table 3.** Frequencies and voltages of captured brain signals.

Brain Signal	Frequency (Hz)	Voltage (V)
Delta Waves	1–3 Hz	20–200 $\mu\text{V}$
Theta Waves	4–7 Hz	10–100 $\mu\text{V}$
Alpha Waves	8–13 Hz	20–100 $\mu\text{V}$ <sup>1</sup>
Beta Waves	14–30 Hz	5–30 $\mu\text{V}$ <sup>2</sup>
Gamma Waves	31–100 Hz	>20 $\mu\text{V}$ <sup>3</sup>

<sup>1</sup> Alpha waves are prominent when a person is relaxed but awake, especially with eyes closed. <sup>2</sup> Beta waves are associated with concentration and active thinking. <sup>3</sup> Gamma waves are associated with higher cognitive processes.

A crucial technical aspect of these headbands is their signal capture method. The Neurosky headband, for instance, uses a dry electrode on the forehead and a reference point on the left earlobe to establish a baseline voltage of 0. In contrast, the Brainlink headband uses a reference point on the user’s own forehead. This simplified signal capture approach, though it limits spatial resolution, makes the headbands ideal for BCI applications where the complexity and cost of traditional medical EEG systems are very high.

The operation of the Neurosky headset and the preprocessing of EEG signals involves several stages. First, the raw EEG data are subjected to a common reference and baseline correction process [21]. Subsequently, artifact detection algorithms, such as facial gestures or muscle movements, can be applied to identify and remove unwanted signals [22]. In addition, relevant feature extraction steps are performed from the pre-processed signals for further analysis [23]. These processes are essential to ensure the quality of EEG data and their usefulness in brain–computer interface applications and other research areas.

ThinkGear technology in the Neurosky headband is a system that amplifies the raw brainwave signal, eliminates noise and artifacts, and delivers a digitized brainwave signal [20]. This technology, together with a dry electrode, enables the acquisition of EEG signals for further processing and analysis in brain–computer interface applications and other areas of research. ThinkGear and TGAM are Neurosky’s patented technologies.

Figure 7 provides a comprehensive visualization of EEG signal fluctuations over time across various frequency bands: Delta, Theta, Alpha (low and high), Beta (low and high), and Gamma (low and high), alongside metrics for attention and meditation. The figure demonstrates the complexity and dynamic nature of brain activity, as well as the capability of our system to capture and distinguish between different mental states and cognitive loads. These data are crucial for our analysis as they validate the sensitivity and specificity of our BCI system in detecting and interpreting nuanced patterns of neural activity, which is foundational for accurate system responses.

The eight base signals, from Delta to Gamma, can be observed, along with the attention and meditation values calculated by the Neurosky algorithm [24].

The application of these headbands in signal labelling for BCIs is particularly promising. Initially, our focus was on using motor imagery to label EEG signals. This technique, which involves mentally simulating movements without physical execution, has the potential to enable users to control devices by simply imagining movements. Additionally, we are exploring models based on evoked potentials, such as P300 and SSVEPs, for cases where motor imagery does not provide the desired level of control [25].

However, low-cost EEG headbands present challenges related to the quality and accuracy of the captured signals. Limitations to a single capture point and the use of dry electrodes reduce spatial resolution and data fidelity. Despite this, advances in machine

learning algorithms and signal processing are improving the interpretation of these data. For example, the article “Methodologies and Wearable Devices to Monitor Biophysical Parameters Related to Sleep Dysfunctions: An Overview” (2022) by Roberto De Fazio et al. provides an overview of the use of EEG devices in monitoring applications, which can be extrapolated to BCI applications [26].



**Figure 7.** Brain signals obtained with Brainlink headset.

Looking forward, the combination of these low-cost technologies with sophisticated algorithms promises broader integration of BCIs in various applications. Future research should focus on improving the accuracy of these devices and exploring new methodologies for signal classification. The democratization of access to EEG technology opens a world of possibilities in the field of neuroscience and human–computer interaction, promising significant advances in understanding and manipulating brain activity.

#### 4.2.2. Hardware for Classification and Control

The NVIDIA Jetson Nano (Figure 8), pivotal for classification and control tasks in our BCI project, is a compact AI powerhouse. With its quad-core ARM Cortex-A57 CPU

and 128-core Maxwell GPU, it is adept at running parallel neural networks and handling multiple high-resolution streams, courtesy of 4 GB LPDDR4 RAM. Its compatibility with a plethora of interfaces like GPIO and I2C, along with its real-time computational prowess, makes it ideal for real-time EEG signal processing with LSTM networks and robotic control via ROS, providing the necessary speed and parallel processing capabilities for sophisticated robotics and BCI applications.



Figure 8. Jetson Nano device.

Table 4 summarizes the key specifications and features of the NVIDIA Jetson Nano.

Table 4. Jetson Nano specifications.

Feature	Specification
CPU	Quad-core ARM Cortex-A57
GPU	128-core NVIDIA Maxwell
Memory	4 GB LPDDR4 RAM
Interfaces	GPIO, I2C, I2S, SPI, UART
Suitable Applications	Robotics, BCI projects
Specialties	Real-time processing, AI tasks, multiple neural networks

These specs highlight the Jetson Nano’s capacity for complex, high-speed AI computations and its suitability for advanced BCIs and robotics systems.

The Arduino Mega, powered by the ATmega 2560 (Figure 9), is a versatile microcontroller with 54 digital I/O pins, 16 analogue inputs, and 4 UARTs, suitable for complex projects involving multiple I/O operations, such as robotic control. It is complemented by the Ramps 1.4 shield, which can manage five stepper motors, typical in precision applications such as 3D printing. This shield also supports power controller drivers for high endurance operation and variable power requirements. Together, the Arduino Mega and Ramps 1.4 shield form a powerful duo for a six-axis robotic system, offering the control and power needed to drive multiple motors and axes with precision. This cost-effective and customizable combination is capable of the detailed motion control essential to the requirements of the BCI project, allowing for custom tuning and scalability of the system.





Figure 9. Arduino Mega + Shield Ramps 1.4 (left); Arduino Nano 33 (right).

The Arduino Nano, a compact microcontroller board based on the ATmega 328P, plays a critical role in our redundant safety system. Its small footprint and robust functionality make it an ideal choice for embedding within complex systems. In our setup, the Nano serves as a backup controller, working in conjunction with the Arduino Mega to ensure system reliability. Through seamless communication with the Mega, it provides an additional layer of monitoring and control, enhancing the safety and stability of the motorized wheelchair's operation.

#### 4.2.3. Cobot and Motorized Wheelchair

The integration of advanced technologies in motorized wheelchairs and cobots, such as the Niryo (Figure 10) open-source model, represents a significant advance in assistance for people with reduced mobility [27,28]. This integration not only improves the autonomy of users but also opens new possibilities in terms of control and adaptability.



**Figure 10.** Open-source NIRYO ONE robot.

Modern motorized wheelchairs (Figure 11), offer various control options to suit the individual needs of users. Control methods include joysticks, manual controls, and remote control, each with its own advantages in terms of accessibility and ease of use. For example, a study on “Modelling and control strategies for a motorized wheelchair with hybrid locomotion systems” highlights the importance of versatile control systems in motorized wheelchairs [29].



**Figure 11.** Basic model of motorized wheelchair.

The proportional control of power wheelchairs (Figure 12) improves manoeuvrability and user comfort by adjusting the movement to the force applied., which is vital for a safe and pleasant driving experience. Studies, such as one on motorized wheelchair imple-

mentation for the handicapped, affirm the efficacy of proportional controls. Wheelchair access can be through parallel joystick control or directly to the motor driver, allowing movement control via digital or analogue setpoint signals. Collaborative robots (cobots) like the open-source Niryo model offer adaptability to various environments and tasks, with precise programming capabilities making them suitable for daily assistance and user life quality improvement [27]. Integrating cobots with motorized wheelchairs, such as the Niryo One, a six-axis robot designed for education, research, and industry, fosters new assistance and autonomy avenues. This integration allows cobots to perform tasks while the user navigates, enhancing efficiency and independence.



**Figure 12.** Manual control of motorized wheelchair.

The Niryo One’s simple, efficient mechanical design, its ease of programming through Niryo Studio, and 3D Unity visualization cater to users across technical proficiencies, enabling immersive learning and operation understanding. Its precision and repeatability are pivotal for EEG signal processing and LSTM network classifications, requiring sensitivity and specificity in tasks involving brain signals. ROS integration expands its application to advanced robotics and BCI projects, making Niryo One an exemplary platform for BCI endeavors that demand seamless hardware–software integration. The combination of its technical capabilities, user-friendly software, and precision control positions Niryo One as an ideal tool for high-level BCI project integration, underscoring the potential of combining advanced control systems and collaborative robotics to enhance autonomy and assistance in BCI applications [30].

Despite advances, there are challenges in integrating these technologies, especially in terms of user interface and accessibility. However, studies such as “Design and Implementation of Hybrid BCI based Wheelchair” show how continuous innovation in wheelchair control can overcome these challenges [31].

#### 4.3. Software Architecture

In this section, we address the integration of EEG signal processing with the robotic control system through ROS. We detail how brain signals are processed using machine learning algorithms and neural networks, enabling precise interpretation of user intentions. This crucial process ensures safe and effective commands for the dynamic control of robotic devices and motorized wheelchairs, highlighting technical innovations and challenges in the brain–computer interface and robotics, based on ROS by the Niryo robot, and other similar robots [27].

As a first approach, Figure 13 presents the diagram of the proposed software architecture, as well as the flow of signals and data necessary for the implementation of the proposed structure.

For this integration, the Jetson Nano device has been used, which allows all the requirements of this development to be integrated into a single device, including each component of the process, its function, specific details, the type of output generated, and the necessary software or libraries.

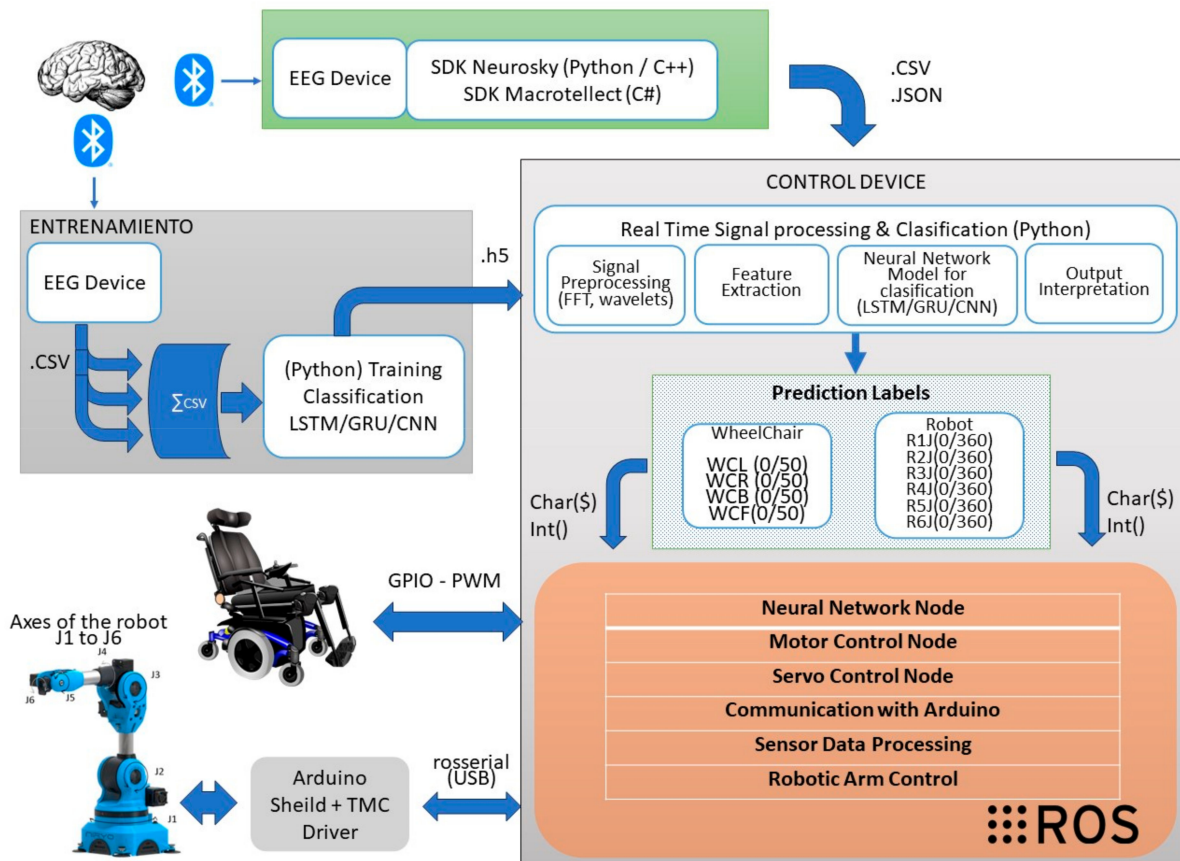


Figure 13. Software architecture.

Having identified the steps for processing the signals in Table 5, we have opted for the NVIDIA Jetson Nano device as our module for execution and data processing.

Table 5. EEG to ROS processing and control structure.

Component	Function	Details	Output	Software and Libraries
EEG Signal Acquisition	Captures raw EEG data from the headset	Direct interface with EEG headband	Raw EEG data	EEG headset SDK or API
Signal Preprocessing	Filters and normalizes EEG signals	Bandpass filters, normalization techniques	Processed EEG data	Python 3.11 libraries (e.g., scipy, numpy)
Feature Extraction	Extracts relevant features from EEG signals	Wavelet transforms, extraction of statistical features	Feature vectors	Python 3.11 libraries (e.g., pywavelets)
Neural Network Model	Classifies signals using a deep learning model	LSTM or Convolutional Neural Network (CNN)	Classification results	TensorFlow (V2.13), PyTorch (2.2.1)
Output Interpretation	Interprets the output of the neural network	Mapping of network output to specific commands	Interpreted commands	Custom script or module
Command Generation	Generates appropriate commands for robotic control	Conversion of network output to control signals	Control commands for ROS	Custom script for integration with ROS

One of the main advantages of the Jetson Nano is its ability to perform deep learning inferences at the edge, meaning it can process data directly on the device without needing a connection to a central server. This is crucial in BCI applications, where low latency and real-time processing are essential for smooth and effective interaction. This is necessary in

our research for the application of controlling wheelchairs or robotic prosthetics, given its capacity to process EEG signals and make real-time decisions, which is fundamental for the safety and efficacy of the system.

Another factor that influenced our choice of the Jetson Nano is its energy efficiency, making it suitable for portable and mobile applications. This is especially relevant in the context of low-cost EEG headbands like Neurosky or Brainlink, where portability and energy efficiency are key considerations. Combining these headbands with a device like the Jetson Nano can facilitate the implementation of BCI systems in non-laboratory environments, increasing their accessibility and applicability in real-life situations.

#### 4.3.1. Real-Time Signal Preprocessing (Jetson Nano)

The Bluetooth connection between the EEG headband and the Jetson Nano initiates the preprocessing of EEG signals, a crucial step in implementing efficient BCIs. This process converts raw EEG signals into a format suitable for real-time analysis and classification, essential for the precision and effectiveness of brainwave classification.

In preprocessing, normalization standardizes the EEG data, while the Fourier Transform and wavelet transforms decompose the signals into frequency components, which is crucial for identifying different cognitive and emotional states. Normalization enhances the robustness of the model, and the Fast Fourier Transform and wavelet transform allow for precise temporal localization of frequencies.

Subasi (2021), in his article, highlights the importance of these techniques in BCIs [32]. Subsequently, the pre-processed EEG signals are classified by neural networks. CNNs and RNNs have proven effective for this, as per Roy et al. (2022) [33].

The integration of these preprocessing techniques with advanced neural networks promises to improve the accuracy and efficacy of BCI systems, opening new possibilities in human–computer interaction and assistance to individuals with motor disabilities.

#### 4.3.2. Classification

The classification of EEG signals, fundamental for brain–computer interfaces, has made significant progress with the incorporation of deep learning and machine learning techniques. Advanced neural networks like CNNs and LSTMs have enhanced efficiency and precision in EEG classification [34,35]. One of the main innovations of our proposed EEG-based control architecture is the integration of a neural short-term memory (LSTM) network to decode brain activity signals in real time. As LSTMs possess innate capabilities to model temporal sequences and learn long-range contextual patterns, they are ideally suited to handle the dynamic and non-linear relationships of EEG data streams.

Once trained, the LSTM model is integrated into our architecture for classifying EEG segments in real time and mapping predictions to wheelchair commands. As users generate distinctive brain patterns via motor imagery, the LSTM classifier assigns probability scores for each control label. On passing preset confidence thresholds, the categorized intents are programmed to trigger corresponding wheelchair movements (e.g., turning left/right, forward/back). This allows intuitive, adaptive wheelchair navigation based solely on decoded brain activity. Moreover, the adaptation of deep transfer networks has shown advantages over traditional methods [36], while feature selection based on minimum entropy has improved performance [37]. The optimization of deep learning models using evolutionary algorithms has increased energy efficiency [34]. Finally, the implementation of simplified models, such as a version of GoogLeNet, has been effective in EEG signal classification [38], highlighting the advancement and practical application of these technologies in BCIs.

Next, we propose a list of possible labels that the LSTM network could send and interpret in ROS to be operational.

WCL, WCR, WCB, and WCF, followed by a value between 0 and 50. The string corresponds to the acronym for Wheelchair Left (WCL), Wheelchair Right (WCR), and so on with backward and forward.

Following the same mechanism, we can do the same with the robot, assigning the letter R for Robot and J to determine the axis that moves, plus a value from 0 to 360 degrees to determine the movement.

#### 4.3.3. LSTM Description

LSTM networks, a subclass of recurrent neural networks (Figure 14), are pivotal in our project for their exceptional ability to process and remember information over extended periods, making them ideal for handling the sequential and temporal nature of EEG signals. Unlike traditional neural networks, LSTMs are designed to avoid the long-term dependency problem, enabling them to remember inputs for long durations with their unique architecture comprising three gates: input, output, and forget gates [39].

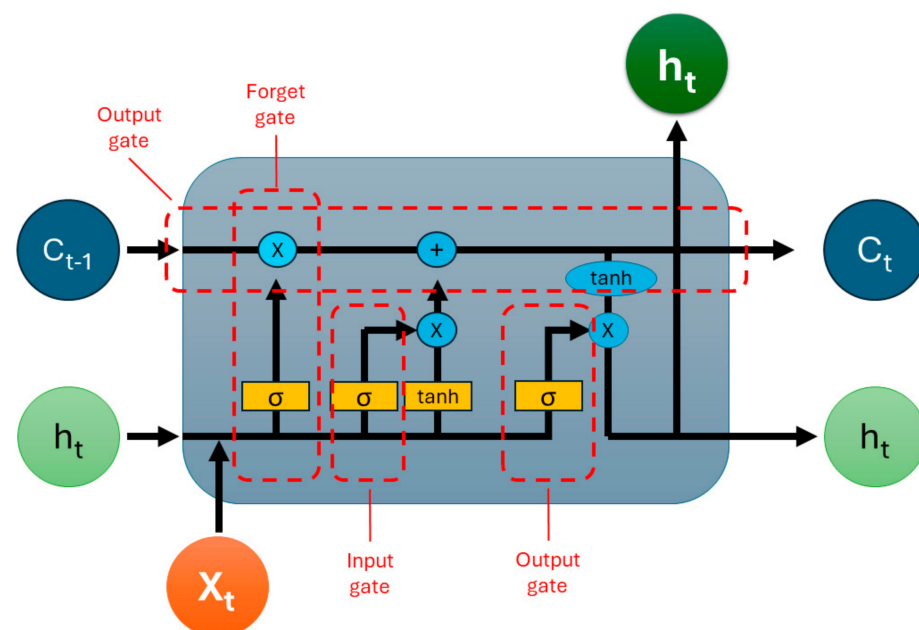


Figure 14. LSTM diagram.

Figure 14 shows the structure of a cell unit in the LSTM network. The input gate controls the extent to which a new value flows into the cell, the forget gate regulates the retention of previous information, and the output gate determines the value to be outputted based on input and the memory of the cell. This gating mechanism allows LSTMs to make precise decisions about retaining or discarding information, making them highly effective for tasks requiring the understanding of context over time, such as EEG signal analysis in our BCI project.

In the context of our work, LSTMs are employed to analyse EEG signals for pattern recognition and classification, which is crucial for translating neural activity into commands for assistive technologies. The ability of LSTMs to learn from the temporal sequence of EEG data, recognizing patterns associated with specific neural activities or intentions, underpins the system's capability to provide accurate and responsive control to the end users. This makes LSTM networks an integral component of our project, bridging the gap between raw EEG signals and actionable outputs in assistive devices, thereby enhancing the interaction between humans and machines in a seamless, intuitive manner. Their integration within our BCI framework not only exemplifies the cutting-edge neural processing technologies but also solidifies the foundation for future advancements in the field [40].

#### 4.3.4. ROS

ROS is a versatile framework like an operating system for robotics, offering hardware abstraction, device control, functionality implementation, inter-process communication,

and package management. Its modularity is essential, allowing robots to be created with reusable software components. ROS 2 further advances robotics by focusing on intelligent systems and compatibility with modern technologies.

Integration with hardware such as Arduino is simplified by *rosserial*, which combines the hardware control of Arduino with the high-level functions of ROS. The programming of nodes in ROS, which communicate to perform computations, is vital and emphasizes publish/subscribe mechanisms, services, and actions for robust robotic systems. The ROS environment favours AI algorithms for advanced automation and intelligent robotics. The use of a Jetson Nano for AI, together with an Arduino with TMC controllers, exemplifies the merging of AI with precise motor control for autonomous robots. This innovative integration of ROS, Arduino, and AI is fundamental to the advancement of intelligent robotics [41].

#### 4.3.5. ROS Nodes on Jetson Nano

Next, in Table 6, we outline the necessary implementation in ROS, focusing on nodes, topics, and basic functions for controlling the robotic arm and wheelchair.

**Table 6.** ROS nodes and topics.

Component	Function	ROS Nodes	Topics	Additional Notes
EEG Signal Processing Node				
Neural Network Node	Interprets EEG signals using LSTM/RNN to generate commands	<code>neural_network_controller</code>	<code>/eeg/commands</code> , <code>/control/commands</code>	Utilizes Deep Learning frameworks such as TensorFlow (V2.13) or PyTorch (2.2.1)
Motor Control Node	Processes commands to control robotic arm motors	<code>motor_control</code>	<code>/motor/commands</code>	Requires knowledge of motor control
Servo Control Node	Controls servos for precise movements	<code>servo_control</code>	<code>/servo/commands</code>	Servo control algorithms necessary
Communication with Arduino	Manages communication between ROS and Arduino Mega	<code>arduino_communicator</code>	<code>/arduino/commands</code> , <code>/arduino/responses</code>	<i>rosserial</i> package can be used for communication
Sensor Data Processing	Processes sensor data in robotic arm and wheelchair	<code>sensor_data_processor</code>	<code>/sensors/raw_data</code> , <code>/sensors/processed_data</code>	Sensor data processing for feedback and safety
Robotic Arm Control	Coordinates movements of the robotic arm based on commands	<code>arm_movement_coordinator</code>	<code>/arm/commands</code> , <code>/arm/status</code>	Integration with <i>moveit</i> or similar packages
Wheelchair Navigation	Manages autonomous navigation of the wheelchair	<code>wheelchair_navigator</code>	<code>/navigation/commands</code> , <code>/navigation/status</code>	Includes route planning and obstacle avoidance algorithms

These components and configurations form a comprehensive guide to implementing the system on the Jetson Nano, utilizing ROS for EEG signal processing, control of the robotic arm, and wheelchair navigation [42].

Controlling an electric wheelchair involves using a propulsion and steering system, which can be controlled via electrical signals. In the context of ROS, a node could be developed that subscribes to a specific topic where LSTM network labels are published. This node would interpret the received labels and generate the appropriate control signals for the GPIO terminals that control the wheelchair. The detailed implementation of this node will depend on the specific configuration of the wheelchair and how it is electrically controlled. For example, if the wheelchair uses DC (Direct Current) motors for propulsion, the node will need to generate the appropriate PWM (Pulse Width Modulation) signals to control the speed and direction of the motors. If the wheelchair uses a joystick for control, the node will need to map the LSTM network labels to joystick movements and generate the corresponding electrical signals.

#### 4.3.6. Coding Orders

The development of an advanced robotic application that integrates EEG data capture, interpretation, and prediction using AI on a Jetson Nano platform, using ROS to control a motorized wheelchair in conjunction with a six-degrees-of-freedom cobot and an Arduino Mega as a microcontroller, is a complex process involving multiple stages and components.

The final architecture, which meets all the requirements defined in this research, is shown in Table 7. This table relates the selected physical components with the input and output signals between the devices and the necessary software for their implementation.

**Table 7.** Hardware/signals/software relationship.

Component	Hardware	Input Signals	Output Signals	Software
EEG Headsets (Neurosky, Brainlink)	Neurosky, Brainlink headsets	User's EEG signals	Delta to Gamma EEG signals	Signal processing software
Prefrontal EEG Signal	EEG electrodes in headsets	Delta to Gamma EEG signals	Processed EEG signals for interpretation	Signal classification algorithms
Neural Network (Jetson Nano)	Jetson Nano	Processed EEG signals	Control commands for robotic arm/wheelchair	Deep Learning frameworks (e.g., TensorFlow (V2.13), PyTorch (2.2.1)), LSTM/RNN
ROS Nodes on Jetson Nano	Jetson Nano	Commands from Neural Network	Control signals to Arduino	ROS, roserial, moveit, navigation stack
Arduino Mega	Arduino Mega controller	Commands from ROS Nodes	Motion commands to robotic arm	Firmware for motor control and feedback
Robotic Arm	Motors, sensors, actuators	Motion commands from Arduino	Movement actions	Control algorithms for robotic arm
Autonomous Wheelchair	Motors, control systems	Navigation commands from ROS	Movement actions	Wheelchair control and navigation systems

Having identified both the functional and technical requirements, as well as the necessary hardware and software devices to meet the requirements and define the proposed architecture in detail, we will proceed to elaborate on each part. To make sense of this definition of methods and methodology, we will follow the timeline of the process and, thus, the data flow.

In summary, this proposed architecture integrates cutting-edge technologies in BCIs, machine learning, robotics, and hardware control to create a solution that can significantly improve the quality of life for patients with neurodegenerative diseases. The key to the success of this project lies in the effective integration of these technologies and in the thorough validation of their functionality and safety, in addition to a substantial cost reduction, focusing on the use of low-cost and/or open-source devices, democratizing this technology.

## 5. Results

In this section, we present a theoretical examination of the proposed method in comparison with established baselines. It is imperative to note that the scope of this study encompasses theoretical analyses, eschewing empirical evaluations of the proposed system. Such empirical assessments are earmarked for subsequent investigations. This delineation ensures a clear understanding of our current findings, which are intended to illustrate potential improvements and theoretical advancements over existing frameworks. Our aim is to lay a robust groundwork for future empirical studies, thereby contributing both to the academic discourse and to practical applications in the field.

### 5.1. Comparison with Other Works

After a comparison of the proposed architecture with nine similar developments, in which both the objectives and the way the research was carried out were evaluated, the results are conclusive, especially in the achievement of the technical requirements.

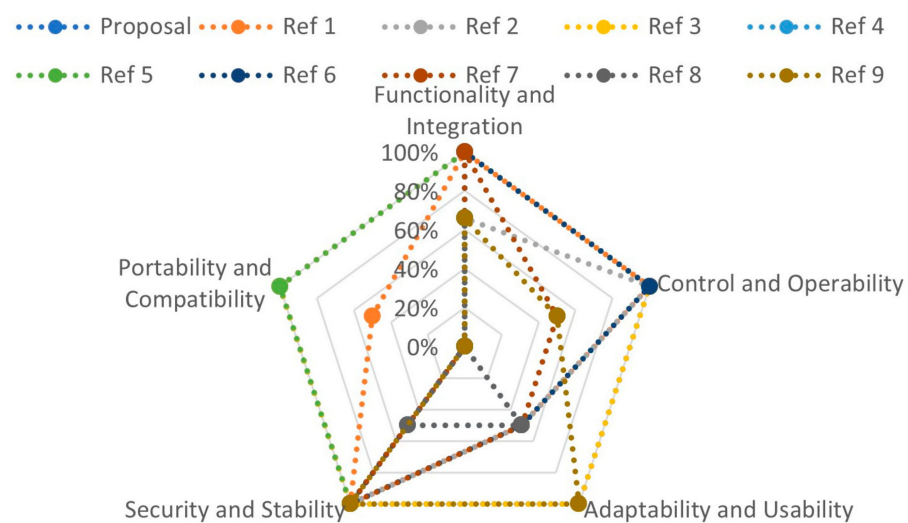
These works were selected after a search of references in Scopus and Google Scholar, where a search was filtered by terms related to this research. The combination of the keywords "EEG", "ML", "ROS", and "wheelchair" has resulted in the following research

that has been used to compare our research with research that is very close in concept and format.

- Ref 1.—SSVEP-Based BCI Wheelchair Control System [43].
- Ref 2.—Brain-Computer Interface Controlled Robotic Gait Orthosis [44].
- Ref 3.—Wheelchair Automation by a Hybrid BCI System Using SSVEP and Eye Blinks [45].
- Ref 4.—EEG-Based BCIs: A Survey [46].
- Ref 5.—EEG Wheelchair for People of Determination [47].
- Ref 6.—BCI-Controlled Hands-Free Wheelchair Navigation with Obstacle Avoidance [48].
- Ref 7.—A Literature Review on the Smart Wheelchair Systems [49].
- Ref 8.—A Real-Time Control Approach for Unmanned Aerial Vehicles Using Brain-Computer Interface [50].
- Ref 9.—Real-Time Brain Machine Interaction via Social Robot Gesture Control [51].

The spider chart provided in Figure 15 presents a comparison of functional requirements across a proposed solution and eight references. Notably, both the proposal and reference 3 exhibit remarkable alignment across all the metrics, suggesting a close or identical prioritization of functional aspects. These encompass functionality and integration, control and operability, adaptability and usability, as well as security and stability, and finally, portability and compatibility. In these domains, the proposal and reference 3 reach parallel scores, implying that they may share similar design philosophies or operational objectives.

## FUNCTIONAL REQUIREMENTS



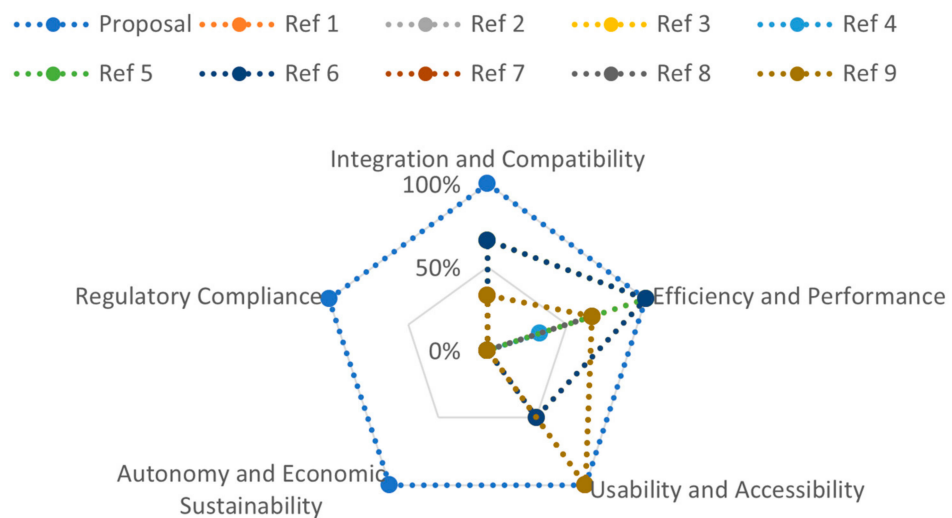
**Figure 15.** Functional requirements compliance diagram. Ref 1.—SSVEP-Based BCI Wheelchair Control System [42]; Ref 2.—Brain-Computer Interface Controlled Robotic Gait Orthosis [43]. Ref 3.—Wheelchair Automation by a Hybrid BCI System Using SSVEP and Eye Blinks [44]. Ref 4.—EEG-Based BCIs: A Survey [45]. Ref 5.—EEG Wheelchair for People of Determination [46]. Ref 6.—BCI-Controlled Hands-Free Wheelchair Navigation with Obstacle Avoidance [47]. Ref 7.—A Literature Review on the Smart Wheelchair Systems [48]. Ref 8.—A Real-Time Control Approach for Unmanned Aerial Vehicles Using Brain-Computer Interface [49]. Ref 9.—Real-Time Brain Machine Interaction via Social Robot Gesture Control [50].

Contrastingly, the other references display varied degrees of divergence from the proposed solution, with each reference presenting a unique profile of strengths and weaknesses. This diversity in scoring indicates differing emphases on the functional requirements, which may stem from alternative strategic focuses or target user needs. Such

discrepancies underscore the necessity for a thorough analysis when benchmarking against multiple frameworks to ensure that the chosen reference aligns with the specific goals and constraints of the project at hand.

In Figure 16, the spider chart delineates a comparative assessment of technical requirements for a proposal against a suite of references. It becomes apparent that the proposal is particularly strong in regulatory compliance, suggesting a conscientious alignment with relevant laws and standards. However, in other technical domains, such as efficiency and performance, usability and accessibility, and autonomy and economic sustainability, the proposal does not reach the benchmark set by some references. This is indicative of a potential trade-off that has been made in favour of compliance over other technical merits.

## TECHNICAL REQUIREMENTS



**Figure 16.** Technical requirements compliance diagram. Ref 1.—SSVEP-Based BCI Wheelchair Control System [42]; Ref 2.—Brain-Computer Interface Controlled Robotic Gait Orthosis [43]. Ref 3.—Wheelchair Automation by a Hybrid BCI System Using SSVEP and Eye Blinks [44]. Ref 4.—EEG-Based BCIs: A Survey [45]. Ref 5.—EEG Wheelchair for People of Determination [46]. Ref 6.—BCI-Controlled Hands-Free Wheelchair Navigation with Obstacle Avoidance [47]. Ref 7.—A Literature Review on the Smart Wheelchair Systems [48]. Ref 8.—A Real-Time Control Approach for Unmanned Aerial Vehicles Using Brain-Computer Interface [49]. Ref 9.—Real-Time Brain Machine Interaction via Social Robot Gesture Control [50].

Differences among the references themselves are also noticeable, with some excelling in areas where others are less capable. Reference 7, for example, shows substantial scores in integration and compatibility, indicating a focus on harmonious system incorporation. In contrast, other references, such as Ref 1 and Ref 9, seem to prioritize efficiency and performance more highly. These variances highlight the diversity of technical strategies and priorities that exist within the field and the importance of carefully selecting a reference that aligns with the specific technical aspirations of a project.

As can be seen in Tables 8 and 9, as well as in the diagrams in Figures 15 and 16, for the functional requirements part, some of the papers. Specifically, the one referenced with n° 3 could be considered to meet the parameters proposed by our architecture, but on the contrary, this same paper, Ref. 3, is substantially far from the technical objectives; therefore, we can consider that in none of the cases compared, the specifications and requirements that our architecture proposes as a solution are met.

Table 8. Comparative table of functional requirements.

Functional Requirements	Proposal	Ref 1	Ref 2	Ref 3	Ref 4	Ref 5	Ref 6	Ref 7	Ref 8	Ref 9
FR 1	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
FR 2	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
FR 7	✓	✓	×	✓	×	✓	✓	✓	×	×
	100%	100%	66%	100%	66%	100%	100%	100	66%	66%
FR 3	✓	✓	✓	✓	×	✓	✓	?	×	?
FR 6	✓	✓	✓	✓	×	✓	✓	✓	×	×
	100%	100%	100%	100%	0%	100%	100%	50%	0%	50%
FR 5	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
FR 11	✓	×	×	✓	×	×	×	×	×	✓
	100%	50%	50%	100%	50%	50%	50%	50%	50%	100%
FR 4	✓	✓	✓	✓	×	✓	✓	✓	×	✓
FR 9	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	100%	100%	100%	100%	50%	100%	100%	100%	50%	100%
FR 8	✓	×	×	✓	×	✓	×	×	×	×
FR 10	✓	✓	×	✓	×	✓	×	×	×	×
	100%	50%	0%	100%	0%	100%	0%	0%	0%	0%
% Total	100%	82%	64%	100%	36%	91%	73%	64%	36%	55%

Table 9. Comparative table of technical requirements.

Technical Requirements	Proposal	Ref 1	Ref 2	Ref 3	Ref 4	Ref 5	Ref 6	Ref 7	Ref 8	Ref 9
TR 1	✓	✓	?	✓	×	✓	✓	✓	×	✓
TR 7	✓	✓	×	✓	×	✓	✓	?	×	×
TR 9	✓	×	×	×	×	×	×	×	×	×
	100%	66%	0%	66%	0%	66%	66%	33%	0%	33%
TR 2	✓	✓	✓	✓	×	✓	✓	✓	✓	✓
TR 3	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
TR 4	✓	✓	?	✓	×	✓	✓	?	×	×
	100%	100%	66%	100%	33%	100%	100%	66%	66%	66%
TR 5	✓	?	×	✓	×	?	✓	✓	×	✓
TR 6	✓	×	×	?	×	×	×	✓	×	✓
	100%	0%	0%	50%	0%	0%	50%	100%	0%	100%
TR 8	✓	×	×	×	×	×	×	×	×	×
TR 10	✓	×	×	×	×	×	×	×	×	×
	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%
TR 11	✓	×	×	×	×	×	×	×	×	×
	100%	0%	0%	0%	0%	0%	0%	0%	0%	0%
% Total	100%	45%	19%	55%	9%	45%	55%	45%	19%	45%

## 5.2. Analysis of the Requirement Fulfillment

Our architecture meets all the functional and technical requirements detailed in Tables 1 and 2 of this publication, as shown in the checklists of Tables 8 and 9. Table 10 shows the degree of compliance with the functional requirements and the justification for compliance.

Appendix B details the result on the Fulfilment of Functional and Technical Requirements with Other Works.

Appendix C details each of the requirements and their degree of compliance in relation to the functional issues.

Next, in Table 11, we will verify that compliance with the technical requirements is also achieved according to the proposed architecture.

Appendix D details each of these requirements and their degree of compliance in relation to technical issues.

**Table 10.** Functional requirements compliance tables.

Functional Requirement	Achieved	Justification
EEG signal capture	Yes	Neurosky and Brainlink EEG headbands
Real-time interpretation of EEG signals	Yes	Signal processing algorithms, embedded in Jetson Nano and associated with ROS module execution
Intuitive control of the robotic arm and wheelchair	Yes	Classification by IM (Motor Imagery) and/or P300
Safety and stability in movement	Yes	Control systems and safety sensors in the prototype
Adaptability to different users	Yes	Machine learning algorithms that adapt to each user, supported by ROS
Control of the wheelchair's movements	Yes	Rational control of movements
Portability and low weight (<100 g)	Yes	Commercial headbands with weights less than 100 g
EEG/ECG signal quality analysis	Yes	The selected headbands provide and monitor this quality signal value
Commercial wireless headbands	Yes	Bluetooth connection
Integration of the robot in commercial chairs	Yes	Possibility of modifying the robot's base support as it is an open-source model with Creative Commons SLTs
Preset routines in the actions of the robot and robot + chair	Yes	Implementation of preset movements in ROS nodes

**Table 11.** Technical requirements compliance tables.

Technical Requirement	Achieved	Justification
Effective integration of BCI with wheelchair + robot	Yes	The ROS module allows this integration
Efficient EEG data processing ( $t = 1$ s)	Yes	Processing times on Jetson Nano with ROS (Benchmark comparison)
Real-time interpretation of EEG signals	Yes	The use of the open-source ROS module provides robustness for wheelchair and robot control
Robust control system for robotic arm and wheelchair	Yes	Graphical interface and usability tests in the field
Accessible and user-friendly interface	Yes	Integrated feedback system in the Jetson Nano control device, with ROS nodes
Feedback system for the user	Yes	Testing with various commercial models
Integration with commercial motorized wheelchairs	Yes	Mechanical and electrical integration
Usage autonomy ( $\geq 3$ h)	Yes	Calculation of predicted consumption values
Support for multi-platform headbands: Windows, Apple, Linux, Android.	Yes	Multi-platform headbands with Windows, Linux, iOS, and Android connectivity
Low integration cost (<EUR 1500)	Yes	Cost estimation less than EUR 1500.
Compliance with applicable regulations	Yes	Compliance with the regulations applicable to these devices according to the current applicable standard

### 5.3. Economic Viability of the Proposed Architecture

An economic and financial analysis was carried out, considering a scenario of device sales, with the results shown in the following figures and tables.

Figures 17 and 18 shows the result of costs with the two options evaluated.

NPV, IRR, and ROI results for the sales scenario with an initial investment of EUR 6000, necessary for the first year of activity, assuming a rate of return of 10%.

In Table 12, you can see the results of the analysis during the first 5 years, which are fundamental for the survival of the business model.




Figure 17. Cost of production scenario.





Figure 18. Selling scenario (5 years).

Table 12. Financial results.

Results	Data
NPV	EUR 2448.22
IRR	19.49%
ROI	210.75%

Figure 19 shows the evolution of annual cash flow for each of the 5 years with the updated initial investment of EUR 6.000.

The annual cash flow reflects the net after subtracting variable costs from the revenue generated by unit sales each year. The initial investment is shown in Year 0 as a negative cash flow, and then a progressive increase in annual cash flow is observed as sales increase.



**Figure 19.** Annual cash flow (5 years).

Moving beyond numbers, the intangible benefits of BCI technology are equally compelling. The independence it affords to individuals with physical disabilities is immeasurable, enhancing their quality of life and autonomy. A BCI system provides constant support, promoting self-reliance and emotional well-being, an advantage that cannot be matched by human assistants. Although the upfront cost is substantial, potential grants and funding opportunities can alleviate this financial challenge. In sum, the long-term economic and emotional gains from a BCI system make a strong case for its adoption, transcending mere financial metrics and profoundly impacting users' lives.

#### 5.4. Legal and Technical Viability

To assess the legal and technical viability of a BCI project with applications in robotics and assisted mobility, it is essential to carefully consider the following aspects.

- **Intellectual Property Protection:**

Patentability of the development is not anticipated, nor is any other type of intellectual property protection at the moment. After reviewing existing patents, no similar models have been found, thus avoiding potential litigation for intellectual property infringement.

The possible patents and/or utility models have been reviewed in the European Patent Office (EPO) and specifically in PATENTSCOPE—Worldwide Inventions within the alternatives of web patent search engines with the following search parameters [52,53]:

1. Search 1: "Assistive cobot in an electric wheelchair"; 0 results.
2. Search 2: "Assistive cobot in a motorised wheelchair"; 0 results.
3. Search 3: "Motorised wheelchair with integrated robot"; 33 results, nonsimilar.

Figures 20–22 show the result of the search of the patents found in the PATENTSCOPE browser.

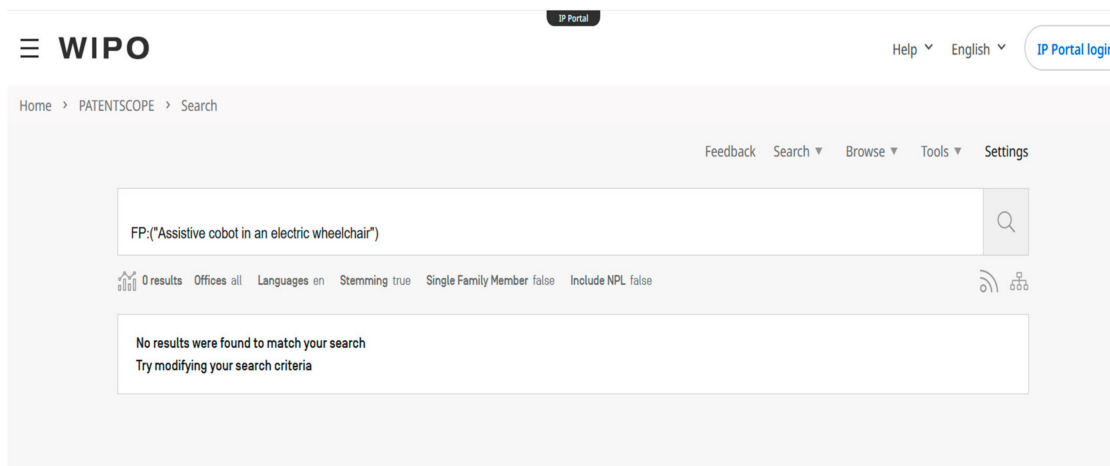


Figure 20. Results of the 1st search on Patentscope.

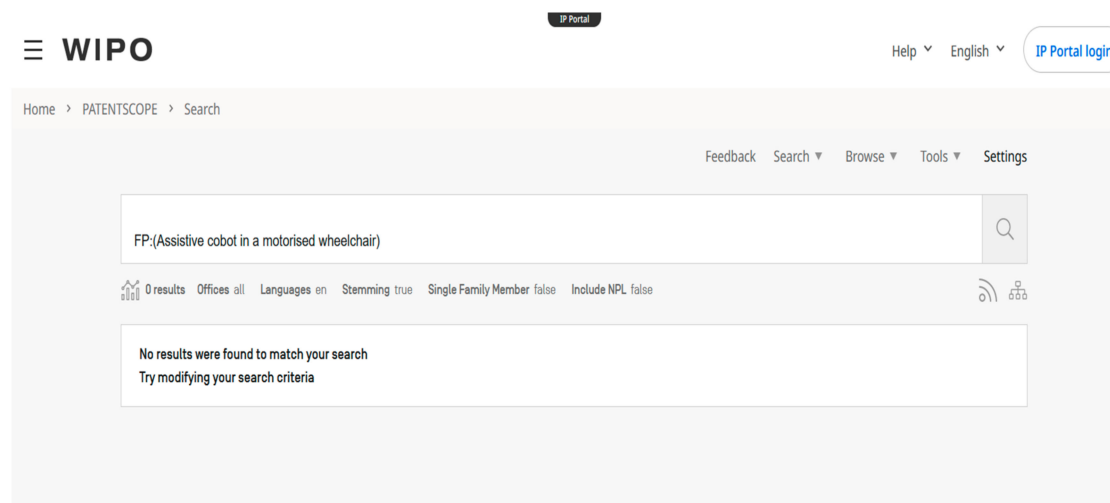


Figure 21. Results of the 2nd search on Patentscope.

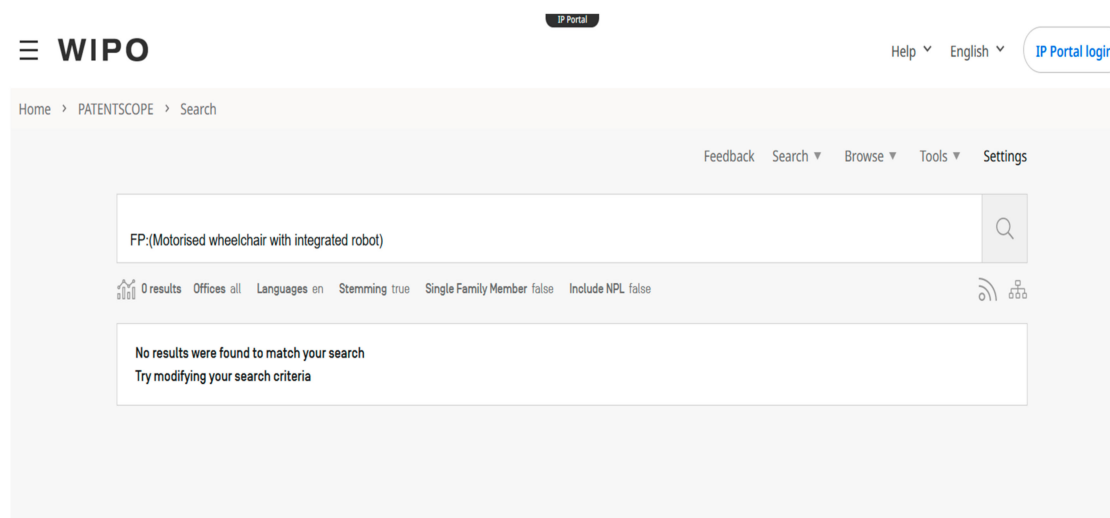


Figure 22. Results of the 3rd search on Patentscope.

## 6. Discussion

The use of low-cost commercial EEG headbands like Neurosky or Brainlink represents a significant advancement in the accessibility of BCI technology. These devices, although

limited in terms of the number of electrodes and precision compared to more advanced EEG systems, offer a viable solution for applications where portability and cost are critical factors. The ability of these headbands to capture a range of brain signals, including Delta, Theta, Alpha, Beta, and Gamma waves, as well as attention and meditation metrics, makes them suitable for a variety of BCI applications, from device control to monitoring mental well-being.

Real-time preprocessing and classification of EEG signals are fundamental to the effectiveness of BCI systems. Techniques such as normalization, Fourier transformation, and wavelet transformation are essential for filtering noise and extracting significant features from EEG signals. These methods allow for more accurate and efficient classification, crucial for real-time applications like the control of motorized wheelchairs and cobots. Research in this field has demonstrated various strategies to improve accuracy and processing speed, vital for the practical implementation of these technologies.

The integration of systems such as Arduino Mega and Jetson Nano in BCI applications presents unique opportunities for device control. Arduino Mega, with its ability to handle multiple inputs and outputs, is ideal for controlling the mechanical aspects of wheelchairs and cobots. On the other hand, Jetson Nano, with its powerful data processing and machine learning capabilities, is suitable for real-time analysis of EEG signals. This combination of hardware allows for a smooth and efficient interaction between the user and the device, opening new possibilities in assistance for people with disabilities and automation.

In summary, research in the field of brain-computer interfaces using low-cost EEG headbands and their integration with control systems like Arduino and Jetson Nano shows great potential. Although there are limitations in terms of precision and processing capacity, advances in signal processing and classification techniques are opening new avenues for practical and accessible applications in this field.

## 7. Conclusions and Futures Work Lines

Research in the field of BCIs using low-cost EEG headbands, such as Neurosky or Brainlink, focused on reading brain signals from the prefrontal area, has proven to be promising for a variety of practical applications. These devices, accessible, portable, and non-invasive, offer a viable solution for capturing brain signals, including a range of brain waves and attention and meditation metrics, calculated thanks to their own algorithm. Despite their limitations compared to more advanced EEG systems, these headbands are sufficient for many BCI applications, especially in contexts where portability, ease of use, and cost are critical considerations.

Real-time preprocessing and classification of EEG signals are crucial aspects of the effectiveness of BCI systems. Brain signal processing techniques, such as normalization, Fourier transformation, and wavelet transformation, play an essential role in improving the accuracy and efficiency of classification. These methods extract significant features from EEG signals, which is fundamental for real-time applications, considering that the filtering stage is carried out in the EEG headband itself thanks to its TGAM device. Research in this field has provided valuable insights on how to improve the speed and accuracy of signal processing, which is vital for the practical implementation of BCI technologies.

The integration of systems like Arduino Mega and Jetson Nano in BCI applications has opened new possibilities for device control. While Arduino Mega is ideal for handling the mechanical aspects of devices like motorized wheelchairs and cobots, Jetson Nano, with its data processing and machine learning capabilities, is suitable for real-time analysis of EEG signals and management of the control environment through ROS and ROS-Neuro. This combination of hardware facilitates a smooth and efficient interaction between the user and the device, which is crucial for practical applications in assistance to people with disabilities and in the automation process.

Regarding the control of motorized wheelchairs, research has shown that the integration of BCI systems with proportional controls demonstrates the ability to control a

wheelchair using brain signals, opening new possibilities for people with severe motor disabilities and offering greater independence and quality of life.

We can affirm after this research that it is theoretically demonstrated that the use of cobots, such as the open-source model from Niryo, controlled by open-source ROS platforms (ROS-Neuro) in combination with EEG/BCI systems, represents a promising area of application. These cobots, adapted to work alongside humans, can be controlled by brain signals to perform complex tasks, which has significant implications in the industry and especially in personal assistance.

In conclusion, research in the field of brain–computer interfaces using low-cost EEG headbands and their integration with control systems like Arduino and Jetson Nano shows great potential for practical and accessible applications. These developments, as shown in this publication, not only improve the quality of life of people with neurodegenerative diseases but also offer new opportunities in automation and the control of physical devices.

While the current research has focused on mobility assistance and robotic control, future work could explore other potential applications of low-cost BCI systems. This includes areas such as mental health monitoring, neurofeedback therapy, and integration with virtual and augmented reality for various educational and entertainment purposes.

By focusing on this area, the field of brain–computer interfaces can continue to evolve, offering increasingly effective and user-friendly solutions that enhance the lives of individuals, particularly those with disabilities, and pave the way for innovative applications across various sectors.

**Author Contributions:** Conceptualization, F.R.; methodology, J.E.S. and J.M.C.; formal analysis, F.R.; research, F.R., J.E.S. and J.M.C.; data preservation, F.R.; data, F.R.; writing the original draft, F.R.; writing, revising and editing, J.E.S. and J.M.C.; visualization, J.E.S.; supervision, J.E.S. and J.M.C.; project administration, F.R. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research received no external funding.

**Statement of the Bioethics Committee:** The study has been conducted in accordance with ethical standards and, in particular, with the provisions of the Declaration of Helsinki and other applicable regulations, as well as with the provisions of the Universal Declaration on Bioethics and Human Rights (UNESCO, 2005), the General Data Protection Regulation of the European Union (Regulation 2016/679) and Organic Law 3/2018, of 5 December, on the Protection of Personal Data and Guarantee of Digital Rights and approved by the Bioethics Committee of the University of Burgos, U05100001, Burgos (Spain). Approval Code: REGAGE24s00009305342 of Date of approval: 5 February 2024.

**Informed Consent Statement:** Informed consent is available for all volunteers participating in the study.

**Data Availability Statement:** The data presented in this study are available on request from the corresponding author.

**Conflicts of Interest:** The authors declare no conflicts of interest.

## Abbreviations

The following abbreviations are used in this manuscript:

BCI	Brain–Computer Interface
hBCI	Hybrid Brain–Computer Interface
TGAM	ThinkGear ASIC Module
MI	Motor Imagery
SSVEP	Steady State Visually Evoked Potential
EEG	Electroencephalography
EMG	Electromyography
EOG	(Electrooculography)
AI	Artificial Intelligence
CNNs	Convolutional Neural Networks
RNNs	Recurrent Neural Networks

LSTM	Long Short-Term Memory
PID	Proportional–Integral–Derivative
GPUs	Graphics Processing Units
GPIO	General Purpose In and Out
STL	Standard Triangle Language
ISO	Internacional Organization for Standardization

## Appendix A. Functional and Technical Requirements

In this appendix, you can find the details and additional data associated with the description of the functional and technical requirements identified in the proposed architecture and their corresponding justification.

### Appendix A.1. Functional Requirements

- EEG signal capture

Using high-quality EEG headsets ensures a frustration-free experience where the user's intentions are correctly translated into actions. This is crucial in terms of ergonomics, as it reduces the need for extra effort or repeated attempts to perform a task, improving user comfort and efficiency. In addition, specialized and comfortable hardware minimizes discomfort during prolonged use, which is especially important for users with disabilities who may have additional sensitivities or limitations in mobility.

- Real-time interpretation of EEG signals

Real-time interpretation of EEG signals is vital for a smooth and responsive user experience. By minimizing latency in the system's response, users feel they have immediate and natural control, similar to habitual body movements. This not only increases user confidence in the system but also enhances intuitive interaction, reducing cognitive load and improving system ergonomics. Powerful hardware and advanced software enable this rapid interpretation to make the system more user-friendly and accessible, even for users with limited technological skills.

- Intuitive control of the robotic arm and wheelchair

Intuitive control of the robotic arm and wheelchair is essential for users with limitations to be able to operate the system independently and with confidence. A simplified user interface, designed with ergonomics in mind, facilitates adaptation and learning of the system, making it accessible even for users with little experience in technology. Integration with commercial motorized wheelchair joysticks offers a familiar control option, which can significantly improve comfort and reduce the stress of learning a new system.

- Safety and stability of movement

Safety and stability in movement are critical aspects for the user's peace of mind and confidence. Implementing control systems and safety sensors, such as LiDAR, provides an additional layer of protection, ensuring that the environment is safe to operate in. This preventive approach is essential to avoid accidents, which is of utmost importance for users who may have limited mobility or reduced capacity to react to dangerous situations. The ergonomics of the safety design ensures that users can enjoy an experience without fear of injury or damage.

- Adaptability to Different Users

The adaptability to different users ensures that the system is inclusive and effective for a wide range of needs and preferences. The system must be usable by patients with neurodegenerative diseases, reduced mobility, individuals who have suffered spinal cord injuries, and even those in postoperative stages. This adaptability will be achieved through machine learning algorithms that adjust to the individual characteristics of each user, allowing for personalization of the system and enhancing the experience and ergonomics. This means that the system is not only easier to use but also adapts to the specific ergonomic

needs of each individual, resulting in a more comfortable and effective experience. Precise and personalized adaptation is key to ensuring that all users, regardless of their abilities or limitations, can interact with the system effectively and comfortably.

- Control of the Wheelchair's Movements

The chair must perform at least the four basic movements necessary to consider the preset movements in the four basic directions and combinations of these basic movements. These directions can be associated with specific values of the Alpha signal, as seen in the study, where controlled variations of the Alpha signal allow a user to select the direction they wish to move. In our case, the selection of the wheelchair's movement takes as a reference more than one signal, even the values of attention and meditation resulting from the calculation algorithm performed by the headband itself [12].

- Integration of the System with Commercial Chairs

The system must be able to integrate with commercial chairs, allowing future users to adapt the motorized chair they have. The adaptation must be possible regardless of the brand and model of the chair, always seeking maximum compatibility with the existing chairs and control forms in the market.

- Portability and Low Weight (<100 g)

A necessary condition to improve the usability of the system. The headband or headbands must be light enough and comfortable for the user to sustain continuous use for at least 3 h, as indicated in the subsequent technical requirements. The maximum bearable weight has been set at 100 g, in line with the weights observed in other wearables with approximate values of 100 g as the maximum weight.

- EEG/ECG Signal Quality Analysis

To verify the correct functioning of the device, the headband must have its own signal that analyzes the quality of the signal. This way, it can even determine if the user is wearing the headband or not. This value will determine that the system is in use and will avoid unwanted signals and, therefore, unwanted or involuntary movements. This creates an extra layer of safety.

- Commercial Wireless Headbands

Maintaining the same philosophy in usage ergonomics, it is proposed to use commercial devices that send the collected data of brain activity wirelessly, facilitating their portability and interconnection with other devices without the need for cables that hinder the user experience.

- Preset Routines in the Actions of the Robot and Robot + Chair

Given the anticipated need for repeated actions over time, which we might consider typical actions, it becomes necessary to predefine certain types of actions that facilitate the control and adaptation of the user to the new tool.

#### *Appendix A.2. Technical Requirements*

- Effective Integration of BCI with Chair + Robot

The effective integration of BCIs with wheelchair and robotic arm systems is crucial for smooth and accurate communication between the user and the device. This is achieved through standard communication protocols such as Bluetooth or Wi-Fi for wireless communication and serial communication for bidirectional communication between control boards, adapting to the latency and range requirements of each device. Software compatibility is also essential and might involve the use of open APIs (Application Programming Interfaces) or middleware software that allows the integration of various devices and platforms. For instance, the use of ROS is ideal for the integration of different hardware and software modules, providing a flexible and scalable platform for robotic device control.

- Efficient EEG Data Processing ( $t \leq 1$  s)

To minimize latency and maximize accuracy in EEG data processing, it is crucial to have optimized hardware. Platforms like NVIDIA Jetson or Raspberry Pi equipped with powerful processors and GPUs (Graphics Processing Units) may be suitable for this purpose. These devices can run complex signal processing and machine learning algorithms, such as CNNs, in real time. Optimizing power consumption is also a crucial aspect, which can be achieved through efficient programming techniques and the selection of low-power components.

- Real-time Interpretation of EEG Signals

For effective real-time interpretation, high-performance processors, and GPUs capable of executing sophisticated algorithms, like CNNs, which can rapidly identify patterns in EEG data, are used. An example of this could be the use of platforms like NVIDIA Jetson, offering AI processing capabilities in compact, energy-efficient devices. Additionally, selecting appropriate algorithms is crucial; for instance, real-time machine learning algorithms must be optimized to ensure there are no significant delays in signal interpretation.

A significant technical challenge is to minimize noise and interference in the EEG signal, which can be achieved through digital filtering techniques and signal amplification. System calibration for each user is also essential, involving adjusting the algorithms to synchronize correctly with the individual brain signals of the user. This requires a machine learning process that can adapt to variations in EEG signals between different users.

In terms of software, operating systems and development frameworks that can efficiently handle real-time data input and facilitate integration with other system components, such as user interfaces and device control systems, are needed. Here, technologies like ROS can play a crucial role, providing a platform for integrating signal processing with real-time control actions.

In summary, real-time interpretation of EEG signals is an advanced technical requirement that combines specialized hardware, sophisticated algorithms, and integrated software design. Its success depends on the accuracy, speed, and adaptability of the system, factors that are essential for providing a smooth and effective user experience, especially for those who rely on these technologies to interact with the world around them.

- Robust Control System for Robotic Arm and Wheelchair

To ensure precise and safe movements, a robust control system comprising advanced algorithms and reliable hardware components is required. Predictive control algorithms, such as PID (Proportional–Integral–Derivative) controllers, can be used for finely tuning the movements of the robotic arm and wheelchair. Moreover, implementing predefined trajectories for common operations can simplify user interaction and enhance system efficiency. Regarding hardware, high-precision stepper motors and sensors like gyroscopes and accelerometers can be used to improve the precision and stability of movement.

- Accessible and User-Friendly Interface

Developing an accessible and user-friendly interface is crucial for the user experience. This could involve using advanced graphical interface technologies and comprehensive usability testing. The interfaces should be intuitive and tailored to the user's needs, possibly incorporating elements of universal design to ensure accessibility. For example, the use of large icons and contrasting colours can aid users with limited vision. Additionally, implementing tactile or auditory feedback can enhance interaction for users with different capabilities, providing a valuable UX (User Experience) measure to adjust the overall functioning of the system.

- User Feedback System

An effective feedback system is essential for keeping the user informed about the system's status. This can be achieved through visual or auditory feedback devices, such

as LCD screens or speakers. The information provided should be clear and easily understandable, using visual or auditory indicators to alert about the system status or potential errors. This improves the user experience and contributes to the safety and efficiency of the system.

- **Integration with Commercial Motorized Wheelchairs**

Compatibility with existing motorized wheelchair systems is an important aspect of ensuring the broad applicability of the system. This may include the development of adapters and interface software that allow integration with commercial joysticks. Mechanical and electrical integration of the system must also be considered.

- **Usage Autonomy ( $\geq 3$  h)**

One of the key points in terms of the system's usability is its energy aspect; hence, a minimum target usage time of 3 h has been set as the energy threshold for the system to be viable, both for the headband and the wheelchair, which will be the limiting aspects of the system.

- **Multi-platform Headband Support, Windows, Apple, Linux, Android**

Connectivity between systems must be ensured, given the need for integration of different elements with various architectures and connectivity modes. We must have multi-platform systems. In our case, we focus on the EEG headband, as it is the key element in data collection, which is fundamental for the operation of our development. Additionally, the ability to connect headbands with mobile devices allows for extra verification in signal collection.

- **Low Integration Cost (<EUR 1500)**

The cost of the system, excluding the motorized chair, which in many cases the user already possesses for daily use, should allow for integration at a reasonable cost, understood as a cost not exceeding EUR 1500, including all necessary devices: headband, controller, and robot, as well as integration into the chair and possible modifications for this integration. In the case of needing a specific motorized chair, it will depend on the necessary needs and usage characteristics, not evaluating this part due to the numerous varieties of commercial chairs available.

- **Compliance with Applicable Regulations**

All current regulations applicable to this type of device must be complied with. As these are elements used by people, the regulations applicable must be followed, not only because of the type of device but also due to its use and target audience.

## **Appendix B. Comparative Result on the Fulfillment of Functional and Technical Requirements with Other Works**

### *Appendix B.1. Functional Requirements*

Compliance with the functional requirements is then determined for each identified reference.



Functional Requirements	Ref 1.	Ref 2.	Ref 3.	Ref 4.	Ref 5.	Ref 6.	Ref 7.	Ref 8.	Ref 9.	
FR 5 Adaptabilidad a diferentes usuarios  FR 11 Rutinas preestablecidas en las acciones del robot y robot + silla.	Adaptability and Usability	<b>Compliant:</b> Evaluated on subjects of diverse ages and races.	<b>Compliant:</b> Tested on subjects with and without disabilities.	<b>Compliant:</b> Designed to be adaptable to different users.	<b>Compliant:</b> Discusses the adaptability of BCI technologies.	<b>Compliant:</b> Designed for individuals with various paralysis conditions.	<b>Compliant:</b> Tested on human subjects with adaptability.	<b>Compliant:</b> Discusses the adaptability of BCI systems in software.	<b>Compliant:</b> Mentions the adaptability of the proposed classification method.	<b>Compliant:</b> Allows adaptation through training in imagined movement tasks.
		<b>Not applicable:</b> Pre-established routines are not mentioned.	<b>Not applicable:</b> Focused on gait control, not pre-established routines.	<b>Compliant:</b> Use of blinking for actions such as stopping.	<b>Not applicable:</b> A review study, does not address pre-established routines.	<b>Not applicable:</b> Pre-established routines are not mentioned.	<b>Not applicable:</b> Pre-established routines for the wheelchair are not mentioned.	<b>Not applicable:</b> A review study, does not specifically address pre-established routines.	<b>Not applicable:</b> Focuses on aerial vehicle control, not pre-established routines for chairs or robots.	<b>Compliant:</b> Provides specific robot feedback based on the user's imagined movement performance.
FR 4  FR 9	Security and Stability	<b>Compliant:</b> Design focused on the safe operation of the chair.	<b>Compliant:</b> System tested for safe gait control.	<b>Compliant:</b> Blinking as a stop command for safety.	<b>Not applicable:</b> A review study, does not directly address safety.	<b>Compliant:</b> Implements clear commands, including stop, for safety.	<b>Compliant:</b> Incorporates ultrasonic sensors for obstacle avoidance.	<b>Compliant:</b> Addresses the importance of autonomous navigation and assistance.	<b>Not applicable:</b> Focuses on aerial vehicles, not wheelchair safety.	<b>Compliant:</b> Provides safe interaction with a social robot.
		<b>Compliant:</b> Applies filters and classification methods to ensure signal quality.	<b>Compliant:</b> Uses prediction models to ensure signal quality.	<b>Compliant:</b> Employs noise reduction and feature extraction methods.	<b>Compliant:</b> Reviews technologies and approaches to improve signal quality.	<b>Compliant:</b> DWT for feature extraction and quality assurance.	<b>Compliant:</b> Addresses the challenge of noisy signals and their analysis.	<b>Compliant:</b> Discusses challenges in signal categorization and proposes solutions.	<b>Compliant:</b> Proposes a classification method to enhance real-time accuracy.	<b>Compliant:</b> Decodes brain waves associated with imagined body kinematics.
FR 8  FR 10	Portability and Compatibility	<b>Not applicable:</b> The weight or portability of the system is not mentioned.	<b>Not applicable:</b> Focused on gait orthoses, not portability.	<b>Compliant:</b> Design considers portability and low weight.	<b>Not applicable:</b> A review study, does not address portability.	<b>Compliant:</b> Emotiv Epoc is lightweight and portable.	<b>Not applicable:</b> The weight or portability of the BCI system is not mentioned.	<b>Not applicable:</b> A review study, does not directly address portability.	<b>Not applicable:</b> Focuses on aerial vehicle control, not BCI system portability.	<b>Not applicable:</b> Focuses on robot interaction, not BCI system portability.
		<b>Compliant:</b> Utilizes wireless EEG for signal capture.	<b>Not applicable:</b> The use of wireless headbands is not specified.	<b>Compliant:</b> Based on a wireless system to avoid cables.	<b>Not applicable:</b> A review study, does not specify wireless headbands.	<b>Compliant:</b> Emotiv Epoc is a wireless headband.	<b>Not applicable:</b> The use of commercial wireless headbands is not mentioned.	<b>Not applicable:</b> A review study, does not specify wireless headbands.	<b>Not applicable:</b> Focuses on aerial vehicle control, not wireless headbands.	<b>Not applicable:</b> Focuses on robot interaction, not the type of headband used.

This table provides a more detailed overview of how each study addresses the functional requirements established, providing a justification for compliance or non-compliance with each.

*Appendix B.2. Technical Requirements*

Detailed table including justifications for each of the technical requirements to be compared.

Technical Requirement	Ref 1.	Ref 2.	Ref 3.	Ref 4.	Ref 5.	Ref 6.	Ref 7.	Ref 8.	Ref 9.	
TR 1	Integration and Compatibility	<b>Compliant:</b> Integrates BCI with wheelchair control via SSVEP.	<b>Partial:</b> Focuses more on gait orthosis than integration with chairs.	<b>Compliant:</b> Integrates EEG signals with wheelchair control.	<b>Not applicable:</b> A review study, does not implement systems.	<b>Compliant:</b> Integrates BCI with wheelchair control.	<b>Compliant:</b> Integrates BCI with wheelchair and sensors for navigation.	<b>Compliant:</b> Analyzes the integration of BCI systems in software.	<b>Not applicable:</b> Focuses on aerial vehicles, not chairs or robots.	<b>Compliant:</b> Integrates BCI to control a social robot.
		<b>Compliant:</b> Designed to integrate with electronic wheelchairs.	<b>Not applicable:</b> Focused on gait orthoses, not wheelchairs.	<b>Compliant:</b> Prototype based on an existing wheelchair.	<b>Not applicable:</b> A review study, does not address integration with chairs.	<b>Compliant:</b> Designed to couple with commercial wheelchairs.	<b>Compliant:</b> Designed to integrate with existing wheelchairs.	<b>Partial:</b> Discusses the integration of BCI in software but does not detail compatibility with specific chairs.	<b>Not applicable:</b> Focuses on aerial vehicles.	<b>Not applicable:</b> Focuses on interaction with a social robot.
		<b>Not applicable:</b> Multi-platform support is not mentioned.	<b>Not applicable:</b> Multi-platform support is not mentioned.	<b>Not applicable:</b> Multi-platform support is not mentioned.	<b>Not applicable:</b> A review study, does not address multi-platform support.	<b>Not applicable:</b> Multi-platform support is not mentioned.	<b>Not applicable:</b> Multi-platform support is not mentioned.	<b>Not applicable:</b> A review study, does not address multi-platform support.	<b>Not applicable:</b> Focuses on aerial vehicle control.	<b>Not applicable:</b> Focuses on interaction with a robot, not on multi-platform support.
TR 2	Efficiency and Performance	<b>Compliant:</b> Integrates BCI with wheelchair control via SSVEP.	<b>Compliant:</b> Designed for real-time operation with low latency.	<b>Compliant:</b> Efficient processing for rapid commands.	<b>Not applicable:</b> A review study, does not directly address data processing.	<b>Compliant:</b> Utilizes real-time processing techniques.	<b>Compliant:</b> Enables efficient mental control with brief training.	<b>Compliant:</b> Discusses BCI technologies for efficient processing.	<b>Compliant:</b> Proposes a classification method for rapid processing.	<b>Compliant:</b> Processes EEG signals in real time for interaction.
		<b>Compliant:</b> Interprets EEG signals in real time for control.	<b>Compliant:</b> Uses EEG prediction models for real-time control.	<b>Compliant:</b> Interprets signals in real time for navigation.	<b>Compliant:</b> Discusses approaches for real-time interpretation.	<b>Compliant:</b> Interprets EEG signals in real time for wheelchair control.	<b>Compliant:</b> Real-time control of the wheelchair.	<b>Compliant:</b> Emphasizes the importance of real-time interpretation.	<b>Compliant:</b> Focus on rapid classification for real-time control.	<b>Compliant:</b> Real-time interaction with the robot.
		<b>Compliant:</b> Precise control of the chair, robotic arm not mentioned.	<b>Partial:</b> Focused on gait orthosis, not on chairs or robotic arms.	<b>Compliant:</b> Precise control of the chair, robotic arm not mentioned.	<b>Not applicable:</b> A review study, does not directly address control systems.	<b>Compliant:</b> Precise control of the chair, robotic arm not mentioned.	<b>Compliant:</b> Safe navigation system with obstacle avoidance.	<b>Partial:</b> Discusses autonomous navigation systems, not specifically robust control.	<b>Not applicable:</b> Focuses on aerial vehicle control.	<b>Not applicable:</b> Controls a social robot, not specifically a robotic arm or chair.

Technical Requirement		Ref 1.	Ref 2.	Ref 3.	Ref 4.	Ref 5.	Ref 6.	Ref 7.	Ref 8.	Ref 9.
TR 5	Usability and Accessibility	<b>Partial:</b> Mentions the use of visual stimuli, but interface details are not provided.	<b>Not applicable:</b> User interface details are not provided.	<b>Compliant:</b> Design considers ease of use with SSVEP and blinking.	<b>Not applicable:</b> A review study, does not address user interfaces.	<b>Partial:</b> Mentions control via thoughts, but interface details are not provided.	<b>Compliant:</b> Intuitive mental control of the wheelchair.	<b>Compliant:</b> Discusses adaptive intelligent interfaces for software.	<b>Not applicable:</b> Focuses on aerial vehicle control.	<b>Compliant:</b> Intuitive interaction with the robot via BCI.
TR 6		<b>Not applicable:</b> An explicit feedback system is not mentioned.	<b>Not applicable:</b> A feedback system is not detailed.	<b>Partial:</b> Blinking may provide an implicit form of feedback.	<b>Not applicable:</b> A review study, does not address feedback systems.	<b>Not applicable:</b> A feedback system is not mentioned.	<b>Not applicable:</b> An explicit feedback system is not mentioned.	<b>Compliant:</b> Addresses the importance of feedback in software.	<b>Not applicable:</b> Focuses on aerial vehicle control.	<b>Compliant:</b> Provides feedback through robot gestures and eye color changes.
TR 8	Autonomy and Economic Sustainability	<b>Not applicable:</b> System autonomy is not mentioned.	<b>Not applicable:</b> System autonomy is not mentioned.	<b>Not applicable:</b> System autonomy is not mentioned.	<b>Not applicable:</b> A review study, does not address system autonomy.	<b>Not applicable:</b> System autonomy is not mentioned.	<b>Not applicable:</b> System autonomy is not mentioned.	<b>Not applicable:</b> A review study, does not address autonomy.	<b>Not applicable:</b> Focuses on aerial vehicle control.	<b>Not applicable:</b> Focuses on interaction with a robot, not on system autonomy.
TR 10		<b>Not applicable:</b> Integration cost is not mentioned.	<b>Not applicable:</b> Integration cost is not mentioned.	<b>Not applicable:</b> Integration cost is not mentioned.	<b>Not applicable:</b> A review study, does not address integration cost.	<b>Not applicable:</b> Integration cost is not mentioned.	<b>Not applicable:</b> Integration cost is not mentioned.	<b>Not applicable:</b> A review study, does not address integration cost.	<b>Not applicable:</b> Focuses on aerial vehicle control.	<b>Not applicable:</b> Focuses on interaction with a robot, not on integration cost.
TR 11 Cumplimiento con regulaciones aplicables	Regulatory Compliance	<b>Not applicable:</b> Compliance with regulations is not mentioned.	<b>Not applicable:</b> Compliance with regulations is not mentioned.	<b>Not applicable:</b> Compliance with regulations is not mentioned.	<b>Not applicable:</b> A review study, does not address compliance with regulations.	<b>Not applicable:</b> Compliance with regulations is not mentioned.	<b>Not applicable:</b> Compliance with regulations is not mentioned.	<b>Not applicable:</b> A review study, does not address compliance with regulations.	<b>Not applicable:</b> Focuses on aerial vehicle control.	<b>Not applicable:</b> Focuses on interaction with a robot, not on compliance with regulations.

This table provides a detailed overview of how each study addresses the technical requirements set, providing a justification for compliance or non-compliance with each.

## Appendix C. Compliance with the Functional Requirements

We will now detail each of the requirements and their degree of compliance.

### Appendix C.1. EEG Signals Capture

NeuroSky's EEG biosensor digitizes and amplifies raw analog brain signals to deliver concise inputs to games, toys, and devices running health and wellness, educational, and research applications. Our brainwave algorithms, developed by NeuroSky neuroscientists and our partner research institutions, have revealed many new ways to interact with our world [54].

### Appendix C.2. Real-Time Interpretation of EEG Signals

For the real-time interpretation of EEG signals, generic ROS modules are used for data capture and transmission, such as *rosvag* for recording sensor data and *topic\_tools* for transforming and filtering data streams in real time. Integration with Python libraries for signal processing and machine learning (such as TensorFlow or PyTorch) is essential to implement and run LSTM or GRU models on EEG data.

### Appendix C.3. Intuitive Control of the Robotic Arm and Wheelchair

The key to achieving intuitive control of the robotic arm and wheelchair through ROS lies in the system's ability to seamlessly integrate BCI signals with mechanical control commands. The *moveit* module in ROS, for example, enables advanced planning and simulation of robotic arm movements, facilitating the creation of movement trajectories that mimic natural human movements. This means that commands derived from EEG signals can be translated into movements that are intuitively understood and expected by the user, like reaching for an object or moving the wheelchair in a particular direction.

For the wheelchair, the use of *nav\_stack* in ROS allows for the implementation of autonomous and assisted navigation systems. This module can process BCI commands and translate them into smooth and predictable wheelchair movements, adapting to environments and avoiding obstacles, resulting in a navigation experience that feels natural and easy to control for the user.

### Appendix C.4. Safety and Stability in Movement

For safety and stability, ROS offers modules like *diagnostic\_aggregator*, which collects and analyzes diagnostic data from various sensors and actuators, and *tf* for managing space transformations between different system components. These modules help continuously monitor the system's status and ensure that movements are performed within established safety parameters.

### Appendix C.5. Adaptability to Different Users

The headbands have been used with a sample of five different users of varying sex and age ranges, with no notable difficulties in reading data. Additionally, the prefrontal cortex is associated with higher cognitive functions such as decision making, planning, and attention. These functions are often preserved in many neurodegenerative diseases and spinal injuries, allowing patients to use these capabilities to interact with a BCI system.

In diseases like ALS (Amyotrophic Lateral Sclerosis), although motor function is severely affected, cognitive function, including operations in the prefrontal cortex, often remains intact [4].

Different neurodegenerative diseases affect different areas of the brain. For example, Alzheimer's disease mainly affects memory and cognitive processing, while ALS affects motor function.

The location for EEG data reading should be selected based on the brain areas least likely to be affected by the user’s specific disease. In many cases, the prefrontal cortex remains functional even when other areas, such as motor areas, are compromised.

Finally, placing electrodes in the prefrontal region is relatively easy and comfortable for the user. This accessibility is crucial for systems designed for prolonged or everyday use.

*Appendix C.6. Control of Chair Movements*

The control of wheelchair movements in the four main directions—forward, backward, left, and right—and their combinations through a BCI relies on advanced interpretation of EEG signals. By using machine learning algorithms such as LSTM or GRU networks, real-time analysis of brain signals is performed to map them into specific movement commands. This technology allows for precise translation of the user’s intentions into concrete actions. Integrated actuation systems within the wheelchair, managed by advanced control software, possibly based on ROS, dynamically respond to these commands, enabling smooth movements in multiple directions [55]. To ensure safety and reliability, the wheelchair is equipped with obstacle detection systems and safety protocols that allow for quick responses to changes in the environment and provide safe operation. This approach not only enhances user autonomy and mobility but also ensures an optimal level of safety and comfort, reflecting a significant advancement in personalized and technological assistance for individuals with mobility limitations.

*Appendix C.7. Portability and Light Weight (<100 g)*

In the following Table A1, we can see how either of the two selected devices comply with the weight restrictions in order to guarantee the perfect usability and user experience that have been defined in the functional requirements tables.

**Table A1.** Headband weight.

Neurosky Mindwave Mobile 2	Macrotellect Brainlink Lite
Physical Weight: 90 g	Net Weight (g): 39

*Appendix C.8. EEG/ECG Signal Quality Analysis*

As can be seen in Table A2, obtained from the manufacturers’ datasheets, both devices have an indicator and a value called “Signal quality”.

**Table A2.** Signal quality control.

Neurosky Mindwave Mobile 2	Macrotellect Brainlink Lite
Can be used to detect poor contact and whether the device is off the head.	Can be used to detect poor contact and whether the device is off the head.

*Appendix C.9. Commercial Wireless Headsets*

As can be seen from the datasheets of the two headsets, both meet the requirements for wireless systems Table A3.

**Table A3.** Wireless headsets.

Neurosky Mindwave Mobile 2	Macrotellect Brainlink Lite
Bluetooth BT/BLE dual mode module -BT(SPP) for PC, Mac, Android -BLE(GATT) for iOS BT Range: 10 m range	Transfer Method: Bluetooth Transmission Range (m): <10 m Baud Rate: 57,600 Bluetooth Compatibility: Bluetooth 2.0, Bluetooth3.0, Bluetooth 4.0 mobile device

Preset routines in robot and robot + chair actions.

To implement preset routines in the robot actions and the robot + wheelchair combination, the capabilities of ROS in terms of motion planning and task sequencing are used. The functional justification for this approach is based on several key ROS components and design considerations.

#### Appendix C.10. Motion Planning and Task Sequencing

**Use of the moveit module in ROS:** moveit is a widely used ROS package for robot arm motion planning. It allows the definition of preset routines by configuring specific trajectories and articulation points. This is essential for programming complex robot movements efficiently and accurately.

**Implementation of actionlib:** actionlib is another package in ROS that is used for the execution of long-running tasks, such as moving the wheelchair from one point to another. It allows for defining pre-configured actions and monitoring their progress, which is crucial to ensure that tasks are performed as intended.

**User Interface and Routine Selection:** Integration of a user interface with the BCI system allows users to select and activate preset routines. This is performed by specific commands interpreted by the BCI, which then activate the corresponding routines in the robot or in the robot + wheelchair system [56].

The preset routines are customized according to the user's needs and preferences. This includes adjusting the speed, range of motion, and navigation patterns for the wheelchair, which increases functionality and user comfort.

#### Appendix C.11. Security and Efficiency

Using packages such as *diagnostic\_aggregator* and *tf*, ROS provides a real-time monitoring system to ensure safety during the execution of routines. Protocols can be implemented to detect and respond to unforeseen or dangerous situations.

**Optimization of Routes and Movements:** Advanced motion planning in ROS allows the optimization of robot routes and actions to maximize efficiency and minimize wear and tear.

In short, the implementation of preset routines in robot actions and the robot + wheelchair system through ROS facilitates precise, customizable, and safe control. This significantly improves the user experience, providing a smooth and efficient interaction with the assisted system.

### Appendix D. Compliance of the Technical Requirements

We will now detail each of the requirements and their degree of compliance regarding technical issues.

- **Effective Integration of BCI with Wheelchair + Robot**

In this context, ROS acts as the central nexus, coordinating communication between the BCI and the wheelchair and robot systems. The BCI data, processed by LSTM or GRU networks, is translated into specific commands that are sent via ROS to the actuators of the

robot and wheelchair. The modularity and scalability provided by ROS are fundamental to ensuring fluid and precise interaction between the brain–computer interface and the mechanical systems. Additionally, ROS facilitates the integration of safety and feedback systems, which is essential for reliable and safe control of assisted devices [55].

At this point, a specific node has been identified within the ROS ecosystem, known as ROS-Neuro, which plays a crucial role in this integration. ROS-Neuro specializes in interacting with BCIs, processing and translating EEG signals into useful commands for the system. This node is used as an alternative method to validate the compatibility and effectiveness of the Neurosky Mindwave and MacroTellec Brainlink Lite headsets, which were not originally evaluated with this node. The implementation and testing of ROS-Neuro, especially on a Jetson Nano board, presents a unique challenge since the ROS-Neuro node has not been evaluated in embedded applications on this type of board. Therefore, this provides an opportunity to validate and potentially optimize its functionality with these specific BCI devices and on the Jetson Nano platform [57]. This approach will not only allow the validation of the mentioned BCI devices in a new environment but will also contribute to the robustness and versatility of the ROS-Neuro node in assistive applications [58].

- **Efficient EEG data processing ( $t \leq 1$  s)**

As we can see in Table A4, the data sending rate is less than 1 s, as shown by the “Timestamp” values of the time series of data captured by the EEG headsets. Therefore, the data are processed within the specified time ranges.

**Table A4.** Real data sample.

Timestamp	Atten.	Medit.	Delta	Theta	L.Alpha	H.Alpha	L.Beta	H.Beta	L.Gamma	H.Gamma	Signal	Key
54,127 *	84	48	25,253	14,225	3441	4172	1881	9630	6863	5745	0	Lbutton **
55,056	78	60	4946	5021	8879	13,002	879	6367	4314	3150	0	None **
56,038	66	75	102,896	14,838	12,817	8565	2890	14,525	9144	23,072	0	None
61,562	51	53	48,239	10,965	5537	6266	2181	4752	5345	2222	0	None
62,073	77	44	53,758	17,563	965	4051	3750	10,528	8904	3930	0	None
63,114	77	44	1,284,256	316,379	87,065	44,605	12,994	13,046	16,701	5478	26	None
64,012	77	44	2,713,787	64,145	9239	39,990	6864	27,507	8148	1871	51	None
65,001	67	47	277,597	21,746	1657	8398	3804	10,485	4459	2230	0	Up **
66,047	54	63	7216	7222	9248	4495	4986	5293	1906	1921	0	Up
67,017	66	48	3799	7718	1745	1698	2233	8488	2545	1782	0	Up

\* Time values in [ms]. \*\* Values labeled for classification.

Following the order defined in the functional requirements table, which matches the temporal requirement of the process, we can see in Figure 3 that the signals taken from a subject of an initial sample of six using the Brainlink headband meet the requested specifications, both for the functional and technical parts. The signals are well defined and structured without gaps in the sample and with coherent values for the attention and meditation data that the headband itself calculates, thanks to its embedded algorithm in the TGAM [59]. It can also be observed that the filtering process and elimination of noise and artifacts, understanding artifacts as the involuntary movements of the subject, which in many cases alter and/or modify the signals obtained by the headband, is correct and falls within the expected values.

- **Real-Time Interpretation of EEG Signals**

Real-time interpretation of EEG signals is achieved using recurrent neural networks, such as LSTM or GRU, which are highly effective at processing sequential, temporal data, such as the EEGs obtained from the headsets [35]. These networks have the capability to remember past information, which is crucial for interpreting EEG signals that vary over time. This allows quick and accurate real-time classification of signals, essential for applications requiring immediate responses, such as assisted device control. The architecture of these

networks is specially designed to handle the inherent complexities of EEG data, such as variations in amplitude and frequency, ensuring reliable and continuous interpretation.

- **Robust Control System for Robotic Arm and Wheelchair**

The control system for the robotic arm and wheelchair greatly benefits from the precision and adaptability of LSTM or GRU networks. These networks can learn and differentiate between a wide range of EEG signal patterns, allowing for detailed and personalized control [60]. The robustness of the system stems from these networks' ability to handle noisy signals and individual variations in EEG patterns, ensuring consistent and precise control. Furthermore, the learning and adaptation capabilities of these networks mean the system can improve with use, adjusting to the particularities of the user's EEG signals, which is crucial for sensitive applications such as controlling a robotic arm or a wheelchair.

An LSTM network is a form of RNN designed to handle long-term dependencies in sequential data. Each LSTM cell has the ability to maintain or discard information using structures called gates [61]. These gates are essentially neural network layers that decide what information is relevant to keep or discard during learning.

In the context of controlling a robotic arm or a wheelchair, the EEG signals would be the inputs to the LSTM network. These signals would be processed sequentially, with the network updating its internal state based on the incoming signals and its own past state. The output of the network at each time step could be interpreted as a command or a series of commands for the device.

For instance, if a particular sequence of EEG signals is associated with moving forward, the LSTM network, after being trained on these signals, would learn to associate these sequences with the corresponding activation to move the wheelchair forward [54].

This process allows for fine and adaptive control, as the network can learn and respond to the user's specific signals, which is crucial for creating a robust and personalized control system for assistive applications.

#### *Appendix D.1. Application in Robotic Arm and Wheelchair Control*

In the context of controlling a robotic arm or a wheelchair, the EEG signals would be the inputs to the LSTM network. These signals would be processed sequentially, with the network updating its internal state based on the incoming signals and its own past state. The output of the network at each time step could be interpreted as a command or a series of commands for the device.

- **Accessible and User-friendly Interface**

The accessibility and friendliness of the user interface are based on the implementation of universal design principles, ensuring that the interface is understandable and usable by people with a wide range of abilities and experiences. This includes the use of clear iconography, legible text, and contrasting colours for easy visual interpretation. The interface will also incorporate adaptive controls, which can be configured according to the specific needs of the user, such as sensitivity adjustments or customization of input methods, which are crucial for users with motor or cognitive limitations.

Moreover, simplicity in interface design is a priority [62]. This means minimizing visual and functional complexity and avoiding overwhelming the user with unnecessary options or confusing information. Navigation will be intuitive, focusing on easy access to the most important functions. This is achieved through a clear hierarchy of menus and the implementation of step-by-step setup assistants, guiding the user in customizing the system according to their preferences and needs.

Finally, the interface will offer interactive tutorials and integrated support, particularly useful for users who may be new to technology or require additional guidance.

- **User Feedback System**

The feedback system is a critical component for enhancing the user's interaction with the system. It will provide visual and tactile responses to inform the user that their commands have been received and executed correctly. This is especially important in assistive applications, where the user must have confidence in the system. Tactile feedback can be particularly useful for users with visual or auditory limitations [63]. Additionally, the feedback system can include adaptive learning elements, where the user receives feedback on how to improve the effectiveness of their commands, increasing the efficiency and satisfaction of the user with the system over time.

- **Integration with Commercial Motorized Wheelchairs**

We can propose two paths for system integration: firstly, targeting the control of the wheelchair's joystick movement by sending parallel information to the controller or, as a second option, directly sending control signals over the motor regulator (driver) if they allow this type of actuation with external signals. Given the wide range of motorized wheelchairs and manufacturers, the system's universality must be ensured for integration. To address the integration of a ROS-based control system with commercial wheelchairs, it is crucial to consider both mechanical and electrical aspects. This integration involves adapting hardware and software to ensure smooth interaction between the BCI-ROS system and the wheelchair.

Some of the world's leading manufacturers of power wheelchairs are Quirumed, Ortopedia ITOMI, Karma Mobility, and Sunrise Medical. These manufacturers offer a variety of power wheelchairs, including compact, foldable, lightweight models with various functionalities [64–66]. For example, Quirumed and Ortopedia ITOMI offer power wheelchairs at factory prices, while Karma Mobility specializes in top-quality manual and power wheelchairs [64,66,67]. The MARTINIKA EVO power wheelchair, offered by Ortopedia Silvio, is another example of a comfortable, foldable, and easy-to-manage model [68].

Sunrise Medical manufactures a variety of power wheelchairs under its Magic Mobility and Quickie brands [69]. Some of the models include the following:

#### *Appendix D.2. Magic Mobility*

X8 Extreme 4 × 4: An all-terrain power wheelchair that adapts to difficult terrain such as sand, snow, and unpaved roads.

#### *Appendix D.3. Quickie*

Sedeo Pro: A high-end standing wheelchair with front-wheel drive and a multi-position seating system.

F35: An economical, detachable model, made in Spain, with 50 amp batteries that offer great autonomy.

#### *Appendix D.4. Mechanical Integration*

Mechanically, adaptation generally requires installing additional actuators and sensors compatible with ROS. These may include stepper motors or servo motors for motion control and sensors like optical encoders for position feedback. Mechanical integration should consider the following:

**Mounting Compatibility:** Ensure that new mechanical components can be mounted on the wheelchair without affecting its basic functionality.

**Load Capacity:** Assess whether the chair can support the weight and additional strain of the new components.

**Modular Design:** Prefer solutions that can be adapted to different wheelchair models.

This integration implies the ability to make modifications to the robot itself. Therefore, the choice has been an open-source robot that allows these modifications. Niryo, in its One model, provides not only the source of the design files and STL files necessary for the printing process but also facilitates the entire breakdown of assembly and adjustment of the robot. Thus, redesigning the support pieces is feasible. In Figure A1, we can appreciate

the breakdown of the base parts of the robot (Figure A2), allowing in a simple design phase to redesign a base for adjustment to the chair and then proceed to its printing. This process facilitates the integration, adjustment, and maintenance of the robot, adapting the robot to the chair and not the chair to the robot, gaining versatility and integration.



Figure A1. Robot base (STL format).

**Step1 : Assembling Base**

Picture	Name	Number
	Base	1
	Air Routing	3
	Belt tensioner	1
	Base Bearing Support	1
	Fan	1
	Switch	1
	Niryo Motor Orange	1



	Bearing 3x10x4 mm	3
	Bearing 8x22x7 mm	1
	M3 Brake Nut	2
	Screw M3 x 10 mm	11
	Screw M3 x 15 mm	5
	Gear GT2	1

Figure A2. Assembling base.

*Appendix D.5. Electrical Integration*

Electrical integration involves connecting the ROS-based control system to the wheelchair’s electronics. This may include the following:

Interface with the Wheelchair Controller: Many commercial wheelchairs have their own controllers. A module like *ros\_serial* can be used to establish communication between the ROS system and these controllers.

Power Supply Adaptation: Ensure that the wheelchair’s power supply can handle the additional load of the new electronic components.

Electrical Safety: Implement safety measures to protect both the electronic system and the user, including fuses, emergency switches, and adequate insulation.

#### Appendix D.6. General Considerations

Software Interoperability: Use ROS to develop custom controllers that can interact with the existing hardware in the wheelchair. This may involve developing specific ROS nodes that communicate with the wheelchair's protocols.

Scientific Publications and Regulations: Consult the relevant literature and safety regulations to ensure that the integration complies with safety and accessibility standards. This includes following IEEE guidelines in robotics and assistive systems.

In conclusion, the effective integration of a BCI-ROS system with commercial wheelchairs is a multidisciplinary process that requires attention to mechanical and electrical compatibility, such as ROS-Neuro, as well as the development of custom software and adherence to safety regulations [70].

- **Usage Autonomy ( $\geq 3$  h)**

In this aspect, two elements need to be evaluated: the headband, which has its own energy system, rechargeable or not, and the mechanical elements, in this case, the robot, wheelchair, and controller, looking for the most limiting factor as the maximum operational value of the system.

According to the datasheets of the headbands, we find that in the case of Neurosky, its headband has an estimated duration of 9 h as it relies on a non-rechargeable AAA battery. Our other headband model, Brainlink Lite by Macrotellect, has a small rechargeable lithium battery but with a maximum duration of 180 min. For wheelchairs, the usage and type of battery vary, with the following ranges of use. (Source: [www.onlinemedical.es/](http://www.onlinemedical.es/) (accessed on 26 December 2023.))

1. Lithium batteries 20 Ah—4 kg—maximum autonomy 25 km.
2. Gel/AGM batteries 12 Ah—10 kg—maximum autonomy 16 km.
3. Gel/AGM batteries 20 Ah—17 kg—maximum autonomy 20 km.

Considering that, by regulation, a wheelchair cannot exceed 6 km/h for an average value of use and a 20 AH gel/AGM battery with a maximum autonomy of 20 km, we can perform a simple calculation in Equations (A1) and (A2) to determine the maximum usage time.

$$T = \frac{20 \text{ Km}}{6 \frac{\text{Km}}{\text{h}}} = 3.33 \text{ h. max autonomy}; \quad (\text{A1})$$

$$\text{Expected consumption : } C = \frac{20 \text{ Ah}}{3.33 \text{ h}} = 6A \quad (\text{A2})$$

Furthermore, the power consumption of the control unit and the robot must be considered. Since they do not have their own power supply system, they will need to be connected to the wheelchair's battery for operation.

Considering the maximum consumption forecast according to the manufacturers of the controller and the robot, the maximum consumption of the Jetson Nano is between 5 and 10 watts, depending on the power mode, either by USB (5 V/2 Amp) or by DC jack. For the Niryo robot, the consumption is like that of the Jetson Nano controller, about 10 W, also with a power supply of 5 V/2 Amp for the Arduino Mega system. Therefore, the sum of the two consumptions, applying a high simultaneity coefficient of 80%, we can calculate a consumption of 4 amperes at 5 volts, which makes a total of  $20 \text{ w} \times 0.8 = 16 \text{ w/h}$ .

In any case, given the low consumption of these devices, it would also be possible to use a power bank like those used by mobile devices that provide this rate of energy.

- **Multi-platform headset support, Windows, Apple, Linux, Android**

Accessing the data supplied by the manufacturers Neurosky and Macrotellect, we can find that in both cases, the two selected models, Neurosky Mindwave Mobile 2 and

Macrotellect Brainlink lite, support all the required platforms. An extract of the data obtained from the manufacturer's website is given in Tables A5 and A6, below [71,72].

**Table A5.** Multi-platform compatibility.

Neurosky Mindwave Mobile 2	Macrotellect Brainlink Lite
Supported platforms: Windows (XP/7/8/10), Mac (OSX 10.8 or later), iOS (iOS 8 or later), and Android (Android 2.3 or later)	Compatibility: iOS/Android With other SDK platforms

- **Low integration costs (<EUR 1500)**

To complete this requirement, we assume, as stated in the definition of the requirement, that we do not consider the value of the motorized wheelchair.

Table A6 gives a breakdown of the cost scale.

**Table A6.** Cost scenario.

Devices	Total Cost Vat Incl.	Store
Headband Neurosky Mindwave Mobile 2	EUR 169.90 (Op1)	Amazon
Headband Macrotellect Brainlink Lite	EUR 239.00 (Op2)	Mindtecstore
Jetson Nano Developer Kit	EUR 194.96	RS-online
Ardino Mega + Shield Ramps 1.4	EUR 51.40	Bricogeek
5 drivers TMC 2208	EUR 22.99	Amazon
Robot Niryo One (Open Source)	EUR 450.00	DIY
Material Total Cost	EUR 889.25 (Op1) EUR 958.35 (Op2)	

The cost breakdown determines that both options fall within the projected cost limit. It should be noted that this does not include the costs related to personnel or development, whose allocation will depend on the potential monetization of the finished product/development.

- **Compliance with Applicable Regulations**

In this section, it has been verified that all devices comply with all applicable regulations, detailing the standards applicable to each device.

Firstly, although not a limiting factor of this study, as we largely depend on the commercial wheelchair available to the user, we will address the motorized wheelchair and its regulations. For this purpose, we consulted with the certification entity TÜV Rheinland [73], which indicates that motorized or electric wheelchairs, as they are also known, must undergo the following certification for approval as a medical product. In our case, what we do is integrate with an already certified chair, so not all these certifications will be applicable to us. The selection of partial certification will depend on the degree of modification and the criteria of the certifying entity.

Table A7 shows the regulations applicable to powered wheelchairs, as well as the recommended certifications for their commercialization.

The next element susceptible to standardization is the Niryo robot, which, in this case, will be subject to the following standards Table A8. UNE Safety Standards in the Robots Sector, which have been extracted from the normative presentation made by AENOR on 28 April 2017 by Mr. Francisco Arribas from the Directorate of Standardization [85].

In our case, due to the use of the robot, we can consider that we are subject to the UNE-EN ISO 13482:2014 standard as it is a personal assistance robot. However, with the latest considerations of COBOTS or Collaborative Robots brought by Industry 4.0, we must consider the following standards in Table A9.

**Table A7.** Applicable standards for testing of wheelchairs and powered scooters for disabled people.

Standard	Description
ISO 7176 [74]	Mechanical tests for compliance with various sections of the ISO 7176 series of standards describing different test methods for wheelchairs and electric scooters
EN 12182 [75]	Assistive products for persons with disability—General requirements and test methods
EN 12183 [76]	Manual wheelchairs—requirements and test methods
EN 12184 [77]	Electrically powered wheelchairs, scooters, and their chargers—requirements and test methods
ISO 7176-14 [78]	Power and control systems for electrically powered wheelchairs and scooters. Requirements and test methods
IEC 60601-1 [79]	Electrical safety tests in accordance with standards describing general safety of electrical medical devices Requirements and test methods
ISO 7176-21 [80] and IEC 60601-1-2 [79]	Electromagnetic compatibility (EMC). Requirements and test methods
ISO 7176-19 [81]	Impact test. Requirements and test methods
EN 1021 [82]	Fire resistance tests
Cadmium and PAH	Tests based on European standards
Proposals	In addition to these specific standards for wheelchairs and electric scooters, it is also recommended to carry out quality management system certification according to ISO 13485 [83] and/or ISO 9001 [84] standards

**Table A8.** Applicable standards for robots and robotic devices.

Standard	Description
UNE-EN ISO 10218-1:2012 [86]	Robots and robotic devices. Safety requirements for industrial robots. Part 1: Robots. (ISO 10218-1:2011)
UNE-EN ISO 10218-2:2011 [87]	Robots and robotic devices. Safety requirements for industrial robots. Part 2: Robot systems and integration. (ISO 10218-2:2011)
UNE-EN ISO 13482:2014 [88]	Robots and robotic devices. Safety requirements for non-industrial robots. Non-medical personal assistance robots. (ISO 13482:2014)

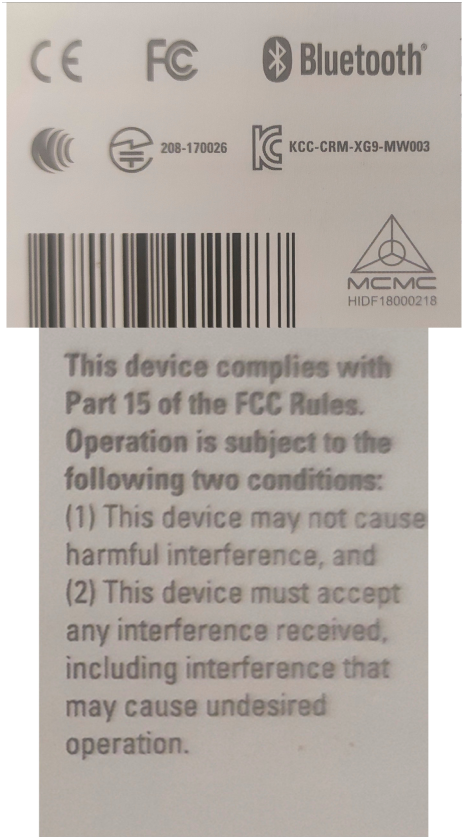
**Table A9.** ISO/TS 15066:2016 robots and robotic devices—collaborative robots.

Standard	Description
ISO/TS 15066:2016 [89]	Specifies safety requirements for collaborative industrial robot systems and the work environment and supplements the requirements and guidance on collaborative industrial robot operation given in ISO 10218-1 and ISO 10218-2
ISO/TS 15066:2016 [89]	Applies to industrial robot systems as described in ISO 10218-1 and ISO 10218-2. It does not apply to non-industrial robots, although the safety principles presented can be useful to other areas of robotics

The next item, we analyse is the NVIDIA Jetson Nano control device, which, as an electronic device, must comply with the Declaration of Conformity with the RoHS Directive. Compliance with this directive is described in the following link, provided by an authorized distributor [90].

Lastly, but no less important, is the regulation applicable to headbands, which is shown in the following Table A10.

**Table A10.** Applicable regulations.

Neurosky Mindwave Mobile 2	Macrotellect Brainlink Lite
	<p data-bbox="1050 801 1417 922">Safety Certification Bluetooth SIG FCC/CE/SRRC/ROHS UN38.3 Lithium Battery Apple Made for iOS (MFi)</p>

## References

- Bhattacharyya, S.; Konar, A.; Tibarewala, D.N. Motor Imagery, P300 and Error-Related EEG-Based Robot Arm Movement Control for Rehabilitation Purpose. *Med. Biol. Eng. Comput.* **2014**, *52*, 1007–1017. [CrossRef]
- Chen, X.; Wang, Y.; Nakanishi, M.; Gao, X.; Jung, T.-P.; Gao, S. High-Speed Spelling with a Noninvasive Brain–Computer Interface. *Proc. Natl. Acad. Sci. USA* **2015**, *112*, E6058–E6067. [CrossRef]
- Frontiers | Hybrid Brain–Computer Interface Techniques for Improved Classification Accuracy and Increased Number of Commands: A Review. Available online: <https://www.frontiersin.org/articles/10.3389/fnbot.2017.00035/full?ref=https://githubhelp.com> (accessed on 8 January 2024).
- Huang, Q.; Zhang, Z.; Yu, T.; He, S.; Li, Y. An EEG-/EOG-Based Hybrid Brain-Computer Interface: Application on Controlling an Integrated Wheelchair Robotic Arm System. *Front. Neurosci.* **2019**, *13*, 1243. [CrossRef]
- Jin, J.; Zhang, H.; Daly, I.; Wang, X.; Cichocki, A. An Improved P300 Pattern in BCI to Catch User’s Attention. *J. Neural Eng.* **2017**, *14*, 36001. [CrossRef]
- Khan, M.J.; Hong, K.-S. Hybrid EEG–fNIRS-Based Eight-Command Decoding for BCI: Application to Quadcopter Control. *Front. Neuroinformatics* **2017**, *11*, 6. [CrossRef]
- Quadcopter Control in Three-Dimensional Space Using a Noninvasive Motor Imagery-Based Brain–Computer Interface—IOpscience. Available online: <https://iopscience.iop.org/article/10.1088/1741-2560/10/4/046003/meta> (accessed on 8 January 2024).
- Single-Trial Analysis and Classification of ERP Components—A Tutorial—ScienceDirect. Available online: <https://www.sciencedirect.com/science/article/abs/pii/S1053811910009067?via=ihub> (accessed on 8 January 2024).
- A Brain Controlled Wheelchair to Navigate in Familiar Environments | IEEE Journals & Magazine | IEEE Xplore. Available online: [https://ieeexplore.ieee.org/abstract/document/5462915?casa\\_token=a8MeRLms4mwAAAAA:uCYHeESHaaFyMvjT\\_4UeCJOG-nNdx215rOo5S\\_Moot09Tgj1x5Xg3wEDAfaxMYxQOh\\_fLfoP4Q](https://ieeexplore.ieee.org/abstract/document/5462915?casa_token=a8MeRLms4mwAAAAA:uCYHeESHaaFyMvjT_4UeCJOG-nNdx215rOo5S_Moot09Tgj1x5Xg3wEDAfaxMYxQOh_fLfoP4Q) (accessed on 8 January 2024).

10. Soekadar, S.R.; Witkowski, M.; Vitiello, N.; Birbaumer, N. An EEG/EOG-Based Hybrid Brain-Neural Computer Interaction (BNCI) System to Control an Exoskeleton for the Paralyzed Hand. *Biomed. Eng. Biomed. Tech.* **2015**, *60*, 199–205. [CrossRef]
11. Witkowski, M.; Cortese, M.; Cempini, M.; Mellinger, J.; Vitiello, N.; Soekadar, S.R. Enhancing Brain-Machine Interface (BMI) Control of a Hand Exoskeleton Using Electrooculography (EOG). *J. NeuroEngineering Rehabil.* **2014**, *11*, 165. [CrossRef] [PubMed]
12. Banach, K.; Małecki, M.; Rosół, M.; Broniec, A. Brain-Computer Interface for Electric Wheelchair Based on Alpha Waves of EEG Signal. *Bio-Algorithms Med-Syst.* **2021**, *17*, 165–172. [CrossRef]
13. Antoniou, E.; Bozios, P.; Christou, V.; Tzamourta, K.D.; Kalafatakis, K.; Tsiouras, M.G.; Giannakeas, N.; Tzallas, A.T. EEG-Based Eye Movement Recognition Using the Brain-Computer Interface and Random Forests. *Sensors* **2021**, *21*, 2339. [CrossRef] [PubMed]
14. Belo, J.; Clerc, M.; Schön, D. EEG-Based Auditory Attention Detection and Its Possible Future Applications for Passive BCI. *Front. Comput. Sci.* **2021**, *3*. [CrossRef]
15. Saichoo, T.; Boonbrahm, P.; Punsawad, Y. Facial-Machine Interface-Based Virtual Reality Wheelchair Control Using EEG Artifacts of Emotiv Neuroheadset. In Proceedings of the 2021 18th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), Chiang Mai, Thailand, 19–22 May 2021; pp. 781–784.
16. Vélez, L.; Kemper, G. Algorithm for Detection of Raising Eyebrows and Jaw Clenching Artifacts in EEG Signals Using Neurosky Mindwave Headset. In Proceedings of the 5th Brazilian Technology Symposium; Smart Innovation, Systems and Technologies; Springer Science and Business Media Deutschland GmbH: Berlin/Heidelberg, Germany, 2021; Volume 202, pp. 99–110.
17. Ping, J.; Wang, F.; Xu, Z.; Bi, J.; Xiao, L. Semi-Autonomous Navigation Control System of Intelligent Wheelchair Based on Asynchronous SSVEP-BCI. In Proceedings of the 2021 IEEE 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), Jiaying, China, 27–31 July 2021; pp. 1–6.
18. Olesen, S.D.T.; Das, R.; Olsson, M.D.; Khan, M.A.; Puthusserypady, S. Hybrid EEG-EOG-Based BCI System for Vehicle Control. In Proceedings of the 9th IEEE International Winter Conference on Brain-Computer Interface, BCI 2021, Gangwon, Republic of Korea, 22 February 2021; Institute of Electrical and Electronics Engineers Inc.: Piscataway, NJ, USA, 2021.
19. Zhang, M.; Zhang, Q. Conditions for Prosperity and Depression of a Stochastic R&D Model under Regime Switching. *Adv. Differ. Equ.* **2020**, *2020*, 173. [CrossRef]
20. Xu, B.; Li, W.; Liu, D.; Zhang, K.; Miao, M.; Xu, G.; Song, A. Continuous Hybrid BCI Control for Robotic Arm Using Noninvasive Electroencephalogram, Computer Vision, and Eye Tracking. *Mathematics* **2022**, *10*, 618. [CrossRef]
21. Cao, L.; Li, G.; Xu, Y.; Zhang, H.; Shu, X.; Zhang, D. A Brain-Actuated Robotic Arm System Using Non-Invasive Hybrid Brain-Computer Interface and Shared Control Strategy. *J. Neural Eng.* **2021**, *18*, 46045. [CrossRef]
22. Park, S.; Han, C.-H.; Im, C.-H. Design of Wearable EEG Devices Specialized for Passive Brain-Computer Interface Applications. *Sensors* **2020**, *20*, 4572. [CrossRef] [PubMed]
23. Michel, C.M.; Brunet, D. EEG Source Imaging: A Practical Review of the Analysis Steps. *Front. Neurol.* **2019**, *10*, 325. [CrossRef] [PubMed]
24. Ruşanu, O.-A. Python Implementation for Brain-Computer Interface Research by Acquiring and Processing the NeuroSky EEG Data for Classifying Multiple Voluntary Eye-Blinks. In Proceedings of the 5th International Conference on Nanotechnologies and Biomedical Engineering, Chisinau, Moldova, 3–5 November 2021; Tiginyanu, I., Sontea, V., Railean, S., Eds.; Springer International Publishing: Cham, Switzerland; pp. 666–672.
25. Alvarado, O.; Tinoco, D.; Veintimilla, J. Sistema Embebido Para Detección de Somnolencia En Conductores Mediante Señal EEG. In *Avances y Aplicaciones de Sistemas Inteligentes y Nuevas Tecnologías*; Universidad de Los Andes (ULA): Merida, Venezuela, 2016; p. 9. ISBN 978-980-11-1836-7.
26. De Fazio, R.; Mattei, V.; Al-Naami, B.; De Vittorio, M.; Visconti, P. Methodologies and Wearable Devices to Monitor Biophysical Parameters Related to Sleep Dysfunctions: An Overview. *Micromachines* **2022**, *13*, 1335. [CrossRef]
27. Niryo One Documentation. *Niryo*. 2018. Available online: <https://niryo.com/docs/niryo-one/> (accessed on 21 February 2024).
28. Groshev, M.; Sacido, J.; Martín-Pérez, J. FoReCo: A Forecast-Based Recovery Mechanism for Real-Time Remote Control of Robotic Manipulators. In Proceedings of the SIGCOMM '22 Poster and Demo Sessions, Amsterdam, The Netherlands, 22–26 August 2022; pp. 7–9.
29. Jorge, A.A.; Riascos LA, M.; Miyagi, P.E. Modelling and Control Strategies for a Motorized Wheelchair with Hybrid Locomotion Systems. *J. Braz. Soc. Mech. Sci. Eng.* **2021**, *43*, 46. [CrossRef]
30. Ruman, M.R.; Barua, A.; Mohajan, S.; Paul, D.; Sarker, A.K.; Rabby, M.R. An Implementation of Motorized Wheelchair for Handicapped Persons. In Proceedings of the 2019 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS), Greater Noida, India, 18–19 October 2019; pp. 301–305.
31. Design and Implementation of Hybrid BCI Based Wheelchair | IEEE Conference Publication | IEEE Xplore. Available online: <https://ieeexplore.ieee.org/document/9591796> (accessed on 22 December 2023).
32. Subasi, A.; Tuncer, T.; Dogan, S.; Tanko, D.; Sakoglu, U. EEG-Based Emotion Recognition Using Tunable Q Wavelet Transform and Rotation Forest Ensemble Classifier. *Biomed. Signal Process. Control* **2021**, *68*, 102648. [CrossRef]
33. Roy, A.M. Adaptive Transfer Learning-Based Multiscale Feature Fused Deep Convolutional Neural Network for EEG MI Multiclassification in Brain-Computer Interface. *Eng Appl Artif Intell* **2022**, *116*, 105347. [CrossRef]
34. Gong, S.; Xing, K.; Cichocki, A.; Li, J. Deep Learning in EEG: Advance of the Last Ten-Year Critical Period. *IEEE Trans. Cogn. Dev. Syst.* **2021**, *14*, 348–365. [CrossRef]

35. Aquino-Britez, D.; Ortiz, A.; Ortega, J.; León, J.; Formoso, M.; Gan, J.Q.; Escobar, J.J. Optimization of Deep Architectures for EEG Signal Classification: An AutoML Approach Using Evolutionary Algorithms. *Sensors* **2021**, *21*, 2096. [CrossRef]
36. Nagabushanam, P.; Thomas George, S.; Radha, S. EEG Signal Classification Using LSTM and Improved Neural Network Algorithms. *Soft Comput.* **2020**, *24*, 9981–10003. [CrossRef]
37. Xu, G.; Shen, X.; Chen, S.; Zong, Y.; Zhang, C.; Yue, H.; Liu, M.; Chen, F.; Che, W. A Deep Transfer Convolutional Neural Network Framework for EEG Signal Classification. *IEEE Access* **2019**, *7*, 112767–112776. [CrossRef]
38. Rahman, M.A.; Khanam, F.; Ahmad, M.; Uddin, M.S. Multiclass EEG Signal Classification Utilizing Rényi Min-Entropy-Based Feature Selection from Wavelet Packet Transformation. *Brain Inform.* **2020**, *7*, 7. [CrossRef] [PubMed]
39. Wang, L.; Wang, J.; Wen, B.; Mu, W.; Liu, L.; Han, J.; Zhang, L.; Jia, J.; Kang, X. Enhancing Motor Imagery EEG Signal Classification with Simplified GoogLeNet. In Proceedings of the 2023 11th International Winter Conference on Brain-Computer Interface (BCI), Gangwon, Republic of Korea, 20–22 February 2023; pp. 1–6.
40. Zargar, S.A. Introduction to Sequence Learning Models: RNN, LSTM, GRU. 2021. Available online: [https://www.researchgate.net/profile/Sakib-Zargar-2/publication/350950396\\_Introduction\\_to\\_Sequence\\_Learning\\_Models\\_RNN\\_LSTM\\_GRU/links/607b41c0907dcf667ba83ade/Introduction-to-Sequence-Learning-Models-RNN-LSTM-GRU.pdf](https://www.researchgate.net/profile/Sakib-Zargar-2/publication/350950396_Introduction_to_Sequence_Learning_Models_RNN_LSTM_GRU/links/607b41c0907dcf667ba83ade/Introduction-to-Sequence-Learning-Models-RNN-LSTM-GRU.pdf) (accessed on 21 February 2024).
41. Ko, D.-H.; Shin, D.-H.; Kam, T.-E. Attention-Based Spatio-Temporal-Spectral Feature Learning for Subject-Specific EEG Classification. In Proceedings of the 2021 9th International Winter Conference on Brain-Computer Interface (BCI), Gangwon, Republic of Korea, 22–24 February 2021; pp. 1–4.
42. Meng, J.; Zhang, S.; Bekyo, A.; Olsoe, J.; Baxter, B.; He, B. Noninvasive Electroencephalogram Based Control of a Robotic Arm for Reach and Grasp Tasks. *Sci. Rep.* **2016**, *6*, 38565. [CrossRef] [PubMed]
43. Zhou, C. SSVEP-Based BCI Wheelchair Control System. *arXiv* **2023**, arXiv:2307.08703.
44. 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. [CrossRef]
45. Kanungo, L.; Garg, N.; Bhobe, A.; Rajguru, S.; Baths, V. Wheelchair Automation by a Hybrid BCI System Using SSVEP and Eye Blinks. In Proceedings of the 2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Melbourne, VIC, Australia, 17–20 October 2021.
46. Gu, X.; Cao, Z.; Jolfaei, A.; Xu, P.; Wu, D.; Jung, T.-P.; Lin, C.-T. EEG-Based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and Their Applications. *IEEE/ACM Trans. Comput. Biol. Bioinform.* **2020**, *18*, 1645–1666. [CrossRef]
47. AlAbboudi, M.; Majed, M.; Hassan, F.; Nassif, A.B. EEG Wheelchair for People of Determination. In Proceedings of the 2020 Advances in Science and Engineering Technology International Conferences (ASET), Dubai, United Arab Emirates, 4 February–9 April 2020.
48. Mounir, R.; Alqasemi, R.; Dubey, R. BCI-Controlled Hands-Free Wheelchair Navigation with Obstacle Avoidance. *arXiv* **2020**, arXiv:2005.04209.
49. Kim, Y.; Velamala, B.; Choi, Y.; Kim, Y.; Kim, H.; Kulkarni, N.; Lee, E.-J. A Literature Review on the Smart Wheelchair Systems. *arXiv* **2023**, arXiv:2312.01285.
50. Vishwanath, R.M.; Kumaar, S.; Omkar, S.N. A Real-Time Control Approach for Unmanned Aerial Vehicles Using Brain-Computer Interface. *arXiv* **2018**, arXiv:1809.00346.
51. Abiri, R.; Borhani, S.; Zhao, X.; Jiang, Y. Real-Time Brain Machine Interaction via Social Robot Gesture Control. In *Dynamic Systems and Control Conference*; American Society of Mechanical Engineers: New York, NY, USA, 2017.
52. OMPI—Búsqueda En Las Colecciones de Patentes Nacionales e Internacionales. Available online: <https://patentscope.wipo.int/search/es/search.jsf> (accessed on 8 January 2024).
53. Homepage | Epo.Org. Available online: <https://www.epo.org/en> (accessed on 8 January 2024).
54. EEG—Electroencephalography—BCI | NeuroSky. Available online: [https://developer.neurosky.com/docs/doku.php?id=neurosky\\_101](https://developer.neurosky.com/docs/doku.php?id=neurosky_101) (accessed on 8 January 2024).
55. Sivakanthan, S.; Candiotti, J.L.; Sundaram, A.S.; Duvall, J.A.; Sergeant, J.J.G.; Cooper, R.; Satpute, S.; Turner, R.L.; Cooper, R.A. Mini-Review: Robotic Wheelchair Taxonomy and Readiness. *Neurosci. Lett.* **2022**, *772*, 136482. [CrossRef] [PubMed]
56. Cebolla Arroyo, R.; de León Rivas, J.; Barrientos, A. Estructura de control en ROS y modos de marcha basados en máquinas de estados de un robot hexápodo. In *Actas de las XXXVIII Jornadas de Automática*; Servicio de Publicaciones de la Universidad de Oviedo: Oviedo, Spain, 2017; pp. 686–693.
57. Tonin, L.; Beraldo, G.; Tortora, S.; Menegatti, E. ROS-Neuro: An Open-Source Platform for Neurorobotics. *Front. Neurorobotics* **2022**, *16*, 886050. [CrossRef]
58. ROS-Neuro. Available online: <https://github.com/rosneuro> (accessed on 20 December 2023).
59. Ruşanu, O.-A. A Brain-Computer Interface for Controlling a Mobile Assistive Device by Using the NeuroSky EEG Headset and Raspberry Pi. In Proceedings of the 5th International Conference on Nanotechnologies and Biomedical Engineering, ICNBME 2021, Chisinau, Moldova, 3–5 November 2021; Tiginyanu, I., Sontea, V., Railean, S., Eds.; Springer International Publishing: Cham, Switzerland, 2022; pp. 231–238.
60. Bala, P.; Amob, R.; Islam, M.; Hasan, F.; Uddin, M.N. EEG—Based Load Control System for Physically Challenged People. In Proceedings of the 2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST), Dhaka, Bangladesh, 5–7 January 2021; pp. 603–606.

61. Alfredo, C.S.; Adytia, D.A. Time Series Forecasting of Significant Wave Height Using GRU, CNN-GRU, and LSTM. *J. RESTI (Rekayasa Sist. Teknol. Inf.)* **2022**, *6*, 776–781. [CrossRef]
62. Memmott, T.; Koçanaoğulları, A.; Lawhead, M.; Klee, D.; Dudy, S.; Fried-Oken, M.; Oken, B. BciPy: Brain–Computer Interface Software in Python. *Brain–Comput. Interfaces* **2021**, *8*, 137–153. [CrossRef]
63. Nieto-Vallejo, A.E.; Ramírez-Pérez, O.F.; Ballesteros-Arroyave, L.E.; Aragón, A. Design of a Neurofeedback Training System for Meditation Based on EEG Technology. *Rev. Fac. Ing.* **2021**, *30*, e12489. [CrossRef]
64. Sillas de Ruedas Eléctricas Con Motor (22 Productos) | Quirumed. Available online: <https://www.quirumed.com/es/ortopedia/sillas-de-ruedas/sillas-de-ruedas-electricas> (accessed on 8 January 2024).
65. Todos los Tipos de Sillas de Ruedas Ortopédicas Eléctrica. Available online: <https://www.ortopediamimas.com/movilidad/sillas-de-ruedas-electricas.html> (accessed on 8 January 2024).
66. Sillas de ruedas KARMA | Distribuidor y Fabricante 2019. Available online: <https://www.karmamobility.es/> (accessed on 21 February 2024).
67. Sillas de Ruedas Eléctricas de Todos Los Tipos—Ortopedia ITOMI. Available online: <https://www.ortopediaitomi.es/venta-articulos-ortopedia/movilidad/sillas-de-ruedas-electricas> (accessed on 8 January 2024).
68. Silla de ruedas MARTINIKA EVO, eléctrica plegable. Available online: <https://www.ortopediasilvio.com/es/sre-000-silla-de-ruedas-electrica/8783-177456-silla-de-ruedas-martinika-evo-electrica-plegable.html> (accessed on 8 January 2024).
69. Sillas de Ruedas, Grúas y Scooters Eléctricos. Available online: <https://www.sunrisemedical.es/> (accessed on 8 January 2024).
70. Valenti, A.; Barsotti, M.; Brondi, R.; Bacciu, D.; Ascari, L. ROS-Neuro Integration of Deep Convolutional Autoencoders for EEG Signal Compression in Real-Time BCIs. In Proceedings of the 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Toronto, ON, Canada, 11–14 October 2020.
71. MindWave. Available online: <https://store.neurosky.com/pages/mindwave> (accessed on 8 January 2024).
72. BrainLink Lite. Available online: [https://o.macrotellect.com/2020/BrainLink\\_Lite.html](https://o.macrotellect.com/2020/BrainLink_Lite.html) (accessed on 8 January 2024).
73. Rheinland, T. Ensayos de Sillas de ruedas y Scooters Eléctricos. Available online: <https://www.tuv.com/spain/es/ensayos-en-sillas-de-ruedas-y-scooters-el%C3%A9ctricas.html> (accessed on 8 January 2024).
74. ISO 7176; Wheelchairs: Requirements and Test Methods. Available online: <https://landingpage.bsigroup.com/LandingPage/Series?UPI=BS%20ISO%207176> (accessed on 8 January 2024).
75. UNE-EN 12182:2012; Productos de Apoyo para Personas con Discapacidad. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0050343> (accessed on 8 January 2024).
76. UNE-EN 12183:2012; Manual Wheelchairs—Requirements and Test Methods. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0054120> (accessed on 8 January 2024).
77. UNE-EN 12184:2012; Electrically Powered Wheelchairs, Scooters and Their Chargers—Requirements and Test Methods. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0054121> (accessed on 8 January 2024).
78. ISO 7176-14; Wheelchairs—Part 14: Power and Control Systems for Electrically Powered Wheelchairs and Scooters—Requirements and Test Methods. Available online: <https://www.iso.org/standard/72408.html> (accessed on 8 January 2024).
79. UNE-EN 60601-1:2008; Equipos electromédicos: Parte 1: Requisitos generales para la seguridad básica y funcionamiento esencial. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0041083> (accessed on 8 January 2024).
80. ISO 7176-21:2009; Wheelchairs—Part 21. Requirements and Test Methods for Electromagnetic Compatibility of Electrically Powered Wheelchairs and Scooters, and Battery Chargers. Available online: <https://www.iso.org/standard/51048.html> (accessed on 8 January 2024).
81. ISO 7176-19:2022; Wheelchairs—Part 19: Wheelchairs for Use as Seats in Motor Vehicles. Available online: <https://www.iso.org/standard/71919.html> (accessed on 8 January 2024).
82. UNE-EN 1021-1:2015; Mobiliario. Valoración de la Inflamabilidad. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0054530> (accessed on 8 January 2024).
83. UNE-EN ISO 13485:2018; Medical devices—Quality management systems—Requirements for regulatory purposes (ISO 13485:2016). (Consolidated Version). Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0060449> (accessed on 8 January 2024).
84. ISO 9001:2015(es); Sistemas de gestión de la calidad—Requisitos. Available online: <https://www.iso.org/obp/ui/#iso:std:iso:9001:ed-5:v1:es> (accessed on 8 January 2024).
85. Arribas, F. Normas Técnicas en Seguridad Robótica. 2017. Available online: <https://es.scribd.com/document/371727317/Robot-Norma> (accessed on 8 January 2024).
86. UNE-EN ISO 10218-1; Robots y Dispositivos Robóticos. Requisitos de Seguridad para Robots Industriales. Parte 1: Robots. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0049289> (accessed on 8 January 2024).
87. UNE-EN ISO 10218-2:2011; Robots y Dispositivos Robóticos. Requisitos de Seguridad para Robots Industriales. Parte 2: Sistemas Robot e Integración. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0048668> (accessed on 8 January 2024).
88. UNE-EN ISO 13482:2014; Robots y Dispositivos Robóticos. Requisitos de Seguridad para Robots no Industriales. Robots de Asistencia Personal no Médicos. Available online: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0053216> (accessed on 8 January 2024).

89. *ISO/TS 15066:2016*; Robots and Robotic Devices—Collaborative Robots. Available online: <https://tienda.aenor.com/norma-iso-ts-15066-2016-062996> (accessed on 8 January 2024).
90. 945-13450-0000-100 | JETSON NANO DEVELOPMENT KIT | RS. Available online: <https://es.rs-online.com/web/p/kits-de-desarrollo-de-procesadores/1999831> (accessed on 8 January 2024).

**Disclaimer/Publisher’s Note:** The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

Article

# Comparison of LSTM- and GRU-Type RNN Networks for Attention and Meditation Prediction on Raw EEG Data from Low-Cost Headsets

Fernando Rivas <sup>1,\*</sup>, Jesús Enrique Sierra-García <sup>2,\*</sup> and Jose María Camara <sup>2</sup><sup>1</sup> Department of Electromechanical Engineering, University of Burgos, 09006 Burgos, Spain<sup>2</sup> Department of Digitalization, University of Burgos, 09006 Burgos, Spain; checam@ubu.es

\* Correspondence: frivas@ubu.es (F.R.); jesierra@ubu.es (J.E.S.-G.)

**Abstract:** This study bridges neuroscience and artificial intelligence by developing advanced models to predict cognitive states—specifically attention and meditation—using raw EEG data collected from low-cost commercial devices such as NeuroSky and Brainlink. Leveraging the temporal capabilities of recurrent neural networks (RNNs), particularly long short-term memory (LSTM) and gated recurrent units (GRUs), the study evaluates their effectiveness in predicting future cognitive states. These predictions have applications in real-time brain–computer interface (BCI) systems, enhancing responsiveness and adaptability in dynamic environments like robotic control. The proposed LSTM model demonstrated superior predictive accuracy for meditation states, achieving a Root Mean Squared Error (RMSE) of 10.90, while the GRU model excelled in predicting attention states, with an RMSE of 11.79. Both models outperformed the results provided by the proprietary eSense algorithm, reinforcing the potential of raw EEG data in cognitive-state analysis. Notably, inference times were optimized to under 50 milliseconds, making the models suitable for real-time applications. These findings underline the feasibility of using raw EEG signals from affordable devices for robust real-time prediction, offering a significant step forward in applied neuroscience. This research lays the groundwork for further exploration of RNN architectures in BCI applications, enabling safer, more intuitive, and personalized interactions in assistive technologies and beyond.



Academic Editor: Luca Mesin

Received: 27 December 2024

Revised: 5 February 2025

Accepted: 7 February 2025

Published: 12 February 2025

**Citation:** Rivas, F.; Sierra-García, J.E.; Camara, J.M. Comparison of LSTM- and GRU-Type RNN Networks for Attention and Meditation Prediction on Raw EEG Data from Low-Cost Headsets. *Electronics* **2025**, *14*, 707. <https://doi.org/10.3390/electronics14040707>

**Copyright:** © 2025 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

**Keywords:** BCI/EEG; LSTM; GRU; deep learning; machine learning; RNN; NeuroSky; Brainlink

## 1. Introduction

Brain–computer interface technology has emerged as a transformative bridge between human cognition and external devices, offering promising solutions for applications ranging from assistive technologies to rehabilitation systems. A critical challenge in BCI development is the reliable detection and interpretation of cognitive states that can serve as robust control signals [1]. Among these states, attention and meditation have garnered particular interest due to their distinctive neurophysiological signatures and practical implications for BCI applications.

The importance of attention and meditation in BCI systems stems from several key factors. First, attention represents a fundamental cognitive mechanism that directly influences task performance, learning efficiency, and error prevention in human–machine interaction [2]. In BCI applications, attentional states can serve as natural control signals, as they can be voluntarily modulated by users and maintain stability over extended periods. Second, meditation states offer complementary advantages through their association

with enhanced signal-to-noise ratios in EEG readings and reduced cognitive interference, potentially improving BCI reliability [3].

Current commercial BCI systems, such as those utilizing NeuroSky technology, employ proprietary algorithms to detect these cognitive states. However, these closed systems present several limitations: lack of transparency in signal processing, inability to customize detection parameters for specific applications, and restricted adaptation to individual user characteristics [4]. These constraints have spurred research interest in developing open, adaptable alternatives that can advance both scientific understanding and practical applications.

EEG has proven particularly valuable for studying attention and meditation due to its high temporal resolution and ability to capture rapid cognitive state transitions [5]. Recent advances in EEG signal processing have demonstrated distinct neural signatures associated with diverse levels of attention and meditative states, particularly in the prefrontal cortex regions [6,7]. These findings suggest the potential for developing more sophisticated detection algorithms that can leverage these neural patterns for enhanced BCI control.

The integration of attention and meditation detection in BCIs has significant practical implications. In rehabilitation settings, accurate detection of attention levels can help optimize therapy sessions and provide objective measures of patient engagement [8]. For assistive technologies, meditation states can serve as stable control signals, particularly beneficial for users with limited motor control. These applications demonstrate the practical value of improving cognitive state detection in BCI systems.

The emergence of advanced machine learning techniques, particularly RNNs, offers new opportunities to address current limitations in cognitive state detection. LSTM and GRU networks have demonstrated particular promise in capturing temporal dependencies in EEG signals, yet their application to attention and meditation detection remains relatively unexplored [8].

### *1.1. Hypothesis and Contributions*

The central hypothesis of this study is that it is feasible to predict attention and meditation values derived from EEG signals using neural networks. This hypothesis is founded on the premise that the temporal and non-linear characteristics of EEG signals can be effectively captured and modeled by advanced neural architectures. Specifically, this study explores the applicability of these predictive models in accurately estimating the cognitive states of attention and meditation, which are essential for various human-computer interaction applications.

By addressing this hypothesis, the research aims to contribute to the growing body of knowledge on EEG signal processing and its integration with machine learning techniques. The outcomes of this investigation have significant implications for developing real-time applications in neurofeedback, cognitive training, and brain-computer interface systems, offering a pathway for improved user experiences and technological advancements in the field.

This research makes specific contributions to the field:

1. Development of LSTM and GRU architectures specifically optimized for real-time detection of attention and meditation states from raw EEG signals.
2. Empirical validation of these models' performance compared to existing proprietary solutions, with detailed analysis of accuracy, latency, and robustness.
3. Introduction of a new methodology for processing raw EEG data that enables greater customization and adaptation of BCI systems.
4. Demonstration of practical applications through case studies in assistive technology and rehabilitation contexts

Our approach addresses several critical limitations in current BCI systems. By working directly with raw EEG signals rather than preprocessed data, we enable greater transparency and customization possibilities. The use of advanced RNN architectures allows for better capture of temporal dynamics in cognitive-state transitions, potentially improving detection accuracy. Furthermore, our models' ability to operate in real-time makes them suitable for practical BCI applications.

This research not only advances our understanding of cognitive-state detection in BCI systems but also provides practical tools for improving human-machine interaction in critical applications. The combination of advanced machine learning techniques with raw EEG signal processing represents a significant step toward more adaptable and effective BCI systems.

### *1.2. Paper Structure*

The paper is structured as follows: Section 2 reviews related works in EEG signal processing and cognitive-state prediction. Section 3 details the materials and methods, including experimental setup, data acquisition protocols, and the architecture of our LSTM and GRU models. Section 4 presents results and validation metrics, while Section 5 discusses findings in relation to the existing literature. Finally, Section 6 concludes with key contributions and future research directions.

## **2. Related Works**

Neuroscience has experienced a boom in recent decades, especially in exploring the relationship between brain activity and cognitive states such as attention and meditation. EEG has established itself as an essential tool for capturing and analyzing the brain's electrical activity in real time. As technology advances, researchers have begun to decipher the brainwave patterns associated with sustained attention and meditative states, opening new possibilities for understanding the human mind. These advances not only offer insights into the fundamental nature of consciousness but also have the potential to influence practical applications, from improving cognitive performance to treating neurological disorders.

This article provides a more detailed and elaborate review of EEG-based attention and meditation prediction, incorporating the most recent publications.

In the past decade, the field of EEG has experienced significant advancements, revolutionizing our understanding of brain activity and its applications in various areas of neuroscience. Chaddad et al. (2023) presented a comprehensive review of EEG signal processing methods and techniques, encompassing everything from acquisition to classification and application [2,9]. This review highlights the inherent complexity of EEG signals and underscores the critical need to develop advanced preprocessing and feature extraction methods for their effective analysis. The complexity of these non-invasive signals has spurred researchers to propose innovative approaches to unravel the wealth of information contained in patterns of electrical brain activity. Concurrently, Posner (2023) examined the evolution of attention networks, proposing an integrative approach that combines human and animal studies to address unresolved problems in this field [3]. His work emphasizes the fundamental importance of attention networks in integrating cognitive and neural studies, laying the groundwork for significant advances in cognitive neuroscience. This integrative perspective promises to unveil the mechanisms underlying complex attentional processes and their relationship to other higher cognitive functions.

The integration of emerging technologies with traditional EEG techniques has opened new avenues of research, expanding our understanding of brain processes in more natural and ecologically valid contexts. An innovative 2019 study explored the connections between creative behavior, flow state, and brain activity through the integration of EEG and virtual

reality [4]. This research revealed significant correlations between individual creativity levels, flow state, and the quality of creative output, providing valuable insights into the neural substrates of creativity and focused attention. In the realm of meditation, several studies have utilized EEG to investigate the effects of different techniques on brain activity and cognitive performance. A 2022 retrospective analysis compared “internal” versus “external” meditation techniques, shedding light on the relative efficacy of different meditative approaches [5]. Complementarily, a 2020 longitudinal study provided direct evidence of the effectiveness of Focused Attention Meditation (FAM) training in modulating brain activity and improving cognitive performance [6], underscoring the potential of meditative practices in optimizing brain functions.

The convergence of EEG with other emerging technologies has significantly broadened the horizon of neuroscientific research. An innovative 2021 project combined EEG with a brainwave lamp to study real-time attention, meditation, and fatigue values [10], opening new possibilities for monitoring and modulating mental states in various contexts. This multidisciplinary approach not only allows for a more holistic assessment of cognitive and emotional states but also offers promising perspectives for applications in areas such as mental health and cognitive performance. Furthermore, a pioneering 2021 study revealed a significant reorganization of brain network connectivity following intensive meditation training [11]. This research identified changes in key areas such as the right insula, superior temporal gyrus, inferior parietal lobe, and bilateral superior frontal gyrus, providing neurobiological evidence of the long-term effects of meditative practice on the brain’s functional architecture. These collective advances not only demonstrate the immense potential of EEG in understanding brain processes but also lay the foundation for revolutionary applications in various fields of neuroscience, biomedical engineering, and personalized medicine, promising to transform our understanding of the human brain and its functioning in states of health and disease.

These publications provide an in-depth and up-to-date overview of research and advances in the field of EEG-based attention and meditation prediction. The combination of advanced signal-processing techniques, together with innovative approaches to measuring and analyzing attention and meditation, is leading to significant discoveries that may have practical applications in areas such as mental health, education, and general well-being.

One of the primary limitations identified in the current literature is the widespread dependence on NeuroSky’s proprietary algorithm for interpreting EEG signals. This algorithm, designed to determine values such as attention and meditation, has been widely used in numerous studies. For instance, the research conducted by Ruşanu et al. (2023) [8] that developed a LabVIEW instrument for brain–computer interface research using the NeuroSky MindWave Mobile headset does not specify whether it relied on NeuroSky’s algorithm for determining certain values. This dependence on a proprietary algorithm raises questions about the reproducibility and comparability of results across different studies, as well as the flexibility in interpreting EEG data for specific applications.

Another significant limitation of the NeuroSky/Brainlink headband lies in its precision and resolution compared to medical-grade or laboratory EEG systems. As a low-cost device designed for the consumer market, the NeuroSky headband may not offer the same level of fidelity in signal acquisition as more expensive professional equipment. This discrepancy in data quality can have important implications for research, especially in studies that require high precision in measuring brain activity. The limitation in spatial resolution, due to the reduced number of electrodes, also restricts the ability to accurately localize sources of neural activity, which can be crucial in certain cognitive and clinical neuroscience applications.

A significant gap in the current literature is the scarcity of research specifically focusing on the use of raw signals from the NeuroSky headband to determine mental states such as attention and meditation [12]. Many studies rely on NeuroSky's algorithm-processed data, limiting the exploration of raw EEG signals' full potential. This research addresses this gap by using RNNs, specifically LSTM and GRU models, to analyze raw EEG data. These architectures are ideal for time series like EEG signals, capturing complex patterns and long-term dependencies [13].

By bypassing the proprietary algorithm, this approach enhances flexibility in data interpretation, uncovering patterns and mental states that NeuroSky's algorithm might overlook. Analyzing raw data also enables the development of personalized models for attention and meditation, tailored to specific applications.

LSTM and GRU networks are particularly effective in handling EEG's sequential nature. LSTMs retain relevant information over time, while GRUs efficiently update internal states, making them well-suited to detect subtle brain activity patterns linked to cognitive states.

Additionally, deep learning techniques like RNNs can identify new features and relationships in EEG data, offering insights into brain signals and cognitive states [14]. This could reveal biomarkers for neurological or psychological conditions while improving result interpretability compared to NeuroSky's opaque "black box" algorithm.

Despite the hardware limitations of devices like the NeuroSky headband, advanced signal processing and RNN-based models improve the functional resolution of data, enabling more precise brain-activity inferences. This enhances the headband's utility and broadens its application to areas like cognitive neuroscience, clinical psychology, and advanced brain-computer interfaces.

This innovative approach not only addresses the current limitations of the NeuroSky headband but also paves the way for more sophisticated and nuanced analyses of EEG data in general. By leveraging the power of deep learning and working directly with raw signals, researchers can potentially uncover subtle patterns and relationships in brain activity that were previously inaccessible. This could lead to breakthroughs in our understanding of cognitive processes, emotions, and various neurological conditions.

Furthermore, the development of custom RNN-based models for EEG analysis could have far-reaching implications beyond the specific context of the NeuroSky headband. The methodologies and insights gained from this research could be applied to other EEG devices and even to more complex multi-channel EEG systems, potentially revolutionizing the field of brain signal analysis.

In conclusion, while the NeuroSky headband has already made significant contributions to democratizing EEG research, the proposed approach of using RNNs to analyze raw signals represents a crucial next step in unlocking its full potential. Although our system is trained with the results of the headset's own algorithm, the key contribution is in the ability to predict future states of attention and meditation. This extends the functionality of BCI systems, allowing them to anticipate user needs and improve interaction with external devices [14]. This predictive modeling based on recurrent neural networks opens new pathways for real-time applications, such as BCI-controlled robotic arms or wheelchair systems, where immediate response to cognitive states is crucial to ensure above all user safety.

The summary of related works is shown in Table 1.

**Table 1.** Summary of related work in EEG-based cognitive-state prediction.


Reference	Focus Area	Methods/Techniques	Key Results	Contributions
Chaddad et al. (2023) [15]	EEG signal-processing methods	Comprehensive review of preprocessing and feature extraction	Identified critical preprocessing techniques for robust EEG analysis	Provided a foundation for understanding preprocessing challenges in EEG studies
Posner (2023) [3]	Evolution of attention networks	Human and animal studies' integration	Highlighted the role of attention networks in cognitive integration	Introduced frameworks to understand attention mechanisms
Yang et al. (2019) [4]	EEG and virtual reality for creativity	EEG combined with virtual reality for flow state analysis	Correlated creativity and brainwave patterns during flow states	Pioneered studies linking EEG signals to creativity and attention dynamics
Yoshida et al. (2020) [6]	Meditation and cognitive performance	FAM with EEG longitudinal study	Demonstrated FAM's effect on improving neural activity and attention	Validated meditation's role in enhancing cognitive performance
Shrestha et al. (2023) [16]	EEG signal classification for disabilities	Deep learning applied to classify EEG signals from low-cost devices	Achieved high classification accuracy for EEG signals based on stimuli	Opened avenues for developing assistive communication systems
Ruşanu et al. (2023) [8]	Real-time EEG data processing	LabVIEW for EEG signal acquisition and neural network classification	Enabled real-time EEG signal classification using low-cost devices	Improved accessibility to real-time EEG-based BCI applications
Mathur et al. (2018) [17]	Directional EEG signal classification	LSTM and attention mechanisms for EEG signal classification	Demonstrated efficacy of deep learning models for classifying brain signals	Advanced methods for interpreting raw EEG data using neural networks
Bréchet et al. (2021) [11].	Meditation and EEG microstates	Digital meditation training with EEG	Showed reconfiguration of EEG networks post meditation training	Explored EEG network adaptations to meditation
Permana et al. (2019) [18].	EEG-based BCI for wheelchair control	NeuroSky MindWave Mobile applied to BCI	Demonstrated feasibility of EEG-based control for assistive devices	Validated low-cost EEG devices for practical BCI implementations

### 3. Technologies

#### 3.1. NeuroSky

The NeuroSky headband has emerged as a revolutionary tool in the field of EEG signal acquisition, offering an accessible and versatile alternative to traditional medical-grade EEG systems. Despite its relative simplicity, this device has proven invaluable in a wide range of research and development applications.

Figure 1 shows the location of the EEG potential signal capture points in a healthy brain.




**Figure 1.** Functional areas of the cerebral cortex where we can capture the raw signal [19].

The brain signals and frequency ranges captured by NeuroSky are shown in Table 2.

**Table 2.** Signals and frequency ranges captured by NeuroSky.

Wave Type	Characteristics	Values (Frequency and Voltage)
Delta wave:	Typical of infancy, children under 3 months of age. Phase III of physiological sleep, its contribution in adults must be considered abnormal.	a 4 Hz Greater than 50 $\mu$ V
Theta wave:	Located in the fronto-central area. If the signal is less than 15 $\mu$ V, it can be considered abnormal, unless it is accompanied by a good Alpha-wave rhythm. Phase I and II of physiological sleep and during hyperventilation and/or fatigue.	4 a 7 Hz Greater than 40 $\mu$ V
Low Alpha wave:	Located in occipital area. If it maintains an asymmetry of more than 50%, it can be considered abnormal.	8 to 12 Hz 15 $\mu$ V
High Alpha wave:		
Low Beta wave:	Predominates in periods of wakefulness. Appears in states where attention is directed to external cognitive tasks. Fast frequency; it is present when we are attentive and focused on solving everyday tasks or making decisions.	Beta 1 (12 to 15 Hz) Beta 2 (15 to 22 Hz) Beta 3 (22 to 30 Hz)
High Beta wave:		
Low Gamma wave:	These are the fastest frequency waves and occur in short bursts. They are related to central nervous-system tasks. It is observed in brain processes of high resolution and intensity, high brain activity.	25 a 100 Hz
High Gamma wave:		

In the following figure, Figure 2, we can see the typical typology of these signals based on their frequency and waveform.



**Figure 2.** Brainwave typology I (source NeuroFeedBack) [20].

Its ability to provide raw EEG data has opened new avenues of research and democratized access to applied neuroscience. A pioneering study conducted in 2022 by Vasilescu et al. illustrates the potential for integrating the NeuroSky headband with advanced data acquisition and processing systems [8]. The researchers developed a series of LabVIEW applications that enable real-time acquisition, processing, feature extraction, and classification of EEG signals detected by the integrated sensor of the NeuroSky MindWave Mobile headset. This innovative approach not only enhances the accessibility of EEG data but also facilitates its real-time analysis, opening new possibilities for research in BCI.

The versatility of the NeuroSky/Brainlink headbands is further evidenced by its application in diverse research fields. A study conducted by Mohd Amin et al. in 2020

explored the use of the NeuroSky Smarter Kit in a brain training program for the elderly [21]. That research focused on analyzing changes in attention and meditation levels, providing valuable insights into how EEG technology can contribute to improving cognitive health in ageing populations. Concurrently, an innovative 2023 study by Shrestha et al. leveraged the capabilities of the NeuroSky headband to classify EEG signals based on color stimuli [16]. Using a deep neural network based on attention, the researchers successfully classified raw EEG signals from the NeuroSky MindWave headset based on two and four different colors.

The NeuroSky’s proprietary algorithm, known as the eSense algorithm, is designed to compute values for attention and meditation by analyzing specific EEG signal components. For attention, the algorithm primarily focuses on the power ratio of high and low Beta waves, which are associated with active cognitive engagement. For meditation, it combines Alpha waves, linked to relaxation, with Theta waves, often indicative of a meditative or drowsy state. Figure 3 shows typical attention and mediation signals. Figure 4 shows the brain points for the calculation of attention and meditation based on signals from the prefrontal area of the brain, identified as point FP1 and FP2.




Figure 3. Brainwave typology II (source NeuroFeedBack) [22].




Figure 4. FP1 and FP2 electrode selected position for capturing raw data (source ResearchGate) [23].

While the eSense algorithm is effective in providing an estimation of these cognitive states, its proprietary nature poses certain limitations. These include restricted transparency in signal processing, limited adaptability to specific applications, and an inability to customize parameters for individual users. Our study addresses these limitations by using raw EEG data and advanced neural network models, offering a more transparent and flexible approach to cognitive-state prediction.

The practical application of NeuroSky technology in assisting people with physical disabilities is evident in the project developed by Sathyanarayanan et al. in 2021 [24]. This brain-controlled EEG system for home automation, specifically designed to aid individuals with physical disabilities and paralysis, achieved an impressive 90% accuracy in detecting attention levels [14]. These results underscore the transformative potential of accessible EEG technology in improving the quality of life for vulnerable populations. Complementing these advancements, an earlier study by Mathur et al. in 2018 explored the classification of EEG-based directional signals using RNN variants [17]. The researchers implemented a sophisticated model using long short-term memory with an attention layer to classify both raw EEG signals and power signals generated by the NeuroSky MindWave device. This approach not only demonstrates the versatility of the data provided by the NeuroSky headband but also illustrates how advanced deep learning techniques can extract meaningful information from these signals, thus expanding the horizon of potential applications in fields such as cognitive neuroscience, human–machine interaction, and neurological rehabilitation.

These studies demonstrate the versatility and applicability of the NeuroSky headset in a variety of research areas, from brain–computer interface to color-based signal classification and home automation. Despite the inherent limitations of a low-cost, single-channel device, researchers have found innovative ways to use it to achieve significant results in their respective fields.

### 3.2. Predictive Deep Learning Models

In this work, we explore the ability of LSTM and GRU networks to predict attention and meditation signals. LSTM and GRU networks have shown promising results in capturing long-term dependencies and modeling temporal dynamics in sequential data, including EEG signals. These models have been successfully applied in various cognitive state-prediction tasks [25].

LSTM networks are advanced recurrent neural networks designed to handle sequential data by addressing the vanishing-gradient problem. As illustrated in Figure 5, each LSTM cell includes three key gates: the input gate, which controls new information entering the cell; the forget gate, which discards unnecessary information; and the output gate, which forwards relevant information to the next step. This gating system allows LSTMs to manage long-term dependencies effectively, making them ideal for processing EEG signals in our BCI project.

GRU networks represent a simplified and highly efficient variant of recurrent neural networks, designed to capture long-term dependencies in sequential data. As illustrated in Figure 6, a GRU unit comprises two primary gates: the update gate, which determines what portion of the previous information is retained, and the reset gate, which controls how much past information is forgotten. This simpler structure, compared to LSTMs, allows GRUs to process data sequences efficiently whilst maintaining the ability to capture complex temporal relationships, making them particularly suitable for EEG signal analysis in our BCI project.




Figure 5. LSTM diagram.

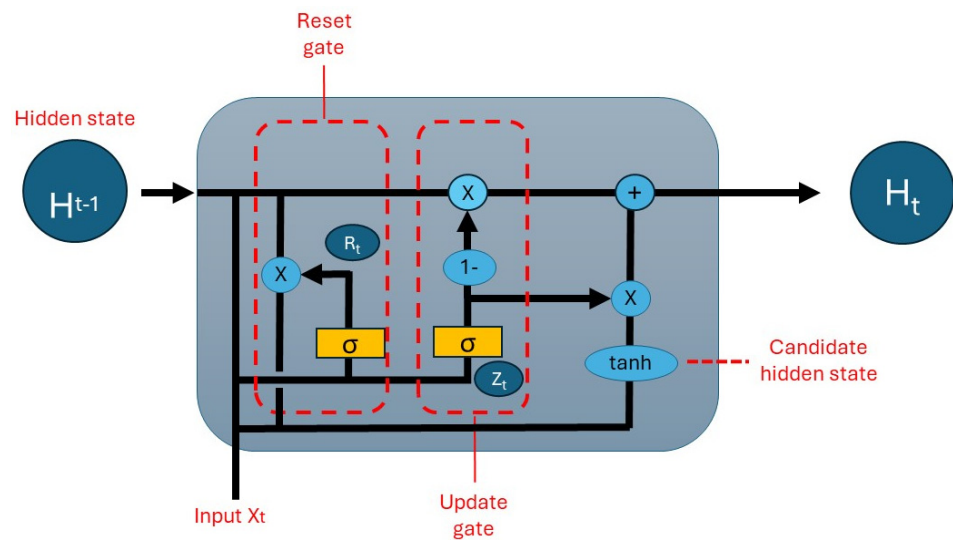


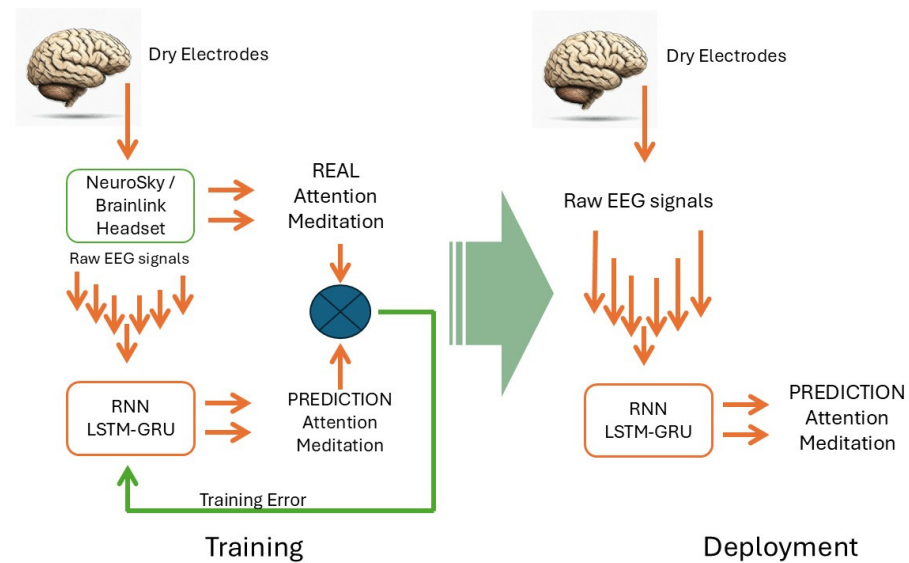
Figure 6. GRU diagram.

In the context of our research, GRUs are employed to analyze and classify patterns in EEG signals, a crucial step in translating neural activity into commands for assistive technologies. The GRU’s ability to learn and recognize temporal patterns in EEG data, corresponding to specific neural activities or intentions, is fundamental to the system’s accuracy and responsiveness. This makes GRU networks an essential component of our BCI framework, facilitating a seamless transition between raw EEG signals and actionable outputs in assistive devices. Their integration into our system not only exemplifies cutting-edge neural-processing technologies but also establishes a solid foundation for future advancements in intuitive human–machine interaction within the field of BCIs.

#### 4. Use-Case Architecture

The use-case architecture is shown in Figure 7. The EEG signals are recorded using commercial headsets (NeuroSky/Brainlink) equipped with dry electrodes, capturing brain activity from the prefrontal cortex. These raw signals, containing information from frequency bands such as delta, theta, alpha, and beta, form the input for the neural networks.

The target data used to train the neural networks are the attention and meditation signals computed by the patented algorithm of NeuroSky. This algorithm is patented and protected by NeuroSky and is not freely available.



**Figure 7.** Use-case architecture.

The aim of the neural network is to replicate the outputs of the patented algorithm. This way the attention and meditation signals will be able to be used in low cost BCIs without these capabilities. The right side in Figure 7 shows the deployment of the neural network. It is shown that whatever low cost BCI can be used. NeuroSky is not needed.

This process ensures that the predictive framework remains both flexible and adaptive. By relying on raw EEG signals rather than the fixed outputs of proprietary algorithms, the architecture achieves greater transparency and adaptability. Furthermore, the use of RNNs allows the system to effectively capture the temporal dependencies within the data, resulting in more accurate and dynamic predictions of cognitive states. This design not only addresses existing limitations in EEG-based systems but also ensures its applicability across diverse real-world scenarios.

## 5. Methodology

The process to record the dataset, analyze, and organize the information, and train the neural models is divided into the following steps:

- Experimental setup: Dataset are recorded following a standardized procedure.
- Feature sets: considering the information captured in the dataset different feature sets are identified.
- Data preprocessing: data are converted into a structure suitable for a time series, as needed to train networks.
- Training: Data are separated into training and validation sets. RandomSearch is used to find the best hyperparameters.
- Cross-validation: Cross-validation is used to validate that results are consistent regardless of the subsets in the dataset are considered.

### 5.1. Experimental Setup

The study employed a structured data collection approach spanning 6 months (June 2023–December 2023). Data were collected from 5 participants (3 male, 2 female, age range of 21–60 years) using both NeuroSky and Brainlink headsets.

Participants were selected based on the following:

- No history of neurological disorders,
- Normal or corrected-to-normal vision,
- No prior experience with BCI devices.

Recording sessions:

- Two 30-min recording sessions separated by one week,
- Controlled environment settings (22 °C ( $\pm 1$ ), 45 dB ambient noise),
- Talks included free-cognitive-state periods ( $\geq 10$  min).

Each subject performed the experiments in two sessions separated by several days to ensure reproducibility of the results [26]. Subsequently, the signals from the different subjects were also incorporated into a continuous dataset in order to achieve a sufficient volume of information to guarantee the training process of the LSTM and GRU network.

The age range varies between 21 and 60 years, trying to maintain gender parity. The participants' data are anonymized, being collected with a consecutive trial number that does not allow for the identification or association of the data with the participant in the trials. It should be noted that, in male adults close to 60 years of age, the process of reading the data in some cases has become unfeasible, as no data can be obtained from the prefrontal region of the subjects, indicating that the use of non-invasive dry electrodes in this case may be a barrier to consistent data capture.

Experiments were conducted in a controlled environment to minimize external distractions. A NeuroSky device and a Brainlink device were used to record EEG signals, as both devices have the same TGAM-based technology.

During the experiments, participants were asked to act naturally, trying to voluntarily maintain high levels of attention and concentration, according to the real-time values that could be seen in the data-capture application.

The data acquisition process was carefully designed to ensure both the authenticity of the collected signals and the comfort of the participants. To closely replicate real-world conditions, participants were given the freedom to engage in any activity of their choice during the sessions, such as watching films, chatting, reading, or simply relaxing. This approach aimed to capture a diverse range of natural cognitive states while minimizing action bias that could otherwise influence the data and limit their generalizability.

The duration of each session was set between 15 and 30 min, providing an optimal balance between data quantity and participant comfort. Given that the EEG headset records one block of data per second, this setup resulted in a minimum of 900 and up to 1800 data points per session, with each block containing 11 signal values. This design ensured that the dataset was both extensive and reflective of natural behavioral conditions, supporting the development of models robust enough to handle dynamic real-life environments.

## 5.2. Features Sets

The dataset captured during the experiments contains the following columns:

1. Timestamp: Timestamp of the capture.
2. Attention: Attention value.
3. Meditation: Meditation value.
4. Delta, Theta, low Alpha, high Alpha, low Beta, high Beta, low Gamma, and high Gamma: Values of the brain signals.
5. Signal: This column indicates the quality of the signal. In general, a value of 0 indicates a good signal quality, while higher values indicate a poor signal quality or no signal.


NeuroSky's patented algorithm uses Beta signals to compute the attention, and Alpha and Theta to compute meditation. Thus, we have created two different sets of features.

In the complete set, all signals are simultaneously used as inputs to predict the attention and meditation levels. In the partial feature set, only the signals used by the protected algorithm are used. Table 3 shows the relation between input and output signals in each feature set.

**Table 3.** Feature sets according to input signals.

Feature Set	Input Signals	Output Signals
Complete	Delta, Theta, low Alpha, high Alpha, low Beta, high Beta, low Gamma, high Gamma	Attention, meditation
Partial	Low Beta, high Beta, low Gamma, high Gamma, Theta, low Alpha, high Alpha	Attention Meditation

Figure 8 shows the attention and meditation data, together with the brain signals, during one of the experiments. Some signals, such as Delta, show much higher values compared to other signals. Attention and meditation signals show fluctuations over time, indicating changes in the levels of attention and meditation.



**Figure 8.** Brain signals obtained with Brainlink headset.

### 5.3. Data Preprocessing

The EEG data underwent a series of carefully designed preprocessing steps to prepare them for training the LSTM and GRU networks. Initially, the raw signals were assessed for quality using the headset's internal metrics, and any segments with poor signal quality were excluded to minimize the impact of noise or artefacts. The remaining data were then normalized to a standard range from 0 to 1, ensuring consistent scaling and facilitating stable model training. To capture the temporal dependencies inherent in EEG signals, the data were organized into sliding look-back windows, where a fixed number of prior time steps (tested with sizes of 3, 5, 7, and 15) were used as input for predicting subsequent values.

### 5.4. Data Training

The dataset was split into training (65%) and testing (35%) subsets, allowing for robust model evaluation and generalizability testing:

- Training set with 1118 records (65%),
- Test set with 602 records (35%).

We used RandomSearch to determine the best hyperparameters and architecture. As part of the RandomSearch process, several hyperparameters were systematically varied to identify the optimal configuration for the LSTM and GRU models. Table 4 provides a comprehensive summary of the hyperparameters explored, including their respective ranges and the best values determined through the experiments. This optimization process was crucial for enhancing model performance and ensuring robust predictions.

**Table 4.** Hyperparameter ranges and optimal values for LSTM and GRU model.

Hyperparameter	Range Explored	Description
LSTM units	[4, 8, 16, 32, 64]	Number of units in the LSTM layer. Optimized to balance capacity and computational efficiency.
GRU units	[4, 8, 16, 32, 64]	Number of units in the GRU layer. Selected to balance accuracy and efficiency.
Batch size	[1, 5, 10, 20]	Number of samples processed before updating the model. Smaller values reduce overfitting risk.
Optimizer	"adam", "rmsprop", "sgd"	Algorithm used to optimize the model's parameters. Adam performed best for both attention and meditation.
Dropout rate	[0.01, 0.1, 0.2, 0.3, 0.4]	Regularization applied to prevent overfitting during training.
Look-back window	[3, 5, 7, 9, 15, 30, 60, 100]	Number of previous time steps used as input to predict the next value.

These hyperparameters were optimized separately for attention and meditation datasets, with consistent performance improvements observed for both.

### 5.5. Cross-Validation

Cross-validation is a vital step in machine learning to ensure that a model performs reliably and is not overly tailored to a specific dataset. This approach ensures that the model is evaluated on different subsets of data, improving its reliability and reducing the bias that might occur if a single train–test split was used. By dividing the data into training and testing subsets, it helps validate the model's ability to generalize, providing confidence that it will work effectively in real-world scenarios.

To evaluate the performance and generalizability of the LSTM and GRU models, we employed a k-fold cross-validation approach with  $k = 5$ , using the values of the hyperparameters obtained in the previous RandomSearch process. This methodology ensures robust performance evaluation while minimizing the risk of overfitting. The process is described as follows:

- **Dataset partitioning:**  
The dataset was randomly shuffled and divided into 5 equally sized folds. At each iteration, 1 fold was used as the test set, while the remaining 4 folds were combined to form the training set.
- **Training and validation:**  
The models were trained on the training set and evaluated on the test fold. This process was repeated 10 times, with each fold serving as the test set once. For each fold, we recorded metrics such as RMSE, MSE, and MAE to measure prediction accuracy.
- **Performance aggregation:**  
After completing the 10 iterations, the evaluation metrics were averaged across all folds to obtain a reliable estimate of the model's performance.

### 5.6. Performance Evaluation Metrics

To evaluate the performance of the LSTM, GRU, and CNN models in calculating attentional and meditative states, metrics such as RMSE, MSE, MAE, and SMAPE were used. These metrics are essential to determine the accuracy and reliability of the models in predicting cognitive states from EEG signals. The choice of these metrics is based on previous studies that have demonstrated their effectiveness in evaluating deep learning models in EEG-based prediction tasks [27].

In the context of interpreting the performance of a neural network, the choice of the appropriate metric depends on the specific problem and the characteristics of the data. The mentioned metrics (MAE, MSE, RMSE, and SMAPE) have different properties and are applied in different situations. A detailed and well-argued justification for each is provided below:

#### 1. Mean Absolute Error (MAE)

**Definition:** The MAE is the mean of the absolute values of the errors between predictions and actual values [28].

MAE Formula (1):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

where

$n$  is the number of observations,

$y_i$  is the actual value,

$\hat{y}_i$  is the predicted value.

**Advantages:**

- It is easy to interpret, as it represents the average error in the same units as the data.
- It is robust to outliers, as it does not penalize large errors as much as the MSE.

**Disadvantages:**

- It is not differentiable at all points, thus potentially complicating its use in some optimization algorithms.

#### 2. Mean Squared Error (MSE)

**Definition:** The MSE is the Mean Squared Error between predictions and actual values [28].

MSE Formula (2):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

where

$n$  is the number of observations,

$y_i$  is the actual value,  
 $\hat{y}_i$  is the predicted value.

Advantages:

- It penalizes large errors more heavily, which can be useful if you want to avoid large deviations.
- It is always differentiable, which facilitates its use in neural network optimization.

Disadvantages:

- It is more sensitive to outliers, as large errors have a quadratic impact on the metric.

### 3. Root Mean Squared Error (RMSE)

Definition: The RMSE is the square root of the MSE [28].

RMSE Formula (3):

$$\text{RMSE} = \sqrt{\text{MSE}} \rightarrow \text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

where

$n$  is the number of observations,

$y_i$  is the actual value,

$\hat{y}_i$  is the predicted value.

Advantages:

- Similar to MSE in terms of penalizing large errors but returns errors in the same units as the original data, which can be more intuitive.
- Useful when a metric is needed that reflects the magnitude of errors more directly than MSE.

Disadvantages:

- Shares the same sensitivity to outliers as the MSE.

### 4. Symmetric Mean Absolute Percentage Error (SMAPE)

Definition: SMAPE is a percentage error metric that is symmetric: it treats overestimation and underestimation errors equally [29,30].

SMAPE Formula (4):

$$\text{SMAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{(|A_t| + |F_t|)/2} \quad (4)$$

where

$A_t$  is the actual value,

$F_t$  is the forecast value,

$n$  is the total number of observations.

Advantages:

- It provides a relative measure of error, which can be useful when comparing errors on different scales.
- It is symmetrical, which makes it suitable for cases where relative errors are to be treated equally.

Disadvantages:

- It can be unstable when actual values or predictions are close to zero, due to splitting.

Final recommendation:

The choice of the most recommendable metric depends on the specific context:

MAE is recommended when an easy-to-interpret metric is needed and the impact of outliers is to be minimized.

MSE and RMSE are useful when you want to penalize larger errors more. RMSE is especially recommended if you need a metric in the same units as the data.

SMAPE is preferable when a relative and symmetric metric is needed, especially in problems where the data may vary in magnitude.

In general, for most neural network regression problems, RMSE is usually the most recommended metric because of its balance between penalizing large errors and easy interpretability in the units of the original data. However, the final selection should consider the specific characteristics of the problem and the objectives of the analysis.


## 6. Results

To assess the accuracy and efficacy of these models, performance metrics were selected, as well as cross-validation techniques to ensure the robustness of the models. This comparison methodology is essential to discern the relative strengths and weaknesses of LSTM and GRU networks in the task of prediction from EEG data, thus enabling a comprehensive assessment of their applicability in neurofeedback and BCI contexts [31]. The evaluation metrics RMSE, MSE, MAE, and SMAPE validate the results, being in line with the results provided by the previous literature on deep learning model evaluation methodologies [32].

For the computational process and calculation of values and metrics with the RandomSearch method, Google Sandbox and Google Colab were used to facilitate a significant reduction in operating times, after selecting the GPU configuration necessary to optimize the process in its execution environment. Python 3.10.11(64-bits) was used as the programming language.

### 6.1. LSTM Performance

In the following figures, Figures 9 and 10, the complete LSTM model validation process can be observed, as well as the metric values and the optimal hyperparameters for these metric values.



**Figure 9.** Hyperparameter calculation with LSTM model for attention values.

The first analysis performed was the calculation of attention and meditation using the same calculation scheme followed by NeuroSky and Brainlink, segmenting the neural signals and discarding the Delta signal value. The first comparison process was performed for the attention and meditation values using an LSTM network and RandomSearch for the determination of the hyperparameters, as shown in Table 5 for the attention values and Table 6 for the meditation values.




Figure 10. Hyperparameter calculation with LSTM model for meditation values.

Table 5. Attention prediction with LSTM model, using the partial feature set.

LSTM Attention								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0.01	18.440895	520.61426	22.816973	46.424299
3	8	1	Adam	0.01	16.443464	390.06958	19.75018	44.18967
5	64	10	Adam	0.1	17.237684	444.3844	21.080427	45.00878
7	8	1	Adam	0.01	17.011745	418.7853	20.464245	44.6055114
9	8	1	Adam	0.01	17.269892	450.35944	21.221674	45.212623
12	32	5	Adam	0.2	18.437788	522.3067	22.85403	46.92971
15	16	1	rmsprop	0.2	18.791443	526.82117	22.952585	48.3881175
60	8	1	Adam	0.01	19.565895	558.27045	23.627747	51.152211
100	64	1	Adam	0.3	21.289196	666.65015	25.819569	53.5422564

Table 6. Meditation prediction with LSTM model, using the partial feature set.

LSTM Meditation								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0.01	12.93792	248.0195	16.34073	26.07285
3	8	1	Adam	0.01	9.74729	152.81094	12.361672	20.292328
5	8	1	Adam	0.01	9.730363	153.521	12.390359	20.3964844
7	16	5	Adam	0.01	9.932504	160.70638	12.677002	20.925404
9	16	5	Adam	0.01	11.080525	194.34912	13.940915	22.482206
12	16	5	Adam	0.01	9.750857	153.20485	12.377595	20.5961972
15	16	5	Adam	0.01	10.855734	167.29128	13.68544	22.5330263
60	8	1	Adam	0.01	13.085041	263.2616	16.225338	26.387578
100	8	1	Adam	0.01	9.309048	137.05049	11.706857	20.1372519

The same process as above, but in this case, with the analysis of 100% of the values of the neural signals obtained from the headband, without replicating the procedure followed by the NeuroSky company, is shown below in Tables 7 and 8.

Table 7. Attention prediction with LSTM, using the complete feature set.

LSTM Attention								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0.01	12.770439	252.98478	15.905495	36.03656
3	8	1	Adam	0.01	10.93788	180.85922	13.448391	38.268446
5	8	1	Adam	0.01	11.117896	185.6015	13.623564	40.6224002
7	8	1	Adam	0.01	9.586014	146.60876	12.1082411	34.657588
9	32	20	Adam	0.1	10.250811	166.4137	12.900144	32.837361
12	16	1	rmsprop	0.2	10.234032	162.91768	12.76921	39.718466
15	4	10	Adam	0.01	12.086856	219.6982	14.8222	77.626531
60	4	10	Adam	0.01	10.679445	170.31284	13.050396	37.424832
100	32	20	Adam	0.1	13.549226	270.00806	16.431921	59.413784

**Table 8.** Meditation prediction with LSTM, using the complete feature set.

LSTM Meditation								
Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	64	1	Adam	0.01	13.012856	266.65714	16.32964	26.2508482
3	8	1	Adam	0.01	9.405639	139.42348	11.807772	19.6614996
5	8	1	Adam	0.01	9.011736	122.980484	11.089657	19.215181
7	8	1	Adam	0.01	8.75148	118.901115	10.904179	18.5926675
9	8	1	Adam	0.01	9.703162	144.41208	12.017158	20.2926966
12	16	5	Adam	0.01	9.390194	136.74336	11.693731	19.839185
15	16	5	Adam	0.01	11.352932	205.39166	14.331492	23.227106
60	16	5	Adam	0.01	13.8042	286.8171	16.935675	28.2309085
60B	4	10	Adam	0.01	10.759749	189.46066	13.794471	23.1912166
100	8	1	Adam	0.01	11.555381	208.5672	14.44185	24.088779

6.2. GRU Performance

The same process was performed, but using a GRU network and the RandomSearch calculation structure, as shown in Table 9 for the prediction of attention and Table 10 for the value of meditation.

**Table 9.** Attention prediction with GRU model, using partial feature set.

GRU Attention								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0.01	18.205666	498.30548	22.342758	46.277722
3	8	1	Adam	0.01	16.537975	391.97757	19.798424	44.8215187
3B	8	1	Adam	0.01	16.757694	409.6622	20.240114	45.133781
5	8	1	Adam	0.01	16.450132	394.23697	19.855402	43.7501669
7	8	1	Adam	0.01	16.665699	400.61368	20.015337	45.749473
9	4	10	sgd	0.2	14.613	368.0468	19.1845	29.7287
9B	8	1	Adam	0.01	16.847183	423.59082	20.581322	46.538028
12	8	5	Adam	0.2	17.409185	442.0205	21.024284	46.35398
15	16	5	Adam	0.01	17.239313	477.5919	21.853876	45.865431
60	8	1	Adam	0.01	17.830471	503.54346	22.439774	50.804883
60B	64	10	Adam	0.1	20.124237	652.8454	25.55084	57.5832188
60C	4	10	Adam	0.1	13.5327	297.3851	17.2449	26.5076
100	4	10	Adam	0.01	19.392126	590.4532	24.299242	54.391807
100B	8	1	Adam	0.01	19.640924	585.0889	24.188612	52.710318

**Table 10.** Meditation prediction with GRU model, using partial feature set.

GRU Meditation								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0.01	12.695457	257.61722	16.050459	25.7325947
3	64	20	Adam	0.01	9.669626	153.72371	12.3985	20.1065033
3B	8	1	Adam	0.01	9.377201	142.39085	11.932764	19.491779
5	8	1	Adam	0.01	10.554417	178.80147	13.371667	21.483133
7	64	20	Adam	0.01	9.94037	161.12167	12.693371	20.752151
9	64	1	Adam	0.3	11.3582	215.1325	14.6674	21.554
9B	64	20	Adam	0.01	10.049313	163.75613	12.7967	20.726409
12	16	5	Adam	0.01	9.7034855	152.66554	12.35579	20.34242
12B	16	5	Adam	0.01	11.157973	197.5904	14.056685	22.694964
15	16	5	Adam	0.01	10.180891	168.55742	12.982966	21.997992
60	4	10	Adam	0.01	10.4398775	183.21724	13.535776	22.5904629
60B	8	1	Adam	0.01	11.246518	206.35455	14.3650465	23.528207
100	8	1	Adam	0.01	12.257871	231.84604	15.226491	25.1133353

In the last two tables, repeated look-back values can be seen, since in the testing process the values obtained, especially in the definition of the hyperparameters, showed values far from what was expected or with a greater dispersion than allowed.

As with the previous model, we performed the prediction with the GRU architecture while maintaining the test conditions, meaning that we maintained the analysis on 100% of the neural signals, with the following results shown in Table 11 for the attention value and Table 12 for the meditation value.

**Table 11.** Prediction attention with GRU, using the complete feature set.

GRU Attention								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0.01	12.905936	259.13977	16.097818	36.4739567
3	64	10	Adam	0.1	14.400285	173.77466	13.182362	37.5045925
5	64	10	Adam	0.1	10.174233	169.12747	13.004902	35.3435516
5B	8	1	Adam	0.01	9.3669615	139.02986	11.79193	31.9900125
7	32	10	rmsprop	0.4	18.602463	561.6555	23.699272	44.233652
7B	64	10	Adam	0.1	10.734492	191.56284	13.840623	34.664142
7C	8	1	Adam	0.01	9.570991	147.82707	12.158416	34.180242
9	64	10	Adam	0.1	9.922806	159.27669	12.620487	33.0549777
9B	16	1	rmsprop	0.2	11.752387	211.51498	14.543554	14.8547634
11	8	5	Adam	0.2	9.488643	148.82626	12.199437	30.0053089
12	8	1	Adam	0.01	11.753124	203.12943	14.252348	45.8035856
15	8	5	Adam	0.2	13.397072	266.48898	16.32449	51.8113613
60	32	20	Adam	0.1	10.852699	181.9647	13.489429	38.016602
100	32	20	Adam	0.1	20.168981	605.4482	24.605846	88.43652

**Table 12.** Meditation prediction with GRU, using the complete feature set.

GRU Meditation								
Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
1	8	1	Adam	0.01	12.594968	248.45146	15.762343	25.644166
3	8	1	Adam	0.01	8.601949	112.522995	10.607686	18.3427959
5	64	20	Adam	0.01	9.537732	151.21387	12.296905	20.873832
5B	64	20	Adam	0.01	10.158519	166.11583	12.888593	20.95598
7	8	1	Adam	0.01	13.383541	311.49344	17.649178	36.1100912
7B	8	1	Adam	0.01	9.552063	143.57953	11.982468	19.974741
7C	8	1	Adam	0.01	9.075036	131.09457	11.449651	19.262354
9	16	5	Adam	0.01	9.315576	143.1378	11.964021	19.808089
11	64	20	Adam	0.01	9.868773	167.212	12.93148	21.18044
13	16	5	Adam	0.01	10.399938	173.73161	13.180719	21.70301
13B	16	5	Adam	0.01	10.867846	187.10138	13.6785	22.142434
15	8	1	Adam	0.01	9.803316	150.17015	12.254394	20.382806
60	8	1	Adam	0.01	10.531624	178.25508	13.35122	22.1152886
100	8	1	Adam	0.01	12.487414	236.91072	15.391905	25.4003704

### 6.3. Model Comparison

To compare the prediction performance between the LSTM and GRU networks, we focused on the RMSE metric as the main evaluation metric. The reason for this choice is that RMSE provides a direct measure of error in the same units as the original data, making it easier to interpret. In addition, RMSE penalizes larger errors more heavily, which is crucial in the context of time-series forecasting, where significant errors can affect the practical utility of the model. The comparison will provide information on the strengths and weaknesses of each model in predicting attention and meditation from raw EEG signals [33].

In the process of comparing the above data, the following results can be extracted for the two model architectures and prediction strategies, based on the data obtained in Tables 13–16.

**Table 13.** Best prediction results for attention/meditation with LSTM, using partial feature set.

Output Signal	Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
Attention	3	8	1	Adam	0.01	16.443464	390.06958	19.75018	44.18967
Meditation	5	8	1	Adam	0.01	9.730363	153.521	12.390359	20.396484

**Table 14.** Best prediction results for attention/meditation with GRU, using partial feature set.

Output Signal	Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
Attention	9	4	10	sgd	0.2	14.613	368.0468	19.1845	29.7287
Meditation	3B	8	1	Adam	0.01	9.377201	142.39085	11.932764	19.491779


**Table 15.** Best prediction results for attention/meditation with LSTM, using the complete feature set.

Output Signal	Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
Attention	7	8	1	Adam	0.01	9.586014	146.60876	12.1082411	34.657588
Meditation	7	8	1	Adam	0.01	8.75148	118.901115	10.904179	18.5926675

**Table 16.** Best prediction results for attention/meditation with GRU, using complete feature set.

Output Signal	Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	MAE	MSE	RMSE	SMAPE
Attention	5B	8	1	Adam	0.01	9.3669615	139.02986	11.79193	31.9900125
Meditation	7C	8	1	Adam	0.01	9.075036	131.09457	11.449651	19.262354

These values resulting from the RandomSearch calculation are reflected in the following graphs, as shown in Figure 11 for the attention values and in Figure 12 for the meditation values.



**Figure 11.** Comparison for attention prediction.

As a summary, the result of the best prediction based on the RMSE metric is shown in Table 17, where you can see the comparison not only of the performance of the LSTM and GRU networks but also the size of the time window (look-back) and which of the prediction strategies is more interesting to follow in our research.




Figure 12. Comparison for prediction of meditation.

Table 17. Best prediction results for attention/meditation regarding LSTM vs. GRU.

Attention	RMSE	LB	Meditation	RMSE	LB
GRU without	11.79193	5	GRU without	11.449651	7
LSTM without	12.10824	7	LSTM without	10.904179	7
GRU with	12.390359	5	GRU with	11.932764	5
LSTM with	19.75018	7	LSTM with	12.390359	7

From the above data, we can extract the optimal value obtained, as well as the architecture and the prediction calculation model, as can be seen in Table 18 for the attention value and Table 19 for the meditation value.

Table 18. Best prediction result for attention regarding LSTM vs. GRU.

Attention	RMSE	LB
GRU without	11.79193	5

Table 19. Best prediction result for meditation regarding LSTM vs. GRU.

Meditation	RMSE	LB
LSTM without	10.904179	7

Continuing with the study and analysis of the values obtained and with the aim of guaranteeing the prediction process, a new calculation and test will be carried out on the look-back values, taking the previous and subsequent values to determine, without any doubt, the optimum value of the time window that determines the best prediction of the models. This new test has been carried out following the same procedure, comparing the two RNN architectures since, as can be seen in the values in Tables 15 and 16 of results, in both cases, the prediction is more favorable with the model that does not use the calculation structure defined and followed by NeuroSky in the eSense algorithm.

To compare the GRU and LSTM architectures for predicting attention and meditation states using EEG signals, a temporal five-fold cross-validation was implemented to evaluate their performance and stability. Parameter 5 was selected because it provided positive results in previous works [34,35]. Key evaluation metrics included MAE, MSE, RMSE, and

SMAPE, each accompanied by standard deviations to assess consistency across validation folds. The results revealed distinct patterns in the behavior of these architectures, offering valuable insights into their suitability for predicting mental states. Tables 20 and 21 below show and compare the results obtained from the cross-validation application. For each case, the configuration of the best hyperparameters has been used.

**Table 20.** Comparison of cross-validation results for attention.

Attention	MAE	MSE	RMSE	SMAPE
GRU:	9.1176 (±0.9822)	134.0736 (±29.3221)	11.5149 (±1.2169)	27.9219 (±10.4861)
LSTM:	9.4034 (±1.6250)	144.8023 (±54.1297)	11.8589 (±2.0415)	27.7985 (±10.8337)

**Table 21.** Comparison of cross-validation results for meditation.

Meditation	MAE	MSE	RMSE	SMAPE
GRU:	9.8498 (±0.4453)	163.8544 (±15.3970)	12.7868 (±0.5929)	19.6260 (±1.5804)
LSTM:	9.8380 (±0.3493)	164.3154 (±18.7108)	12.7973 (±0.7371)	19.7476 (±1.6546)

Based on the values obtained and shown in the tables above, we can state that in the case of attention-state prediction, GRU outperformed LSTM across all metrics, with a notably lower MAE compared to LSTM’s. GRU also demonstrated superior stability, as reflected in lower standard deviations, particularly for MSE. However, the difference in SMAPE values between GRU and LSTM was marginal, indicating similar performance in terms of normalized percentage error. This suggests that while GRU is more robust and reliable for attention prediction, both models are comparable when interpretability of normalized errors is prioritized in practical applications.

For meditation-state prediction, the performance of GRU and LSTM was strikingly similar, with almost identical MAE values and parity across all metrics. Both architectures showed greater stability in meditation predictions compared to attention, as evidenced by significantly lower standard deviations. Notably, the SMAPE for meditation was considerably lower, suggesting that meditation states exhibit more consistent and predictable patterns in EEG signals. These findings highlight the distinct characteristics of mental states and their computational modeling potential, offering practical guidance for architecture selection and avenues for further research in deep learning applications for EEG-based mental-state prediction.

To ensure the consistency of the above results, the window values or (LB) before and after the calculated value will be analyzed, as the analysis intervals have been performed in two window steps, leaving values unanalyzed.

The result of the comparison with the previous and subsequent values are shown in Tables 22 and 23 below.


**Table 22.** Best prediction results of prior and posterior LB for attention/meditation with LSTM architecture and partial feature set.

Output Signal	Look-Back	LSTM Units	Batch_Size	Optimizer	Dropout	RMSE
Attention	6	8	1	Adam	0.01	13.416016
	7	8	1	Adam	0.01	12.1082411
	7B	32	20	rmsprop	0.3	13.100437
	8	4	10	Adam	0.01	14.6655445
Meditation	6	16	5	Adam	0.01	11.016348
	7	8	1	Adam	0.01	10.904179
	7B	64	20	Adam	0.01	12.357736
	8	8	1	Adam	0.01	12.174273

**Table 23.** Best prediction results of prior and posterior LB for attention/meditation with GRU architecture and partial feature set.

Output Signal	Look-Back	GRU Units	Batch_Size	Optimizer	Dropout	RMSE
Attention	4	8	1	Adam	0.01	12.974952
	5	8	1	Adam	0.01	11.79193
	5B	64	10	Adam	0.1	12.302976
	6	32	20	Adam	0.1	13.864193
Meditation	6	8	1	Adam	0.01	12.525784
	7	8	1	Adam	0.01	11.449651
	7B	16	5	Adam	0.01	12.585928
	8	16	5	Adam	0.01	12.0246105

With these data, we can confirm that the values of the time window are consistent and that the data were calculated previously. These data are reflected in Figure 13, corresponding to the attention and meditation value.



**Figure 13.** Final prediction results for attention and meditation.

This verification allows us to specify the metrics and values of the time window that best results in the prediction of attention and meditation, and the final results correspond to Tables 24 and 25, which confirm the initial values of the first RandomSearch test.

**Table 24.** Best prediction result for attention.

Architecture/Feature Set			RMSE	LB
Look-Back	GRU/partial feature set		11.79193	5
	GRU Units	Batch_Size	Optimizer	Dropout
5	8	1	Adam	0.01

**Table 25.** Best prediction result for meditation.

Architecture/Feature Set			RMSE	LB
Look-Back	LSTM/partial feature set		10.904179	7
	LSTM Units	Batch_Size	Optimizer	Dropout
7	8	1	Adam	0.01

Thus, we can conclude that the prediction of the attention and meditation values using LSTM-type RNNs to determine the meditation value and GRU type for the attention value.

#### 6.4. Real-Time Deployment and Analysis of Inference Time

With these results, the next step is to calculate the inference times of the networks in the calculation of the attention and meditation value in a real-time analysis. This calculation is motivated by the limitation of the reading process of the NeuroSky and Brainlink headset

that supplies a block of raw data (Delta, Alpha, Theta, . . .) every second, so implicitly there is a limitation in the available time of inference in the calculation.

As can be seen in the graphs in Figure 14, the inference times in the calculation of the attention and meditation values are substantially less than one second, with average values around 50 milliseconds.




Figure 14. Histogram of inference times.

The inference times of attention were calculated with a GRU, with  $LB = 5$ . In the case of meditation, it was performed with LSTM, with  $LB = 7$ . These architectures were used because they provided the best performances, according to Section 6.3.

To complete the real-time analysis, additional EEG data were collected from a new subject, allowing us to independently validate the previous experimental setup. This approach ensures that the model is evaluated against entirely unseen data that were not included in the training, validation, or cross-validation processes.

The real-time testing was conducted using the GRU network, following insights from the cross-validation results, which demonstrated a slight advantage of this architecture over LSTM in predictive performance.

Using this newly acquired dataset, we proceeded with real-time testing of the GRU-based neural network, incorporating the optimized hyperparameters. The results obtained from this evaluation are presented in Table 26, and Figures 15 and 16.





Figure 15. Real-time prediction of ATTENTION signal with GRU and data other than those used during training.

**Table 26.** Results of real-time prediction with GRU.

Signal	MAE	MSE	RMSE	SMAPE	Correlation	F1-Score
Attention	13.99607	337.22452	18.363674	24.714878	0.732409	0.873117
Mediation	12.7323065	261.5731	16.173222	28.55646	0.680617	0.645211

**Figure 16.** Real-time prediction of MEDITATION signal with GRU and data other than those used during training.

It is possible to see how these results are similar to those presented in Section 6.3. This additional testing further strengthens the validation of our model in a real-world setting.

## 7. Discussion

In our study, LSTM and GRU models were used to predict attention and meditation levels from raw EEG data. The results show that both models are able to make predictions with relatively low errors, as indicated by the MAE, MSE, and RMSE metrics.

Comparison with the literature:

1. “EEG-Based Age and Gender Prediction Using Deep BLSTM-LSTM Network Model” (2019) [36]: This study demonstrates the effectiveness of LSTM architectures in classifying EEG data, albeit in a different context (age and gender). The high accuracy obtained in this study suggests that LSTMs are suitable for capturing complex temporal features of EEG signals, a suggestion that is consistent with their findings that LSTMs can successfully predict attentional and meditative states.
2. “Application of Artificial Intelligence Techniques for Brain–Computer Interface in Mental Fatigue Detection: A Systematic Review (2011–2022)” (2023) [37]: Although this study focuses on mental-fatigue detection, the systematic review of AI techniques applied to BCI supports the idea that deep learning models are powerful tools for interpreting EEG signals. This reinforces the validity of the study’s approach using LSTM and GRU to predict cognitive states.
3. “EEG-based Biometric Authentication Using Machine Learning: A Comprehensive Survey” (2022) [38]: This study provides an overview of machine learning techniques applied to EEG-based biometric authentication. Although the goal is different, the effectiveness of machine learning techniques in classifying EEG signals bodes well for their application in attention and meditation prediction.

In summary, the results obtained are in line with the existing literature regarding the applicability and effectiveness of RNNs, specifically LSTMs and GRUs, for analyzing and predicting cognitive states from EEG signals. The comparison of different architectures and the optimization of hyperparameters in their study provide a valuable contribution to the field of BCI study, demonstrating that, with the right setup, these models can be tuned to

improve accuracy in predicting complex mental states. The integration of bioelectric signal acquisition systems with artificial intelligence techniques, as demonstrated in recent work by Laganà et al. (2024), offers promising opportunities for enhancing signal interpretation and clinical diagnosis through the combination of robust hardware design and advanced computational analysis methods [39]. This synergistic approach can lead to more accurate and reliable diagnostic tools in neurological assessment.

### *7.1. Analysis of the Strengths and Weaknesses of LSTM and GRU Networks for the Prediction of Attention and Meditation*

LSTM and GRU networks are variants of recurrent neural networks that have been widely used to process sequences of data such as EEG signals. Both architectures are designed to capture long-term temporal dependencies, making them suitable for time-series prediction tasks such as predicting attention and meditation from EEG signals. However, each has its own strengths and weaknesses in this context.

#### Strengths of LSTM:

1. **Memory capacity:** LSTMs are designed to avoid the problem of gradient fading, which allows them to learn long-term dependencies. This is crucial when working with EEG signals, which may contain patterns relevant to attention and meditation over long periods of time.
2. **Accuracy:** Studies have shown that LSTMs can be very accurate in classification and prediction tasks, as reflected in the study “EEG-Based Age and Gender Prediction Using Deep BLSTM-LSTM Network Model” (2019), suggesting that they can be equally effective in predicting attention and meditation [36].

#### Weaknesses of LSTMs:

1. **Complexity and computational cost:** LSTMs have a more complex structure than GRUs, possibly leading to higher computational cost and longer training times, especially on large datasets.
2. **Risk of overfitting:** Given their complexity, LSTMs can be prone to overfitting, especially when insufficient training data are available.

#### Strengths of GRU:

1. **Efficiency:** GRUs have a simpler structure than LSTMs, as they combine forgetting and updating gates. This can result in faster training and higher computational efficiency, as suggested in the systematic review “Application of Artificial Intelligence Techniques for Brain–Computer Interface in Mental Fatigue Detection” (2023) [37].
2. **Flexibility:** The simplicity of GRUs can make them more flexible to adapt to different data sizes, which can be advantageous in BCI applications where datasets may be limited or highly varied [40].

#### Weaknesses of GRU:

1. **Memory capacity:** Although GRUs are efficient, they may have a slightly lower memory capacity compared to LSTMs, potentially posing a drawback when modeling EEG signals that require the capture of long-term information.
2. **Generalization:** GRUs may have difficulty generalizing in some cases, especially when dealing with complex or subtle patterns in the data, which could affect the accuracy of attention prediction and meditation.

In our study, the final results show that both LSTM and GRU models perform comparably in terms of MAE, MSE, and RMSE metrics. This indicates that, despite their differences, both architectures can capture the dynamics of EEG signals to predict attention and meditation with reasonable accuracy. The choice between LSTM and GRU may depend on

factors specific to the dataset and application context, such as the size of the dataset, the availability of computational resources, and the need for fast training.

We can observe how both LSTMs and GRUs have their merits in predicting cognitive states from EEG signals. The choice between them must be based on a balance between desired accuracy and available resources, as well as on the specific nature of the EEG data being worked with. On the other hand, if we also consider the results obtained from the cross-validation process, we can conclude that the results indicate that GRU offers superior performance and stability for attention-state prediction, making it the preferred choice for tasks requiring robust and consistent predictions. However, for meditation-state prediction, both GRU and LSTM demonstrate an equivalent performance, allowing the choice between them to be guided by practical considerations, such as computational efficiency. These findings provide valuable insights into the suitability of these architectures for mental-state modeling and underscore the potential for future research to further optimize their application in EEG-based cognitive-state prediction.

### *7.2. Implications and Possible Applications of the Research Results*

The research results have several significant implications and open the door to multiple practical applications in the field of BCI, cognitive neuroscience, and mental health. The ability to accurately predict attentional and meditative states from EEG signals using LSTM and GRU networks has the potential to positively impact several areas:

#### 7.2.1. Implications for BCI Research and Technology

1. Improved brain–computer interfaces: LSTM and GRU models could be integrated into BCI devices to provide real-time feedback on users' attention and meditation states. This could improve human–machine interaction, especially in applications that require sustained concentration, such as learning or driving.
2. Personalization of user experience: By understanding and predicting cognitive states, applications could dynamically adapt to user needs, improving the experience in virtual reality applications, video games, and educational applications.

#### 7.2.2. Applications in Mental Health and Well-Being

1. Monitoring and improving mental well-being: wearable devices equipped with EEG sensors and the predictive models developed could be used to monitor stress levels and mental well-being, providing timely interventions, such as breathing exercises or guided meditation.
2. Personalized therapies: In the clinical context, the models could help personalize therapies for attention or meditation disorders, such as ADHD or anxiety, by adjusting interventions based on the patient's brain response in real time [41].

#### 7.2.3. Implications for Education and Training

1. Improved educational tools: Education systems could use these models to assess and improve students' concentration during learning activities, adapting content to maintain optimal attention.
2. Attention training: In high-performance pursuits, such as sport or music, the models could be used to train individuals in concentration and meditation techniques, improving overall performance.

#### 7.2.4. Future Research in Cognitive Neuroscience

1. Understanding cognitive processes: The results may provide a basis for further studies on the underlying neural mechanisms of attention and meditation, contributing to scientific knowledge in cognitive neuroscience.

2. Biomarker development: The ability to predict cognitive states from EEG could lead to the development of biomarkers for various neurological and psychiatric conditions.

#### 7.2.5. Challenges and Ethical Considerations

1. Data privacy and security: Implementation of these technologies must address the privacy and security of EEG data, which are sensitive biometric information.
2. Accessibility and equity: It is crucial to consider accessibility and equity in the development and implementation of BCI applications to ensure that the benefits are available to a wide range of users.

In summary, the results of this research have the potential to enrich human–computer interaction, improve mental health and well-being, and advance scientific understanding of cognitive processes. However, it is critical to address ethical and practical challenges in order to maximize the benefits and minimize the potential risks.

For a more detailed and specific discussion of BCI and EEG applications in mental-fatigue detection, the study [37] provides a relevant systematic review. In addition, the survey [38] provides an overview of EEG applications in biometric authentication and could provide insights into future applications of LSTM and GRU models in this field.

#### 7.3. Limitations Encountered During the Study

1. Sample Size and Diversity:
  - The sample may have been limited in size or diversity, which affects the generalizability of the results. A larger and more diverse sample could improve the robustness of the predictive models.
2. EEG Data Quality:
  - EEG data can be subject to noise and artefacts, which can affect the accuracy of predictions. Data quality is critical to the performance of machine learning models.
3. Complexity of Cognitive States:
  - Attention and meditation are complex cognitive states that may not be fully captured by EEG data or metrics used.
4. Models and Hyperparameters:
  - Model selection and hyperparameter optimization may have been limited by time or available computational resources.
5. Model Interpretation:
  - Neural networks, especially deep ones such as LSTM and GRU, are often criticized for their lack of interpretability, which can make it difficult to understand how models arrive at their predictions.

#### 7.4. Comparison with the Results Previously Obtained in Similar Studies

Our results demonstrate that both LSTM and GRU models are capable of effectively predicting attention and meditation values, showcasing their suitability for EEG-based cognitive-state analysis. These findings align with previous research that has employed recurrent neural networks for EEG signal processing, reinforcing their capacity to capture the temporal dynamics inherent in this type of data. For example, studies have shown similar predictive performance when using RNN-based architectures for cognitive-state classification [36,37]. However, many of these studies relied on preprocessed or proprietary EEG features, whereas our approach uses raw EEG signals, which enhance transparency and adaptability.

One of the notable insights from our work is that GRU models, due to their simpler architecture, provide a computational advantage over LSTM without sacrificing accuracy. This observation is consistent with prior findings in an analysis of the computational and efficiency advantages of the GRU over LSTMs [40]. However, unlike much of the existing research that relies on multi-channel EEG systems, our study demonstrates the feasibility of using low-cost, single-channel devices, making EEG-based technologies more accessible for practical applications. These distinctions underline the relevance of our study in bridging the gap between advanced predictive models and real-world usability.

Future research could build on these findings by testing the models on larger and more diverse datasets, as well as exploring hybrid architectures or additional neural network approaches to further enhance performance and generalizability. Nonetheless, this study provides a meaningful step toward simplifying and improving EEG-based cognitive-state predictions for practical and scalable applications.

## 8. Conclusions

This study has explored the application of deep learning models, specifically LSTM and GRU networks, in the prediction of cognitive states of attention and meditation using raw EEG signals. Our preliminary results indicate that these advanced models can accurately capture the temporal dynamics and long-term dependencies present in EEG signals, as doing so is essential for the accurate prediction of cognitive states [25]. Performance comparison between LSTM and GRU networks has provided valuable insight into the strengths and weaknesses of each model in this specific domain. Evaluation metrics, RMSE, MSE, MAE, and SMAPE, have been essential to quantify and compare the performance of these models [42].

For attention, the LSTM model with the partial feature set outperformed in regard to MAE and MSE, showing lower average and squared errors. Although its SMAPE is slightly higher, this model remains preferable if absolute error minimization is prioritized. Similarly, for meditation, the LSTM model with the partial feature set consistently showed better performance across all metrics compared to the GRU model with the algorithm, indicating higher accuracy and reliability. These findings highlight the promise of deep learning models in predicting cognitive states from raw EEG signals, paving the way for further exploration of RNNs in applied neuroscience and real-time BCI systems.

In conclusion, this study highlights the potential of LSTM and GRU neural networks to predict attention and meditation states using raw EEG signals collected from single-channel, low-cost devices. Both models demonstrated strong performance, with GRU standing out as a computationally efficient option that does not sacrifice accuracy. These results underscore the practicality of these neural network architectures for real-time cognitive-state monitoring, particularly in accessible applications like neurofeedback and brain–computer interface systems.

Moving forward, future research could build on these findings by involving larger and more diverse participant groups to improve the generalizability of the models. Additionally, integrating EEG data with other physiological signals or exploring hybrid neural network architectures may further enhance prediction accuracy and expand the range of applications. Overall, this work marks an important step toward making EEG-based cognitive-state prediction both simpler and more adaptable for real-world use.

**Author Contributions:** Conceptualization, F.R.; methodology, J.E.S.-G. and J.M.C.; formal analysis, F.R.; research, F.R., J.E.S.-G., and J.M.C.; data preservation, F.R.; data, F.R.; writing the original draft, F.R.; writing—revising and editing, J.E.S.-G. and J.M.C.; visualization, J.E.S.-G.; supervision, J.E.S.-G. and J.M.C.; project administration, F.R. All authors have read and accepted the published version. All authors have read and agreed to the published version of the manuscript.

**Funding:** This work was financially supported by the University of Burgos.

**Data Availability Statement:** The data presented in this study are available upon request from the corresponding author.

**Conflicts of Interest:** The authors declare no conflicts of interest.

## Abbreviations

The following abbreviations are used in this manuscript:

BCI	brain–computer interface
EEG	electroencephalography
EMG	electromyography
EOG	(electrooculography)
AI	artificial intelligence
CNN	convolutional neural networks
RNN	recurrent neural networks
LSTM	long short-term memory
MAE	Mean Absolute Error
MSE	Mean Squared Error
RMSE	Root Mean Squared Error
SMAPE	Symmetric Mean Absolute Percentage Error
DBS	Deep Brain Stimulation

## References

1. Sergio, R.L. Reducción de Artefactos En Señales Electroencefalográficas Mediante Nuevas Técnicas de Filtrado Automático Basadas En Separación Ciega de Fuentes. Ph.D. Thesis, Universitat Politècnica de Catalunya, Barcelona, Spain, 2010.
2. Miranda, C.; Lescher, A.; Rojas, A.; Molino, J.; Ibarra, E.; de Tristan, S. Detección Temprana de Epilepsia Pediátrica: Progresión de los Electrodo en EEG. *Eur. Sci. J.* **2023**, *19*, 1. [[CrossRef](#)]
3. Posner, M.I. The Evolution and Future Development of Attention Networks. *J. Intell.* **2023**, *11*, 98. [[CrossRef](#)] [[PubMed](#)]
4. Yang, X.; Cheng, P.Y.; Lin, L.; Huang, Y.M.; Ren, Y. Can an Integrated System of Electroencephalography and Virtual Reality Further the Understanding of Relationships Between Attention, Meditation, Flow State, and Creativity? *J. Educ. Comput. Res.* **2019**, *57*, 846–876. [[CrossRef](#)]
5. Sharma, K.; Wernicke, A.G.; Rahman, H.; Potters, L.; Sharma, G.; Parashar, B. A Retrospective Analysis of Three Focused Attention Meditation Techniques: Mantra, Breath, and External-Point Meditation. *Cureus* **2022**, *14*, e23589. [[CrossRef](#)] [[PubMed](#)]
6. Yoshida, K.; Takeda, K.; Kasai, T.; Makinae, S.; Murakami, Y.; Hasegawa, A.; Sakai, S. Focused Attention Meditation Training Modifies Neural Activity and Attention: Longitudinal EEG Data in Non-Meditators. *Soc. Cogn. Affect. Neurosci.* **2020**, *15*, 215–224. [[CrossRef](#)]
7. García, P.; Ángel, M. Caracterización de la sincronía de fase de EEG para su aplicación en Interfaces Cerebro-Computadora. Ph.D. Thesis, Universidad Autónoma Metropolitana, Mexico City, Mexico, 2020. [[CrossRef](#)]
8. Ruşanu, O.A. A LabVIEW Instrument Aimed for the Research on Brain-Computer Interface by Enabling the Acquisition, Processing, and the Neural Networks Based Classification of the Raw EEG Signal Detected by the Embedded NeuroSky Biosensor. *Int. J. Online Biomed. Eng.* **2023**, *19*, 57–81. [[CrossRef](#)]
9. Vélez, L.; Kemper, G. Algorithm for Detection of Raising Eyebrows and Jaw Clenching Artifacts in EEG Signals Using Neurosky Mindwave Headset. In *Proceedings of the 5th Brazilian Technology Symposium; Smart Innovation, Systems and Technologies*; Springer: Cham, Switzerland, 2021; Volume 202, pp. 99–110.
10. Chen, R.C.; Liou, M.J.; Dewi, C. Combination of EEG and Brainwave Mind Lamp to Detect the Value of Attention, Meditation and Fatigue of a Person. In *Proceedings of the 2021 International Conference on Technologies and Applications of Artificial Intelligence (TAAI)*, Taichung, Taiwan, 18–20 November 2021; pp. 174–179.
11. Bréchet, L.; Ziegler, D.A.; Simon, A.J.; Brunet, D.; Gazzaley, A.; Michel, C.M. Reconfiguration of Electroencephalography Microstate Networks after Breath-Focused, Digital Meditation Training. *Brain Connect.* **2021**, *11*, 146–155. [[CrossRef](#)] [[PubMed](#)]
12. You, S.D. Classification of Relaxation and Concentration Mental States with EEG. *Information* **2021**, *12*, 187. [[CrossRef](#)]
13. Ali, A.; Afridi, R.; Soomro, T.A.; Khan, S.A.; Khan, M.Y.A.; Chowdhry, B.S. A Single-Channel Wireless EEG Headset Enabled Neural Activities Analysis for Mental Healthcare Applications. *Wirel. Pers. Commun.* **2022**, *125*, 3699–3713. [[CrossRef](#)] [[PubMed](#)]

14. Adhikari, B.; Shrestha, A.; Mishra, S.; Singh, S.; Timalisina, A.K. EEG Based Directional Signal Classification Using RNN Variants. In Proceedings of the 2018 IEEE 3rd International Conference on Computing, Communication and Security (ICCCS), Kathmandu, Nepal, 25–27 October 2018; pp. 218–223.
15. Chaddad, A.; Wu, Y.; Kateb, R.; Bouridane, A. Electroencephalography Signal Processing: A Comprehensive Review and Analysis of Methods and Techniques. *Sensors* **2023**, *23*, 6434. [CrossRef]
16. Shrestha, A.; Adhikari, B. Color-Based Classification of EEG Signals for People with the Severe Locomotive Disorder. *arXiv* **2023**, arXiv:2304.11068.
17. Saha, S.; Mathur, A.; Bora, K.; Basak, S.; Agrawal, S. A New Activation Function for Artificial Neural Net Based Habitability Classification. In Proceedings of the 2018 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2018, Bangalore, India, 19–22 September 2018; pp. 1781–1786. [CrossRef]
18. Permana, K.; Wijaya, S.K.; Prajitno, P. Controlled Wheelchair Based on Brain Computer Interface Using Neurosky Mindwave Mobile 2. *AIP Conf. Proc.* **2019**, *2168*, 020022.
19. Attentional Modulation Effects on Brain Networks: An fMRI Study on the Visual Attention Network and the Default-Mode Network. Available online: [https://www.researchgate.net/publication/281239686\\_Attentional\\_Modulation\\_Effects\\_on\\_Brain\\_Networks\\_an\\_fmri\\_Study\\_on\\_the\\_Visual\\_Attention\\_Network\\_and\\_the\\_Default-Mode\\_Network?channel=doi&linkId=55dc6dcc08aec156b9b1771d&showFulltext=true](https://www.researchgate.net/publication/281239686_Attentional_Modulation_Effects_on_Brain_Networks_an_fmri_Study_on_the_Visual_Attention_Network_and_the_Default-Mode_Network?channel=doi&linkId=55dc6dcc08aec156b9b1771d&showFulltext=true) (accessed on 23 January 2025).
20. Brainwaves, The Key To Healthy Brain Function | The Neurofeedback Center of Pittsburgh. Available online: <https://www.neurofeedbackpittsburgh.com/brainwaves-the-key-to-healthy-brain-function/> (accessed on 21 September 2024).
21. Chaipakornwong, T.; Sittiprapaporn, P. Brain Exercise in Elderly: NeuroSky Smarter Kit Investigation. *Asian J. Med. Sci.* **2020**, *11*, 69–74. [CrossRef]
22. Alpha-Theta Training—The Neuro Brain—Neurofeedback Melbourne—FAQs. Available online: <https://theneurobrain.com/blog/tag/alpha-theta+training> (accessed on 21 September 2024).
23. Cerebral Areas for EEG Band Power Spectrum Calculations | Download Scientific Diagram. Available online: [https://www.researchgate.net/figure/Cerebral-areas-for-EEG-band-power-spectrum-calculations\\_fig2\\_267811728](https://www.researchgate.net/figure/Cerebral-areas-for-EEG-band-power-spectrum-calculations_fig2_267811728) (accessed on 21 September 2024).
24. Bala, P.; Amob, R.; Islam, M.; Adib, S.; Hasan, F.; Uddin, M.N. EEG—Based Load Control System for Physically Challenged People. In Proceedings of the 2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST), Khaka, Bangladesh, 5–7 January 2021; pp. 603–606.
25. Tigga, N.P.; Garg, S. Efficacy of Novel Attention-Based Gated Recurrent Units Transformer for Depression Detection Using Electroencephalogram Signals. *Health Inf. Sci. Syst.* **2023**, *11*, 1. [CrossRef] [PubMed]
26. Zheng, W.; Lu, B. Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks. *IEEE Trans. Auton. Ment. Dev.* **2019**, *7*, 162–175. [CrossRef]
27. Alfredo, A.S.; Adytia, D.A. Time Series Forecasting of Significant Wave Height Using GRU, CNN-GRU, and LSTM. *J. RESTI (Rekayasa Sist. Dan Teknol. Inf.)* **2022**, *6*, 776–781. [CrossRef]
28. Understanding MAE, MSE, and RMSE: Key Metrics in Machine Learning—DEV Community. Available online: [https://dev.to/mondal\\_sabbha/understanding-mae-mse-and-rmse-key-metrics-in-machine-learning-4la2](https://dev.to/mondal_sabbha/understanding-mae-mse-and-rmse-key-metrics-in-machine-learning-4la2) (accessed on 24 January 2025).
29. Goodwin, P.; Lawton, R. On the Asymmetry of the Symmetric MAPE. *Int. J. Forecast.* **1999**, *15*, 405–408. [CrossRef]
30. How to Calculate SMAPE in Excel?—GeeksforGeeks. Available online: <https://www.geeksforgeeks.org/how-to-calculate-smape-in-excel/> (accessed on 24 January 2025).
31. Yang, D.; Hollenstein, N. PLM-AS: Pre-Trained Language Models Augmented with Scanpaths for Sentiment Classification. In Proceedings of the Northern Lights Deep Learning Workshop, Tromsø, Norway, 10–12 January 2023; Volume 4. [CrossRef]
32. Sahu, A.K.; Sharma, S.; Raja, R. Deep Learning-Based Continuous Authentication for an IoT-Enabled Healthcare Service. *Comput. Electr. Eng.* **2022**, *99*, 107817. [CrossRef]
33. Sravanth, K.R.; Peddi, A.; Sagar, G.S.; Gupta, B.; Chakraborty, C. Comparison of Attention and Meditation Based Mobile Applications by Using EEG Signals. In Proceedings of the 6th Global Wireless Summit, GWS 2018, Chiang Rai, Thailand, 25–28 November 2018; pp. 260–265. [CrossRef]
34. Noh, J.H.; Yang, H.-D. Alzheimer Progression Classification Using fMRI Data. *Smart Media J.* **2024**, *13*, 86–93. [CrossRef]
35. Ma, B.; Dong, S. A Hybrid Prediction Model for Pumping Well System Efficiency Based on Stacking Integration Strategy. *Int. J. Energy Res.* **2024**, *2024*, 8868949. [CrossRef]
36. Kaushik, P.; Gupta, A.; Roy, P.P.; Dogra, D.P. EEG-Based Age and Gender Prediction Using Deep BLSTM-LSTM Network Model. *IEEE Sens. J.* **2019**, *19*, 2634–2641. [CrossRef]
37. Yaacob, H.; Hossain, F.; Shari, S.; Khare, S.K.; Ooi, C.P.; Acharya, U.R. Application of Artificial Intelligence Techniques for Brain-Computer Interface in Mental Fatigue Detection: A Systematic Review (2011–2022). *IEEE Access* **2023**, *11*, 74736–74758. [CrossRef]

38. Shams, T.B.; Hossain, M.S.; Mahmud, M.F.; Tehjib, M.S.; Hossain, Z.; Pramanik, M.I. EEG-Based Biometric Authentication Using Machine Learning: A Comprehensive Survey. *ECTI Trans. Electr. Eng. Electron. Commun.* **2022**, *20*, 225–241. [[CrossRef](#)]
39. Laganà, F.; Praticò, D.; Angiulli, G.; Oliva, G.; Pullano, S.A.; Versaci, M.; Foresta, F. La Development of an Integrated System of SEMG Signal Acquisition, Processing, and Analysis with AI Techniques. *Signals* **2024**, *5*, 476–493. [[CrossRef](#)]
40. Wang, X.; Han, Q.; Li, J.; Jin, Y. Research on Prediction Model of Epileptic EEG Signal Based on GRU. In Proceedings of the 2021 International Conference on Electronic Information Engineering and Computer Science (EIECS), Changchun, China, 23–26 September 2021; pp. 9–12.
41. Hidalgo-Munoz, A.R.; Acle-Vicente, D.; Garcia-Perez, A.; Taberero-Urbieta, C. Application of Neurotechnology in Students with ADHD: An Umbrella Review. *Comun. Media Educ. Res. J.* **2023**, *31*, 59–69. [[CrossRef](#)]
42. Ahmadzadeh, E.; Kim, H.; Jeong, O.; Kim, N.; Moon, I. A Deep Bidirectional LSTM-GRU Network Model for Automated Ciphertext Classification. *IEEE Access* **2022**, *10*, 3228–3237. [[CrossRef](#)]

**Disclaimer/Publisher’s Note:** The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.