

DESARROLLO DE UN SISTEMA MECATRÓNICO EXPERIMENTAL PARA EL  
CONTROL DE UN PROTOTIPO DE PRÓTESIS DE MANO MEDIANTE SEÑALES  
ELECTROENCEFALOGRÁFICAS Y RETROALIMENTACIÓN HÁPTICA

LUISA FERNANDA MENESES FANDIÑO

CORPORACIÓN UNIVERSITARIA COMFACAUCA – UNICOMFACAUCA

FACULTAD DE INGENIERÍAS

INGENIERÍA MECATRÓNICA

POPAYÁN, CAUCA

2024

DESARROLLO DE UN SISTEMA MECATRÓNICO EXPERIMENTAL PARA EL  
CONTROL DE UN PROTOTIPO DE PRÓTESIS DE MANO MEDIANTE SEÑALES  
ELECTROENCEFALOGRÁFICAS Y RETROALIMENTACIÓN HÁPTICA

LUISA FERNANDA MENESES FANDIÑO

TRABAJO DE GRADO PARA OPTAR AL TÍTULO DE:  
INGENIERO MECATRÓNICO

DIRECTOR:

M.SC. SAÚL EDUARDO RUIZ SARZOSA

CORPORACIÓN UNIVERSITARIA COMFACAUCA - UNICOMFACAUCA

FACULTAD DE INGENIERÍAS

INGENIERÍA MECATRÓNICA

POPAYÁN, CAUCA

2024

NOTA DE ACEPTACIÓN

---

---

---

---

---

---

FIRMA DEL DIRECTOR OPCIÓN DE GRADO

---

FIRMA DEL JURADO

# DEDICATORIA

---

Esta investigación está profundamente inspirada en mi sobrina, María Victoria Díaz Meneses, quien ha sido mi motivación para adentrarme en el diverso campo de la ingeniería mecatrónica. Ella me ha enseñado que no existen las discapacidades, sino capacidades distintas; y que las limitaciones son, en gran medida, barreras mentales. Gracias a los avances tecnológicos, tenemos la oportunidad de construir un futuro más empático e inclusivo. Veo cada necesidad no como una deficiencia, sino como una oportunidad para desarrollar sistemas que mejoren la calidad de vida de todas las personas.

Dedico este trabajo también a mí misma, recordando quién era hace unos años, alguien que no imaginaba que tomaría un avión y cruzaría el mundo, hacia otro continente en búsqueda de conocimiento. He superado innumerables obstáculos en mi camino con un objetivo claro: adquirir un crecimiento profesional y personal invaluable. Este viaje ha sido una prueba de mi resiliencia y determinación, y cada desafío superado ha fortalecido mi compromiso con mi campo de estudio y conmigo misma.

# AGRADECIMIENTOS

---

Son innumerables las personas a quien agradezco porque cada una ha aportado significativamente a lo que hoy se vuelve una realidad.

Principalmente agradezco a Dios quien ha sido esa fortaleza espiritual en todo momento.

También agradezco a mi madre por ser un ejemplo para seguir y esa persona que siempre ha creído en mí y en mis capacidades, sigo nombrando a mi padre, hermana y abuelos quienes han sido una compañía invaluable en todo momento.

Enseguida quiero nombrar a mi pareja Sebastián Rojas, quién con su conocimiento y compañía, ha hecho que cada aprendizaje tenga un por qué y para qué, siendo mi apoyo tanto personal como profesional.

También quiero agradecer de manera especial a mi director de tesis Saul Ruiz quien ha estado en acompañamiento permanente y aportando su conocimiento en pro de un excelente resultado.

A el señor Jorge Prado y el joven Cesar Chagüendo, quienes, con su alegría y disposición en los laboratorios de la universidad y el almacén de herramientas, hicieron que fueran un lugar de trabajo óptimo.

Por último y no menos importante cabe resaltar a la empresa *Mirai Innovation Research Institute* en Japón, a su CEO Cristian Peñaloza y al mentor de proyecto Rafael Hernández quienes me abrieron las puertas de la empresa y de sus instalaciones en pro de adquirir nuevos conocimientos en diferentes tecnologías emergentes.

# RESUMEN

---

Esta tesis aborda el desarrollo de un prototipo de prótesis de mano mecatrónica, controlada por señales electroencefalográficas (EEG) con integración de retroalimentación háptica. Frente a la limitación de las prótesis convencionales en cuanto a funcionalidad e interacción, este estudio propone una solución innovadora utilizando interfaces cerebro-computadora (BCI) para mejorar la calidad de vida de los usuarios.

La metodología adoptada se basa en la estrategia de diseño de la Metodología V, centrada en fases sucesivas que incluyen el diseño biomecánico detallado, el procesamiento avanzado de señales EEG, la implementación de técnicas de aprendizaje automático para la clasificación de patrones de señales cerebrales, y el desarrollo de un sistema de retroalimentación háptica para proporcionar sensaciones táctiles.

Los resultados demuestran la viabilidad del sistema de prótesis propuesto, con una interfaz BCI eficaz que permite al usuario realizar movimientos precisos y recibir retroalimentación sensorial. Las pruebas con sujetos han mostrado una mejora significativa en términos de control intuitivo y experiencia de uso en comparación con sistemas de prótesis sin retroalimentación háptica.

Finalmente, este trabajo contribuye al campo de las prótesis mecatrónicas mediante la integración exitosa de tecnologías BCI y hápticas, ofreciendo nuevas perspectivas en la interacción entre usuarios y sus prótesis. Los trabajos futuros para la investigación incluyen la miniaturización de componentes, la mejora de la autonomía de la batería y la personalización de la prótesis para diversas actividades de la vida diaria.

# ABSTRACT

---

This thesis addresses the development of a prototype of a mechatronic prosthetic hand, controlled by electroencephalographic (EEG) signals with haptic feedback integration. In response to the limitations of conventional prostheses in terms of functionality and interaction, this study proposes an innovative solution using brain-computer interfaces (BCI) to improve the quality of life of users.

The methodology adopted is based on the V-Model design strategy, focused on successive phases that include detailed biomechanical design, advanced EEG signal processing, the implementation of machine learning techniques for the classification of brain signal patterns, and the development of a haptic feedback system to provide tactile sensations.

The results demonstrate the feasibility of the proposed prosthetic system, with an effective BCI interface that allows the user to perform precise movements and receive sensory feedback. Subject testing has shown a significant improvement in terms of intuitive control and user experience compared to prosthetic systems without haptic feedback.

Finally, this work contributes to the field of mechatronic prostheses by the successful integration of BCI and haptic technologies, offering new perspectives in the interaction between users and their prostheses. Future research directions include the miniaturization of components, the improvement of battery autonomy, and the customization of the prosthesis for various activities of daily living.

## この論文の要約

---

本論文では、脳波(EEG)信号による制御と触覚フィードバック統合を備えた、生体電子的義手プロトタイプ的设计と開発を取り扱っています。従来の義肢の機能性と相互作用の限界に対応して、本研究では脳コンピュータインタフェース(BCI)を用いた革新的なソリューションを提案し、利用者の生活の質向上を目指しています。

採用された手法は、詳細な生体機械設計、高度な EEG 信号処理、脳信号パターン分類のための機械学習技術の実装、触覚感覚を提供するための触覚フィードバックシステムの開発など、連続する段階に焦点を当てた V モデル設計戦略に基づいています。

結果は、提案された義肢システムの実現可能性を実証しています。効果的な BCI インタフェースにより、ユーザーは正確な動きを行い、感覚フィードバックを受け取ることができます。被験者テストでは、触覚フィードバックのない義肢システムと比較して、直感的な操作性とユーザーエクスペリエンスが大幅に向上していることが示されています。

最後に、本研究は、BCI 技術と触覚技術の成功した統合によって生体電子義肢の分野に貢献し、ユーザーと義肢との相互作用における新しい視点を提供しています。今後の研究方向としては、部品の小型化、バッテリー寿命の改善、日常生活のさまざまな活動に合わせて義肢をカスタマイズすることが挙げられます。

# CONTENIDO

---

DEDICATORIA.....	4
AGRADECIMIENTOS.....	5
RESUMEN.....	6
ABSTRACT.....	7
この論文の要約.....	8
CONTENIDO.....	9
LISTA DE FIGURAS.....	12
LISTA DE TABLAS.....	14
LISTA DE GRÁFICOS.....	14
1 INTRODUCCIÓN.....	15
2 PLANTEAMIENTO Y FORMULACIÓN DEL PROBLEMA.....	17
3 JUSTIFICACIÓN.....	20
4 OBJETIVOS.....	23
4.1 OBJETIVO GENERAL.....	23
4.2 OBJETIVOS ESPECÍFICOS.....	23
5 ESTADO DEL ARTE.....	24
5.1 Uso de Señales Electroencefalográficas en el Control de Prótesis.....	25
5.2 Retroalimentación Háptica en Prótesis.....	28
5.3 Control Brain Computer Interface (BCI) para Prótesis.....	30
5.4 MIRAI Innovation Research Institute JAPAN.....	34
6 MARCO TEÓRICO.....	37
6.1 Biomecánica de la Mano Humana.....	37
6.1.1 Anatomía de la Mano.....	38
6.1.2 Fisiología de la Mano.....	39
6.1.3 Biomecánica de la Mano.....	40
6.1.4 Biomecánica de la Prehensión.....	40
6.1.5 Aplicaciones de la Biomecánica de la Mano.....	41
6.2 Señales Electroencefalográficas (EEG).....	42
6.2.1 Naturaleza de las Señales EEG.....	42
6.2.2 Adquisición de Señales EEG.....	43

6.2.3	Análisis de Señales EEG .....	47
6.2.4	Aplicaciones de las Señales EEG .....	50
6.3	Técnicas de Procesamiento de Señales EEG .....	50
6.3.1	Preprocesamiento .....	50
6.3.2	Análisis en el Dominio de la Frecuencia .....	54
6.3.3	Análisis en el Dominio del Tiempo-Frecuencia .....	56
6.3.4	Análisis Espacial .....	57
6.3.5	Métodos Estadísticos y de Aprendizaje Automático .....	59
6.3.6	Métodos Avanzados .....	60
6.4	Mecatrónica y Diseño de Prótesis.....	61
6.4.1	Aplicación de la Mecatrónica en Diseño de Prótesis.....	62
6.4.2	Componentes Mecatrónicos en Prótesis .....	62
6.4.3	Diseño de Prótesis .....	65
6.4.4	Avances y Desafíos Actuales.....	66
6.5	Interfaz Cerebro-Computadora (BCI) .....	67
6.5.1	Tipos de BCI .....	67
6.5.2	Componentes Clave de un BCI .....	68
6.5.3	Aplicaciones de las BCI .....	69
6.6	Retroalimentación Háptica .....	69
6.6.1	Tipos de Retroalimentación Háptica .....	69
6.6.2	Componentes Clave de la Retroalimentación Háptica.....	69
6.6.3	Aplicaciones de la Retroalimentación Háptica .....	70
6.6.4	Desafíos y Consideraciones en la Retroalimentación Háptica .....	70
6.7	Machine Learning .....	70
6.7.1	Aprendizaje Supervisado .....	71
6.7.2	Aprendizaje No Supervisado .....	71
6.7.3	Aprendizaje por Refuerzo .....	72
6.7.4	Regresión Logística en el Desarrollo de Prótesis Mecatrónicas .....	73
6.8	Kit AURA como Biosensor .....	74
6.8.1	Desarrollo Tecnológico del Kit Aura .....	74
7	METODOLOGÍA .....	78
7.1	Pasos Clave en la Metodología V .....	79

7.2	Requisitos y Diseño del Sistema.....	80
7.2.1	FASE 1 Diseño de Ingeniería y Modelado.....	81
7.3	Modelado y Análisis .....	86
7.3.1	FASE 2 Construcción y Codificación Inicial .....	87
7.3.2	FASE 3 Procesamiento de Señales y Machine Learning .....	91
7.3.3	FASE 4 Desarrollo de Retroalimentación Háptica .....	104
7.4	Integración del Sistema .....	110
7.4.1	FASE 5 Integración y Pruebas del Sistema.....	111
8	CONCLUSIONES .....	125
9	TRABAJOS FUTUROS .....	127
10	REFERENCIAS.....	129
11	Anexos.....	146
11.1	Anexo 1 Código Control Motores Prótesis.....	146
11.2	Anexo 2 Código Aura.py.....	147
11.3	Anexo 3 LSL_write.py .....	149
11.4	Anexo 4 Iterative_Get_Data.py .....	151
11.5	Anexo 5 Calibration.py.....	152
11.6	Anexo 6 VRehab_2.py .....	154
11.7	Anexo 7 Código Sensor piezoeléctrico de presión.....	157
11.8	Anexo 8 Código M5 stack .....	159
11.9	Anexo 9 Partes de diseño de mano del modelo de mano versión 1 del robot Inmoov para ensamblaje .....	160

# LISTA DE FIGURAS

---

Figura 1. Carpo, Metacarpo y Falanges (generada por DALL-E-3 Operated by Poe) .....	39
Figura 4. Biomecánica de la prehensión (generada por DALL-E-3 Operated by Poe) .....	41
Figura 5. Vista lateral del cráneo para mostrar los métodos de medición desde el nasión hasta el inión en la línea media. Fuente (Klem, Lüders, et al., 1999).....	44
Figura 6. Vista frontal del cráneo que muestra el método de medición de la línea central de electrodos. Fuente (Klem, Lüders, et al., 1999).....	45
Figura 7. Vista superior con corte transversal del cráneo a través de la línea temporal de electrodos que ilustra el sistema 10±20 aplicado en esta dirección. Fuente (Klem, Lüders, et al., 1999).....	46
Figura 8. La vista lateral de los hemisferios izquierdo y derecho mostrando todas las posiciones estándar de los electrodos. Fuente (Klem, Lüders, et al., 1999) .....	46
Figura 9. Vistas frontal superior y posterior que muestran todas las posiciones estándar de los electrodos. Fuente (Klem, Lüders, et al., 1999).....	47
Figura 10. Principales ondas neuronales generadas en el cerebro (generada por DALL-E-3 Operated by Poe) .....	48
Figura 11. Filtros de Paso Bajo («Filtro paso bajo», 2022).....	51
Figura 12. Filtro pasa alto («Filtro paso alto», 2022) .....	52
Figura 13. Filtro Pasa Banda («Filtro paso banda», 2023) .....	52
Figura 14. Filtro Notch («Filtro elimina banda», 2019) .....	53
Figura 15. Transformada de Fourier (Transformadas Wavelet   Multimedia, s. f.) .....	55
Figura 16. Transformada de Fourier (Transformadas Wavelet   Multimedia, s. f.) .....	57
Figura 17. Principales Actuadores (generada por DALL-E-3 Operated by Poe).....	63
Figura 18 Aura 00 (“Aura Through Time,” 2023.).....	75
Figura 19 Aura 01 (“Aura Through Time,” 2023.).....	75
Figura 20 Aura 02 (“Aura Through Time,” 2023.).....	76
Figura 21. Metodología en V (Graessler & Hentze, 2020) .....	80
Figura 22. Diseño Arquitectónico. Fuente: Autor.....	82
Figura 23. Diseño CAD de ensamblaje de mano mecánica. Fuente: Autor. ....	84
Figura 24. Diseño CAD Caja Micromotores. Fuente: Autor.....	84
Figura 25. Diseño CAD Malla para Cajas. Fuente: Autor. ....	85
Figura 26. Diseño CAD Micromotor. Fuente: Autor. ....	85
Figura 27. Diseño CAD de M5 stack. Fuente: Autor.....	85
Figura 28. Diseño CAD de brazaletes feedback incorporando motores y M5 stack (microcontrolador). Fuente: Autor. ....	86
Figura 29. Selección de componentes mecánicos y electrónicos. Fuente: Autor. ....	87
Figura 30. Ensamblaje de mano robótica. Fuente: Autor.....	87
Figura 31. Ensamblaje de muñeca mecánica con actuador. Fuente: Autor. ....	88
Figura 32. Ensamblaje mano, muñeca y actuadores electrónicos. Fuente: Autor.....	88
Figura 33. Diagrama de Flujo del Algoritmo en Arduino para el Control de la Mano Robótica. Fuente: Autor.....	89
Figura 34. Funcionamiento de la mano con sensores mioeléctricos MyoWare. Fuente: Autor...	90
Figura 35. Diagrama de Flujo para el Código Aura. Fuente: Autor. ....	93

Figura 36. Diagrama de Flujo para el Código LSL_write. Fuente: Autor.....	95
Figura 37. Diagrama de Flujo para el Código Iterative_Get_Data. Fuente: Autor.....	97
Figura 38. Diagrama de Flujo para el Código Calibration. Fuente: Autor.....	99
Figura 39. Diagrama de Flujo para el Código VRehab_2. Fuente: Autor.....	102
Figura 40. Preprocesamiento y Entrenamiento del Modelo de Aprendizaje Automático. Fuente: Autor.....	104
Figura 41. selección de objetos con diferentes durezas. Fuente: Autor.....	105
Figura 42. Diagrama de Flujo del Algoritmo en Arduino para la lectura del sensor piezoeléctrico. Fuente: Autor.....	106
Figura 43. Diagrama de Flujo del Algoritmo para el M5 Stack que gestiona el pwm de los motores de vibración. Fuente: Autor.....	107
Figura 44. Integración de sensor piezoeléctrico RP-S40-ST de Alta Precisión a mano mecánica. Fuente: Autor.....	108
Figura 45. Micromotor de vibración 1030 DC utilizados en el sistema de retroalimentación. Fuente: Autor.....	108
Figura 46. Pruebas de sujeción de objeto y captación de señal a partir del sensor piezoeléctrico. Fuente: Autor.....	109
Figura 47. Construcción de sistema de realimentación a partir de ingeniería inversa del brazalete MYO, adaptándolo a los requerimientos del proyecto. Fuente: Autor.....	110
Figura 48. Integración del Sistema. Fuente: Autor.....	111
Figura 49. Pruebas del primer tiempo. Fuente: Autor.....	114
Figura 50. Pruebas del segundo tiempo. Fuente: Autor.....	115
Figura 51. Momento de experimentación Tipo Test o tercer tiempo. Fuente: Autor.....	115
Figura 52. Pruebas del brazalete con una cubierta de tela para mayor percepción de vibración. Fuente: Autor.....	119
Figura 53. Validación de los ajustes realizados. Fuente: Autor.....	122
Figura 54. Validación del sistema integrado. Fuente: Autor.....	122

## **LISTA DE TABLAS**

---

Tabla I. Ritmos característicos en señales EEG clasificados por su frecuencia («Ondas cerebrales y su significado», 2019) .....	48
Tabla II. Primeros resultados de experimentación. Fuente: Autor. ....	116
Tabla III. Total "Si" y "No" pruebas preliminares. Fuente: Autor. ....	117
Tabla IV. Resultados después de ajustes. Fuente: Autor. ....	120
Tabla V. Intentos Realizados por los Usuarios. Fuente: Autor. ....	123
Tabla VI. Resultados antes y después de ajustes. Fuente: Autor. ....	123
Tabla VII. PARTES DE DISEÑO DE MANO DEL MODELO DE MANO VERSIÓN 1 DEL ROBOT INMOOV PARA ENSAMBLAJE .....	160

## **LISTA DE GRÁFICOS**

---

Gráfico 1. Porcentaje nivel de dureza reconocible pruebas preliminares. Fuente: Autor. ....	118
---	-----

# 1 INTRODUCCIÓN

---

La interacción entre los seres humanos y las máquinas ha experimentado un avance significativo a lo largo de las últimas décadas, marcada especialmente por el desarrollo de sistemas mecatrónicos que integran mecánica, electrónica y control computacional en una unidad funcional. Este trabajo se encuentra en la vanguardia de la investigación aplicada, abordando el desafío de diseñar, desarrollar y evaluar un sistema mecatrónico experimental para el control de un prototipo de prótesis de mano utilizando señales electroencefalográficas y proporcionando retroalimentación háptica al usuario (Lebedev & Nicoletis, 2006a).

A nivel global, el campo de las prótesis mecatrónicas ha alcanzado hitos notables, con avances tecnológicos que se han traducido en mejoras significativas en la calidad de vida de los usuarios. Empresas y laboratorios en países como Estados Unidos, Alemania y Japón lideran la investigación y desarrollo en este ámbito, con prótesis cada vez más sofisticadas que incluyen características como el movimiento controlado por el pensamiento y la sensación táctil. Según la Organización Mundial de la Salud (*World Health Organization (WHO)*), estas innovaciones son cruciales para abordar las necesidades de aproximadamente 30 millones de personas que requieren dispositivos protésicos y ortopédicos.

En Colombia, el desarrollo de prótesis mecatrónicas está en una etapa de crecimiento con el apoyo de universidades y centros de investigación que están trabajando para cerrar la brecha tecnológica con los líderes mundiales. Instituciones como la Universidad Nacional de Colombia (*Periódico UNAL*) y la Universidad de los Andes (Uniandes, 2020) han reportado avances en la creación de prótesis robóticas accesibles, poniendo énfasis en la adaptabilidad y la reducción de costos para hacer estos dispositivos más accesibles a la población.

El Departamento del Cauca, aunque enfrenta desafíos en términos de infraestructura y financiamiento para la investigación de punta, ha mostrado iniciativas prometedoras a través de la colaboración entre universidades locales y entidades gubernamentales. Estos esfuerzos buscan impulsar el desarrollo tecnológico y la innovación, con proyectos

que incluyen el diseño y la implementación de prótesis mecatrónicas (Minciencias et al., 2024), aunque a una escala más reducida en comparación con la escena nacional e internacional.

Con el auge de la neurociencia y la ingeniería biomédica, surge la necesidad de crear prótesis avanzadas que no solo reemplacen la funcionalidad mecánica de las extremidades perdidas, sino que también restablezcan la percepción sensorial. En respuesta a esta necesidad (Ran et al., 2020), el objetivo general de esta investigación es desarrollar un sistema mecatrónico experimental que permita a los usuarios controlar una prótesis de mano con la intención de movimiento interpretada a través de señales electroencefalográficas capturadas por el Kit AURA y experimentar una retroalimentación sensorial háptica.

Para lograr este propósito, se han establecido objetivos específicos que guían el desarrollo del proyecto: desde la evaluación y selección de componentes, pasando por la construcción del prototipo y la implementación de algoritmos de procesamiento de señales y aprendizaje automático, hasta el diseño de un sistema háptico que se integra perfectamente con la prótesis. Estos pasos están diseñados para asegurar que la prótesis no solo sea un sustituto mecánico, sino que también proporcione al usuario una experiencia sensorial enriquecedora. La metodología adoptada para alcanzar los objetivos se basa en la Metodología V (Morelos et al., 2019), un enfoque estructurado que abarca desde la definición de requisitos hasta la integración y las pruebas del sistema. Esta metodología, adaptada a este proyecto, se despliega en las siguientes fases sucesivas: diseño de ingeniería y modelado, construcción y codificación inicial del prototipo, procesamiento avanzado de señales y machine learning, desarrollo de retroalimentación háptica, y finalmente, la integración y pruebas del sistema completo.

A través de esta investigación, se espera no solo avanzar en el campo de las prótesis robóticas sino también proporcionar una solución tangible que mejore la calidad de vida de los usuarios, ofreciéndoles una mayor autonomía y una experiencia más natural y cercana a la funcionalidad humana perdida. Este trabajo, por tanto, no solo tiene un valor tecnológico y científico sino también un profundo impacto social.

## 2 PLANTEAMIENTO Y FORMULACIÓN DEL PROBLEMA

---

La pérdida de una extremidad es un desafío que puede cambiar drásticamente la vida de una persona. Las limitaciones físicas que resultan pueden ser enormes, limitando la capacidad de una persona para realizar tareas cotidianas y, en última instancia, afectando su calidad de vida (Ziegler-Graham et al., 2008a). Las prótesis han sido durante mucho tiempo una respuesta a este problema, proporcionando a las personas que las utilizan una forma de recuperar parte de la funcionalidad perdida. Sin embargo, las prótesis tradicionales a menudo carecen de la capacidad de proporcionar un control intuitivo y una retroalimentación sensorial adecuada, lo que puede limitar su utilidad y eficacia (Biddiss & Chau, 2007).

Las prótesis de extremidades superiores, y especialmente las prótesis de mano, requieren un control particularmente preciso debido a la gran cantidad de movimientos finos y complejos que las manos pueden realizar. En este contexto, el control intuitivo y la retroalimentación sensorial son especialmente importantes. Sin embargo, a pesar de los avances en la tecnología de prótesis, estos siguen siendo desafíos significativos en el campo de las prótesis de extremidades superiores (Belter et al., 2013).

Las prótesis de mano actuales a menudo utilizan métodos como la electromiografía (EMG) para controlar los movimientos de la prótesis. Este tipo de control se basa en la detección de las señales eléctricas generadas por los músculos residuales del usuario, que luego se utilizan para controlar los movimientos de la prótesis (Farina et al., 2014a). Sin embargo, estos métodos pueden ser limitados en términos de la cantidad y calidad de los movimientos que pueden proporcionar. Aunque la EMG puede permitir cierto grado de control sobre una prótesis, este control a menudo no es intuitivo y puede requerir un esfuerzo mental significativo por parte del usuario (Scheme & Englehart, 2011), lo que puede limitar aún más la interacción del usuario con su entorno.

A diferencia de la electromiografía (EMG), que detecta las señales eléctricas generadas por los músculos para controlar una prótesis, la electroencefalografía (EEG) tiene el potencial de permitir un control más directo e intuitivo de las prótesis. Esto se

debe a que la EEG no se basa en la actividad muscular, sino en las señales cerebrales que reflejan las intenciones motoras directas del usuario (Nicolas-Alonso & Gomez-Gil, 2012).

El control basado en EMG a menudo requiere que el usuario realice contracciones musculares específicas para producir comandos de control, lo que puede ser fatigante y contra intuitivo. Además, la EMG puede verse afectada por factores como la fatiga muscular y las interferencias de otras señales musculares, lo que puede limitar su eficacia y precisión (Farina et al., 2014a).

Por otro lado, el uso de señales EEG para controlar prótesis puede superar algunos de estos desafíos. Las señales EEG reflejan directamente la actividad cerebral asociada con las intenciones motoras, lo que puede permitir un control más intuitivo y natural de las prótesis (Meng et al., 2016a). Al captar estas señales cerebrales, es posible decodificar las intenciones del usuario sin necesidad de contracciones musculares físicas ni la intervención de otras señales del cuerpo.

Además, la EEG puede proporcionar un mayor número de comandos de control potenciales, ya que el cerebro es capaz de generar una gran variedad de señales distintas. Esto puede permitir un control más preciso y versátil de las prótesis, en comparación con los métodos basados en EMG. Sin embargo, el uso de señales EEG para controlar prótesis también presenta desafíos, como la necesidad de procesar y traducir estas complejas señales cerebrales en comandos útiles para la prótesis en tiempo real. Además, las señales EEG pueden verse afectadas por artefactos y ruido, lo que exige métodos de procesamiento de señales robustos y eficaces (Bhattacharyya et al., 2014).

A pesar de los avances en las tecnologías protésicas, todavía hay desafíos significativos en proporcionar una retroalimentación sensorial completa y satisfactoria. Muchas prótesis modernas ofrecen alguna forma de retroalimentación háptica, que se refiere a la capacidad de sentir y manipular objetos a través del tacto. Sin embargo, estas soluciones suelen ser limitadas y no logran recrear una experiencia táctil completa para el usuario. (Antfolk et al., 2013).

La retroalimentación háptica tiene el potencial de mejorar en gran medida la interacción del usuario con su entorno y la realización de tareas precisas y complejas. La falta de una retroalimentación táctil realista puede limitar la manipulación efectiva de objetos y reducir la sensación de "propiedad" de la prótesis por parte del usuario. Desafortunadamente, los métodos actuales para proporcionar este tipo de retroalimentación suelen ser complicados o poco prácticos para su uso cotidiano (Cipriani et al., 2014).

Además de los desafíos con la retroalimentación sensorial, la personalización de las prótesis también sigue siendo un obstáculo. Aunque las prótesis han avanzado en términos de forma y función, aún existe una necesidad apremiante de personalización para adaptarse a las necesidades individuales de cada usuario. Esto incluye no sólo el ajuste y la comodidad de la prótesis, sino también la apariencia estética, un aspecto que a menudo se pasa por alto en el diseño de las prótesis (Cordella et al., 2016). Por último, el costo de las prótesis avanzadas sigue siendo un problema crítico. Las prótesis de extremidades superiores más sofisticadas y funcionales suelen ser inaccesibles desde el punto de vista financiero para muchos de los que más las necesitan. Esto limita su accesibilidad y uso generalizado, lo que subraya la necesidad de soluciones más asequibles y efectivas (J. Zuniga et al., 2015).

Finalmente, y después de un análisis detallado del problema, es evidente que hay una necesidad crítica de un sistema innovador que pueda superar las limitaciones actuales en el control de las prótesis de mano. La combinación de señales electroencefalográficas y retroalimentación háptica tiene el potencial de mejorar significativamente la funcionalidad y la interacción del usuario con las prótesis. Por lo tanto, este trabajo se centra en diseñar, desarrollar y evaluar un sistema mecatrónico experimental para el control de un prototipo de prótesis de mano mediante señales electroencefalográficas y retroalimentación háptica. Todo esto con el objetivo de dar respuesta a ¿Cómo puede un operador humano controlar una mano robótica con la mente y sentir una respuesta háptica? y así contribuir a superar las barreras existentes y ofrecer una solución más intuitiva y eficaz para los usuarios de prótesis de mano, mejorando su calidad de vida y su independencia en las actividades diarias.

### 3 JUSTIFICACIÓN

---

En Colombia, las amputaciones parciales o totales de extremidades ocurren por diversas razones, que van desde enfermedades hasta accidentes y conflictos armados. Según la Asociación Colombiana de Medicina Física y Rehabilitación, la tasa de amputación en el país oscila entre 200 y 300 personas por cada cien mil habitantes (Valencia et al., 2015). Estas cifras son alarmantes y apuntan a la necesidad urgente de soluciones prácticas y eficaces para las personas afectadas.

Además, la población de personas con amputaciones aumenta en sectores con factores de riesgo adicionales. Por ejemplo, las personas con diabetes, problemas en los sistemas vasculares y enfermedades crónicas tienen una mayor probabilidad de requerir una amputación (Boulton et al., 2005). Estas enfermedades pueden llevar a complicaciones que, en última instancia, requieran la eliminación de una extremidad para preservar la vida del individuo.

Por otro lado, no se puede ignorar que las condiciones genéticas y los problemas al nacer también pueden llevar a la necesidad de una prótesis. Las malformaciones congénitas, que pueden resultar de factores genéticos o de condiciones durante el embarazo, pueden dar lugar a la ausencia de una extremidad o a su desarrollo incompleto (Rodríguez González & Soriano Padilla, 2015) . Estos individuos pueden depender de una prótesis desde una edad temprana, lo que subraya aún más la importancia de soluciones eficientes y accesibles.

Por su parte, las intervenciones quirúrgicas que llevan a las amputaciones tienen dos objetivos claros. En primer lugar, tratan de eliminar o contrarrestar la causa subyacente para reducir los riesgos y preservar la vida del paciente (Boulton et al., 2005). Sin embargo, también buscan permitir una rehabilitación adecuada posterior para lograr la mejor adaptación de una prótesis y restaurar las funciones motoras asociadas a la mano de la mejor manera posible.

La necesidad de prótesis es una consecuencia directa de los problemas mencionados anteriormente (Ziegler-Graham et al., 2008a). Sin embargo, el desarrollo

de prótesis ha estado estrechamente ligado al avance de la robótica asistencial, lo que las convierte en una de las aplicaciones destacadas en el campo de la bioingeniería. Aunque estas tecnologías han existido durante más de tres décadas, su evolución no ha sido tan rápida como se esperaba inicialmente.

Varias razones explican esta falta de progreso. Una de las más prominentes es que la funcionalidad que se puede obtener con respecto al uso de brazos y manos sanos es limitada. Estas limitaciones pueden ser resultado de restricciones mecánicas, estrategias de manipulación inadecuadas, o la habilidad del usuario para transmitir las órdenes adecuadas para producir los movimientos deseados (Micera et al., 2010).

Además, muchas prótesis dependen de las señales mioeléctricas generadas en los músculos del usuario para su activación. Sin embargo, si el paciente tiene limitaciones en sus músculos remanentes y no puede contraerlos fácilmente, las señales electromiográficas (EMG) del usuario no pueden ser captadas y la manipulación de la prótesis se vuelve más difícil sin métodos invasivos (Farina et al., 2014a).

Adicionalmente, la identificación de la intención de movimiento del usuario y la degradación de la señal muscular son desafíos importantes. En pacientes con lesiones antiguas, estas dificultades se agravan, ya que el paciente puede perder las vías de comunicación con el sistema nervioso y la capacidad de controlar el músculo voluntariamente (Fougner et al., 2012).

A pesar de estos desafíos, se han realizado esfuerzos significativos para avanzar en este campo. En los últimos años, ha habido un enfoque en el desarrollo de sistemas biónicos híbridos que permitan la conexión del sistema nervioso humano con prótesis o incluso máquinas robóticas externas a través de interfaces naturales (Zhang et al., 2020a).

Por consiguiente, este proyecto se enmarca en un área de investigación de gran importancia y en constante desarrollo. La meta principal es incrementar la calidad de vida y la autonomía de los usuarios de prótesis de mano en Colombia y en el resto del mundo. Para lograr esto, se emprenderá el diseño, desarrollo y evaluación de un sistema mecatrónico a nivel experimental. El enfoque de este sistema estará centrado en el

control de la intención de movimiento de un prototipo de prótesis de mano, utilizando señales electroencefalográficas recogidas a través del Kit AURA como biosensor. Adicionalmente, se proporcionará retroalimentación háptica sensorial a los usuarios, lo que marcará un notable avance en la integración y la interacción del usuario con la prótesis.

## **4 OBJETIVOS**

---

### **4.1 OBJETIVO GENERAL**

Desarrollar un sistema mecatrónico para el control de un prototipo de prótesis de mano robótica mediante señales electroencefalográficas y retroalimentación háptica.

### **4.2 OBJETIVOS ESPECÍFICOS**

1. Construir un prototipo físico de prótesis de mano robótica y un sistema de retroalimentación háptica.
2. Generar un algoritmo de procesamiento de señales y captación de datos electroencefalográficos basados en Machine Learning.
3. Integrar el prototipo físico de prótesis de mano robótica con el sistema de retroalimentación háptica para la entrega de sensaciones táctiles diferenciada.
4. Evaluar el desempeño del sistema integrado por medio de pruebas a pacientes sanos.

## 5 ESTADO DEL ARTE

---

El desarrollo de la tecnología en el ámbito de la biomedicina ha abierto puertas a innovaciones que han transformado significativamente la calidad de vida de las personas con discapacidad. Entre estas innovaciones, las prótesis mecatrónicas controladas por señales electroencefalográficas (EEG) con capacidad de retroalimentación háptica han surgido como una solución prometedora para restaurar la funcionalidad perdida y mejorar la autonomía de los individuos con amputaciones de las extremidades superiores.

Las señales EEG capturan la actividad eléctrica del cerebro y, cuando se procesan adecuadamente, pueden utilizarse para controlar dispositivos externos, como las prótesis de mano. Sin embargo, para que estas prótesis sean verdaderamente efectivas, deben ser capaces de imitar de cerca la funcionalidad de una mano humana, lo que implica no solo la capacidad de moverse y agarrar objetos, sino también de sentir el entorno. Aquí es donde la retroalimentación háptica juega un papel crucial, proporcionando a los usuarios una sensación de tacto que mejora la interacción con el entorno.

Este estado del arte se centra en la revisión de la literatura actual sobre prótesis mecatrónicas controladas por señales EEG y con capacidad de retroalimentación háptica. El objetivo es proporcionar una visión clara del campo actual, identificar las limitaciones de las investigaciones previas y destacar las oportunidades para futuras investigaciones.

Este estado del arte está estructurado de la siguiente manera: primero, se discute el uso de las señales EEG en el control de prótesis y se revisan las técnicas de procesamiento de señales utilizadas. Luego, se examinan los sistemas mecatrónicos en las prótesis de mano y se exploran diferentes diseños de prótesis. A continuación, se aborda la importancia de la retroalimentación háptica y se examinan los desafíos asociados con la interfaz usuario-prótesis. Posteriormente, se discute el uso del Kit AURA como biosensor. Finalmente, se consideran las implicaciones éticas y sociales de estas prótesis, se examina el futuro de las prótesis de mano controladas por EEG y se concluye con los trabajos futuros de la investigación en este campo.

## **5.1 USO DE SEÑALES ELECTROENCEFALOGRÁFICAS EN EL CONTROL DE PRÓTESIS**

Las señales EEG se han utilizado para controlar dispositivos a través de una interfaz cerebro-computadora (BCI), que permite a los usuarios interactuar con el entorno utilizando solo su actividad cerebral. En particular, estas técnicas se han utilizado para controlar prótesis de mano, permitiendo a los usuarios con amputaciones o parálisis usar estas prótesis de manera similar a una mano natural (Donchin et al., 2000).

Las señales electroencefalográficas (EEG) son medidas de las fluctuaciones eléctricas generadas por la actividad neuronal del cerebro. Estas señales se capturan utilizando electrodos colocados en el cuero cabelludo del paciente. Los electrodos captan las señales eléctricas producidas por las neuronas, que luego se amplifican y se registran para su análisis posterior (Niedermeyer & Silva, 2005). Numerosos estudios han investigado el uso de señales EEG para controlar prótesis de mano a continuación se presentan algunos de los más relevantes:

(Müller-Putz et al., 2006) describieron un método para mejorar la adquisición de señales EEG utilizando electrodos de gel seco. Los autores argumentaron que este método ofrece una adquisición de señales más cómoda y rápida en comparación con los métodos tradicionales. En su estudio, utilizó un sistema de prótesis de mano controlado por EEG de baja densidad (8 canales) y demostró que el uso de electrodos de gel seco no degradó la calidad de la señal, lo que podría facilitar el uso de prótesis controladas por EEG en la vida diaria.

(Bhattacharyya et al., 2014) desarrollaron un sistema de control de prótesis de mano basado en EEG utilizando una red neuronal artificial. Los electrodos de EEG se colocaron en el cuero cabelludo de los participantes para detectar las señales cerebrales asociadas con la intención de mover la mano. El sistema fue capaz de clasificar estas señales con una precisión del 76%, lo cual es una tasa de éxito significativa teniendo en cuenta que las señales cerebrales son extremadamente complejas y pueden ser influenciadas por una serie de factores. Este estudio es un paso importante hacia la

creación de prótesis de mano controladas por la mente que pueden mejorar la calidad de vida de las personas con amputaciones de la mano.

(Edelman et al., 2016) demostraron el uso de electrodos de EEG de alta densidad para capturar señales cerebrales. Utilizaron un algoritmo de aprendizaje profundo para interpretar las señales, alcanzando una precisión de clasificación de hasta el 85%. Este estudio destaca la utilidad de los electrodos de EEG de alta densidad para capturar una gran cantidad de información sobre la actividad cerebral, así como el potencial de los algoritmos de aprendizaje profundo para interpretar estas señales complejas.

(Meng et al., 2016b) En este estudio, Meng y sus colegas utilizaron un sistema de clasificación de EEG basado en la técnica de máquinas de vectores de soporte para controlar una prótesis de mano. El sistema fue capaz de clasificar las señales con una precisión del 82%, lo que representa un avance importante en la precisión de la clasificación en comparación con los estudios anteriores. Este estudio también muestra el potencial de las técnicas de aprendizaje automático para mejorar el control de las prótesis de mano.

(Branco et al., 2017) utilizaron un casco de electroencefalografía de alta densidad para adquirir señales EEG. Las señales EEG se procesaron utilizando un algoritmo de clasificación basado en la técnica de máquinas de vectores de soporte (SVM). Los autores demostraron que este método podría usarse para controlar una prótesis de mano en tiempo real con una precisión del 80%, lo que representa un avance importante en la mejora de la funcionalidad de las prótesis de mano.

(Lu et al., 2017) presentaron un nuevo enfoque para el procesamiento de señales EEG basado en el aprendizaje automático. El estudio utilizó una prótesis de mano robótica y un dispositivo de adquisición de señales EEG de 32 canales. Los autores demostraron que su método podía mejorar la precisión del control de prótesis, alcanzando una precisión de clasificación de hasta el 88%.

(Brandl & Blankertz, 2020) utilizaron una combinación de técnicas de procesamiento de señales y aprendizaje automático para interpretar señales EEG. Demostraron que su sistema podía detectar la intención de movimiento con una precisión

de hasta el 80%. Este estudio es importante porque muestra cómo las técnicas de aprendizaje automático pueden usarse para interpretar las señales cerebrales, lo que podría tener implicaciones para una variedad de aplicaciones, desde el control de prótesis hasta la detección de enfermedades neurológicas.

(Gu et al., 2020) utilizaron un casco de EEG portátil para capturar señales cerebrales y un algoritmo de aprendizaje profundo para interpretarlas. Su sistema fue capaz de clasificar las señales con una precisión del 88%, lo que representa un avance significativo en la precisión de la clasificación. Este estudio también demuestra el potencial de los sistemas portátiles de EEG, que podrían permitir a los usuarios controlar prótesis y otros dispositivos con su mente mientras se mueven libremente en el mundo.

(Guerrero-Mendez et al., 2023) aplicaron redes neuronales profundas para procesar señales EEG. Utilizaron una prótesis de mano robótica y un dispositivo de adquisición de señales EEG de 64 canales. Los autores demostraron que su enfoque mejora la precisión de la clasificación en comparación con los métodos tradicionales de procesamiento de señales, alcanzando una precisión de hasta el 85% en algunas tareas.

En un estudio reciente de 2023, (Yadav & Maini, 2023) presentaron un sistema de prótesis de mano controlado por EEG que utiliza un algoritmo de aprendizaje profundo para interpretar las señales cerebrales. Este sistema ha demostrado ser eficaz para ayudar a los usuarios a realizar tareas del día a día con la prótesis de mano. Utilizaron una prótesis de mano robótica y un dispositivo de adquisición de señales EEG de 128 canales. Los autores encontraron que su sistema podía interpretar con precisión las intenciones del usuario, permitiéndoles controlar la prótesis de mano con una precisión de clasificación de hasta el 90%.

(Pawan & Dhiman, 2023) utilizaron una combinación de algoritmos de aprendizaje automático para interpretar las señales EEG. Demostraron que esta combinación podía mejorar la precisión de la clasificación en comparación con un solo algoritmo, con una precisión de clasificación de hasta el 90%. Este estudio resalta la importancia de las técnicas de aprendizaje automático en la interpretación de las señales cerebrales y

sugiere que la combinación de varios algoritmos puede ser una estrategia efectiva para mejorar la precisión de la clasificación.

(Bai et al., 2023) presentaron un sistema de control de prótesis de mano basado en EEG que utiliza una red neuronal convolucional para interpretar las señales cerebrales. El sistema fue capaz de clasificar las señales con una precisión del 92%, lo que es una tasa de éxito extremadamente alta para este tipo de tarea. Este estudio demuestra el potencial de las redes neuronales convolucionales, un tipo de algoritmo de aprendizaje profundo, para interpretar las señales cerebrales y controlar las prótesis de mano, lo que podría tener un impacto significativo en la vida de las personas con amputaciones de la mano.

En resumen, la investigación en el control de prótesis mediante señales EEG ha avanzado significativamente en los últimos años, con mejoras en la adquisición de señales, las técnicas de procesamiento de señales y la precisión del control de prótesis. Sin embargo, aún quedan desafíos en la implementación de estos sistemas en aplicaciones de la vida real, y se espera que la investigación futura continúe abordando estos problemas.

Es importante destacar que estos avances no solo benefician a los usuarios de prótesis de mano, sino que también tienen implicaciones más amplias para el campo de la neurociencia y la tecnología de interfaz cerebro-computadora. El uso de técnicas de aprendizaje automático y aprendizaje profundo para interpretar las señales cerebrales puede tener un amplio rango de aplicaciones, desde el desarrollo de dispositivos de asistencia para personas con discapacidades hasta la detección y el tratamiento de enfermedades neurológicas.

## **5.2 RETROALIMENTACIÓN HÁPTICA EN PRÓTESIS**

La retroalimentación háptica se ha vuelto cada vez más relevante en el diseño y desarrollo de prótesis, proporcionando a los usuarios una sensación táctil y la capacidad de interactuar con su entorno de una manera más intuitiva y natural. Esta sección ofrece un resumen del estado actual de la retroalimentación háptica en prótesis.

La retroalimentación háptica se refiere a la recreación de la sensación de tacto mediante la aplicación de fuerzas, vibraciones u otros estímulos al usuario (Antfolk et al., 2013). En las prótesis, esta tecnología tiene como objetivo proporcionar a los usuarios una percepción de la fuerza de agarre y la forma, tamaño y textura de los objetos, lo que puede mejorar significativamente la funcionalidad de la prótesis y la calidad de vida del usuario (D'Alonzo & Cipriani, 2012).

La implementación de la retroalimentación háptica en las prótesis puede ser un desafío debido a la necesidad de interfaces de usuario intuitivas y sistemas de control efectivos. Se han explorado varias técnicas, como las vibraciones mecánicas, la estimulación eléctrica y la estimulación térmica (Hebert et al., 2014).

A pesar de los avances, la retroalimentación háptica en prótesis aún enfrenta varios desafíos. Estos incluyen la miniaturización de los componentes, la mejora de la durabilidad y la confiabilidad, y la adaptación a las necesidades individuales de los usuarios. Además, todavía hay un largo camino por recorrer para lograr una sensación táctil que se sienta "natural" para el usuario (Saal & Bensmaia, 2015).

Algunas de las investigaciones más recientes han tratado de proporcionar retroalimentación háptica a través de la estimulación directa de los nervios periféricos. Por ejemplo, un estudio de 2016 utilizó una interfaz de nervio periférico para proporcionar retroalimentación táctil y de posición a los usuarios de prótesis (Serrancolí et al., 2016).

El futuro de la retroalimentación háptica en las prótesis parece prometedor. Con los continuos avances en la tecnología, es probable que veamos prótesis cada vez más sofisticadas y capaces de proporcionar una retroalimentación háptica más precisa y naturalista. A medida que se superen los desafíos actuales, la retroalimentación háptica puede convertirse en una característica estándar en todas las prótesis, mejorando significativamente la funcionalidad y la calidad de vida de los usuarios de prótesis (Charkhkar et al., 2018).

El aprendizaje automático y las técnicas de inteligencia artificial también se han utilizado para mejorar la eficacia de la retroalimentación háptica. Un estudio de 2022

demonstró que el uso de algoritmos de aprendizaje automático puede mejorar la precisión de la retroalimentación háptica en las prótesis (Wells et al., 2022).

Teniendo en cuenta la revisión del estado del arte en este campo se puede decir que la retroalimentación háptica en prótesis ha experimentado un desarrollo significativo en los últimos años, y ha demostrado ser una herramienta esencial para mejorar la funcionalidad y la calidad de vida de los usuarios de prótesis. La capacidad de proporcionar una retroalimentación sensorial precisa puede mejorar enormemente la interacción del usuario con el entorno, permitiéndole manejar objetos de manera más efectiva y realizar tareas con mayor precisión.

### **5.3 CONTROL BRAIN COMPUTER INTERFACE (BCI) PARA PRÓTESIS**

Las interfaces cerebro-computadora (BCI, por sus siglas en inglés) proporcionan una conexión directa entre el cerebro y los dispositivos externos, permitiendo a los usuarios controlar una variedad de funciones usando solo sus pensamientos. En las prótesis, los BCI pueden permitir a los usuarios mover y controlar sus prótesis de una manera que imita la funcionalidad natural de la extremidad. A continuación, se presenta un resumen del estado actual del control BCI para prótesis.

Jacques Vidal (Vidal, 1973a), en este artículo histórico, propuso por primera vez la idea de comunicación directa entre el cerebro y la computadora, y acuñó el término "interfaz cerebro-computadora" (BCI). Vidal describió los fundamentos teóricos y técnicos para registrar la actividad eléctrica del cerebro mediante electroencefalografía (EEG) y utilizar estas señales para controlar dispositivos externos. Aunque en ese momento no se realizaron experimentos concretos, este trabajo es reconocido por anticipar el campo de las interfaces cerebro-computadora y por establecer las bases para futuras investigaciones en este ámbito.

En este estudio, (Wolpaw et al., 1991) desarrollaron una de las primeras interfaces cerebro-computadora (BCI) basadas en EEG para controlar el movimiento del cursor. Los sujetos aprendieron a controlar voluntariamente sus ritmos alfa y beta, que se detectaron y tradujeron en movimientos del cursor. Este estudio demostró por primera vez que las

personas pueden aprender a controlar sus ondas cerebrales para interactuar con una computadora, proporcionando la base para el desarrollo de BCI más sofisticadas.

(Birbaumer et al., 1999) en este estudio presentó un "dispositivo de ortografía" para personas con parálisis severa. Los participantes fueron entrenados para controlar sus potenciales de oscilación lenta a través de bio feedback, lo que les permitió seleccionar letras en una pantalla y deletrear palabras. Este estudio demostró que las interfaces cerebro-computadora pueden ofrecer una vía de comunicación para personas con trastornos motores graves, como la parálisis de bloqueo.

(Leuthardt et al., 2004) en este estudio utilizó señales de electrocorticografía (ECoG), que se obtienen colocando electrodos directamente en la superficie del cerebro. Los participantes, que eran pacientes con epilepsia sometidos a cirugía, utilizaron las señales ECoG para controlar un cursor en una pantalla. Este estudio demostró que las señales ECoG proporcionan una forma más detallada y precisa de medir la actividad cerebral en comparación con las señales EEG, y que las interfaces cerebro-computadora basadas en ECoG pueden proporcionar un control más preciso y flexible.

En este estudio, (Pfurtscheller et al., 2005) demostraron que una interfaz cerebro-computadora (BCI) basada en EEG puede utilizarse para controlar la estimulación eléctrica funcional (FES) en un paciente tetrapléjico. El FES es un método que utiliza corrientes eléctricas para activar los nervios que controlan los músculos, permitiendo el movimiento en personas con parálisis. El paciente en este estudio fue capaz de usar el BCI para controlar la FES y realizar acciones como agarrar objetos. Este estudio mostró que las BCIs pueden integrarse con otras tecnologías para ofrecer más opciones de control a las personas con discapacidades motoras.

En este estudio transformador, (L. R. Hochberg et al., 2006) informaron el uso de una interfaz cerebro-computadora implantable para controlar dispositivos prostéticos. El paciente, que tenía tetraplejia, fue capaz de mover un cursor en la pantalla y manipular una prótesis robótica para alcanzar y agarrar objetos simplemente pensando en los movimientos. Este estudio demostró que las interfaces cerebro-computadora pueden restaurar algunas formas de interacción con el mundo en personas con parálisis severa.

(Schwartz et al., 2006) proporciona una visión general de las interfaces cerebro-computadora para la restauración del movimiento, centrándose en las prótesis neurales que pueden ser controladas por la actividad cerebral. Los autores describen el estado del arte en BCIs y discuten los desafíos y oportunidades futuras en el campo. Esto incluye cuestiones técnicas, como la mejora de la decodificación de las señales cerebrales y la miniaturización de los dispositivos implantables, así como cuestiones éticas y regulatorias relacionadas con el uso de estas tecnologías.

Este estudio de (L. R. Hochberg et al., 2012) avanzó en el uso de la interfaz cerebro-computadora para ayudar a personas con tetraplejia. Los participantes fueron capaces de utilizar un brazo robótico controlado por la mente para realizar acciones como alcanzar y agarrar objetos. Este estudio fue significativo porque mostró un nivel de control más sofisticado y detallado de los dispositivos robóticos utilizando la actividad cerebral.

Este estudio de (Collinger et al., 2013) demostró el uso de una interfaz cerebro-computadora intracortical para permitir la comunicación de alta velocidad en personas con parálisis. Los participantes fueron capaces de escribir a velocidades comparables a las de una persona que teclea en un smartphone, lo que demuestra el potencial de las interfaces cerebro-computadora para restaurar la comunicación en personas con graves discapacidades motoras.

Este estudio de (Gilja et al., 2015) se mostró la aplicación clínica de una prótesis neural de alto rendimiento. Los participantes con parálisis pudieron utilizar la prótesis para controlar un cursor en una pantalla de ordenador con precisión y velocidad, lo que demuestra el potencial de las prótesis neurales para mejorar la interacción con el mundo digital.

(Aflalo et al., 2015) demostró la capacidad para decodificar la imaginación del movimiento del córtex parietal posterior de un humano tetrapléjico. Los participantes fueron capaces de controlar un cursor en una pantalla simplemente imaginando el movimiento de sus propias manos, lo que es un paso importante hacia el desarrollo de interfaces cerebro-computadora que pueden ser controladas mediante la imaginación del movimiento.

(Vansteensel et al., 2016) presentó uno de los primeros interfaces cerebro-computadora totalmente implantados utilizados por un paciente con síndrome de encierro debido a la esclerosis lateral amiotrófica (ELA). El sistema permitía la comunicación funcional en la vida diaria, lo que representa un hito importante en el desarrollo de tecnologías BCI para la asistencia de pacientes con graves discapacidades motoras.

(Staff, 2019) demostró la viabilidad de la comunicación basada en la interfaz cerebro-computadora en personas en estado de bloqueo completo (CLIS), un estado en el que los individuos están completamente paralizados y no pueden comunicarse verbalmente ni mediante movimientos oculares. Los investigadores utilizaron una técnica de imagen cerebral no invasiva llamada espectroscopia de infrarrojo cercano para medir las respuestas cerebrales de los participantes a las preguntas, permitiéndoles responder 'sí' o 'no'. Este estudio mostró que las BCIs pueden proporcionar una forma de comunicación para las personas en CLIS, que anteriormente se pensaba que estaban completamente desconectadas del mundo exterior.

(Canny et al., 2023) demostró la aplicabilidad del uso de interfaces cerebro-computadora para facilitar la comunicación en un paciente con síndrome de encerrado. El paciente fue capaz de utilizar una interfaz cerebro-computadora para comunicarse de manera efectiva, lo que demuestra la utilidad de esta tecnología para las personas con graves discapacidades motoras.

Los avances significativos en las interfaces cerebro-computadora (BCI) y las neuro prótesis, resaltados a través de una serie de estudios influyentes, han demostrado su capacidad para proporcionar medios de interacción y comunicación efectiva para individuos con parálisis severa o tetraplejia. Estos desarrollos incluyen el control de dispositivos robóticos y la comunicación de alta velocidad, ambos esenciales para la mejora de la calidad de vida de las personas con discapacidades motoras graves. La inclusión de este tema en este proyecto de grado aporta una visión en profundidad de cómo la tecnología BCI puede transformar radicalmente la vida de aquellos con limitaciones físicas, subrayando la importancia de la investigación y el desarrollo continuos en este campo emergente y altamente relevante.

## 5.4 MIRAI INNOVATION RESEARCH INSTITUTE JAPAN

Ubicado en Osaka, Japón, el Mirai Innovation Research Institute Japan, fundado por el Dr. Christian Peñaloza, se erige como un prominente centro de investigación y desarrollo. Este instituto nace con la visión de integrar jóvenes talentos de Latinoamérica en el ámbito de la innovación tecnológica, promoviendo no solo su formación avanzada sino también el intercambio cultural entre Japón y Latinoamérica. Mirai se ha establecido como un referente en la generación de proyectos innovadores, adoptando como base de sus investigaciones los trabajos previos realizados o propuestos en su centro tecnológico, lo cual facilita el avance continuo en la aplicación de nuevas tecnologías y fortalece los lazos culturales y profesionales entre ambas regiones.

En este artículo (Penaloza et al., 2014) abordan el problema de la fatiga mental causada por el uso prolongado de los Sistemas de Interfaz Cerebro-Máquina (BMI). Los autores proponen un sistema que se vuelve gradualmente autónomo aprendiendo las preferencias del usuario y considerando la retroalimentación de percepción de error. Como aplicación particular, muestran que su sistema permite a los pacientes controlar electrodomésticos electrónicos en una habitación de hospital, y aprende la correlación de los datos del sensor de la habitación, los estados cerebrales y los comandos de control del usuario. Además, utilizan una retroalimentación de percepción de error basada en un potencial cerebral llamado Negatividad Relacionada con el Error (ERN) - que ocurre espontáneamente cuando el usuario percibe un error cometido por el sistema - para corregir los errores del sistema y mejorar su rendimiento de aprendizaje. En cuanto a la metodología y los materiales utilizados, se describe el diseño y la construcción de interfaces de hardware y software, la adquisición y el procesamiento de señales cerebrales, y el entrenamiento del sistema utilizando técnicas de aprendizaje automático. Los resultados experimentales con voluntarios demostraron que el sistema reduce el nivel de fatiga mental y logra más del 90% de rendimiento de aprendizaje total cuando se considera la retroalimentación de percepción de error. Este enfoque propuesto sugiere una nueva forma de diseñar sistemas BMI que incorporan capacidades de aprendizaje y retroalimentación de percepción de error para volverse gradualmente autónomos. Una vez entrenado, el sistema puede predecir comandos de control en nombre del usuario en

condiciones similares y, si el sistema comete un error, se considera la retroalimentación de percepción de error del usuario para mejorar el rendimiento de aprendizaje del sistema.

En este artículo (Penaloza et al., 2018) se centra en los sistemas de interfaz cerebro-computadora (BCI) basados en EEG que han demostrado su potencial para ayudar a los pacientes con devastadoras condiciones de parálisis motora. No obstante, existe un gran interés en orientar la tendencia de los BCI hacia aplicaciones destinadas a usuarios saludables. Si bien la operación de los BCI depende de factores tecnológicos (es decir, algoritmo de clasificación de patrones de EEG) y humanos (es decir, cuán bien la persona puede generar patrones de EEG de buena calidad), es este último aspecto el que se investiga menos. Para controlar un BCI basado en la imaginación motora, los usuarios necesitan aprender a modular sus ritmos cerebrales sensomotrices practicando la imaginación motora utilizando un protocolo de entrenamiento clásico con retroalimentación visual abstracta. En este trabajo, se investiga un protocolo de entrenamiento de BCI diferente utilizando un robot androide humanoide (Geminoid HI-2) para proporcionar retroalimentación visual realista. El protocolo de entrenamiento propuesto aborda las deficiencias del enfoque clásico y aprovecha las capacidades del usuario con habilidades corporales. Los resultados experimentales sugieren que el entrenamiento de BCI basado en retroalimentación de androide mejora la modulación de los ritmos sensomotrices durante la tarea de imaginación motora. Además, se discute cómo la influencia de la ilusión de transferencia de propiedad del cuerpo hacia el androide podría tener un efecto en la modulación de la actividad de desincronización/sincronización relacionada con eventos.

Finalmente, (Penaloza & Nishio, 2018) en este artículo se centran en los sistemas de interfaz cerebro-máquina (BMI) que han sido ampliamente estudiados para permitir a las personas con condiciones de parálisis motora controlar dispositivos robóticos asistentes que reemplazan o recuperan la función perdida, pero no para ampliar las capacidades de los usuarios saludables. Se informa de un experimento en el que los participantes saludables pudieron extender sus capacidades utilizando un BMI no invasivo para controlar un brazo robótico de aspecto humano y lograr la multitarea. Los

resultados experimentales demuestran que los participantes pudieron controlar de manera confiable el brazo robótico con el BMI para realizar una tarea orientada a un objetivo mientras utilizaban simultáneamente sus propios brazos para realizar una tarea diferente. Este resultado abre posibilidades para explorar futuras aplicaciones de aumento del cuerpo humano para personas saludables que no solo mejoran su capacidad para realizar una tarea en particular, sino que también extienden sus capacidades físicas para realizar múltiples tareas simultáneamente.

Tras realizar un análisis exhaustivo y profundo del estado del arte y de la tecnología desarrollada por Mirai, es necesario reconocer la importancia de seguir avanzando en esta línea de investigación. En el campo emergente y en rápida evolución de las interfaces cerebro-máquina y la neuro tecnología, la innovación y el progreso constante son esenciales.

La tecnología avanzada desarrollada por Mirai, desde sistemas de aprendizaje autónomo hasta protocolos de entrenamiento mejorados con robots humanoides, destaca la necesidad de la innovación y la exploración constante. Este análisis ha proporcionado una perspectiva invaluable sobre el estado actual de la tecnología y ha subrayado la necesidad de seguir profundizando en la investigación y el desarrollo.

Es precisamente este impulso de exploración y expansión de los límites de la tecnología lo que se pretende con el presente proyecto de grado. Al continuar explorando y expandiendo las posibilidades de estas tecnologías, se espera abrir un camino para nuevas soluciones que mejoren la calidad de vida de las personas, amplíen las capacidades humanas y permitan una mayor integración entre la tecnología y la fisiología humana; el cual busca avanzar, explorar nuevas ideas y construir sobre los logros actuales para seguir impulsando este campo hacia adelante.

## **6 MARCO TEÓRICO**

---

En el marco teórico de la presente investigación, se abordan conceptos clave que constituyen la base teórica y técnica del estudio. Se comienza por examinar la biomecánica de la mano humana, que provee entendimiento esencial acerca de la estructura y funcionamiento de la mano, y es crucial para el diseño de prótesis que buscan emular sus capacidades.

El análisis se extiende a las señales electroencefalográficas (EEG), que son fundamentales para captar la actividad cerebral que refleja las intenciones del usuario. Las técnicas de procesamiento de señales EEG se presentan como un paso necesario para convertir estas señales en instrucciones ejecutables para sistemas mecatrónicos.

Se profundiza en la mecatrónica y el diseño de prótesis, destacando cómo la sinergia de mecánica, electrónica y control computacional da lugar a extremidades artificiales avanzadas. Se examina la interfaz cerebro-computadora (BCI), que actúa como un enlace vital permitiendo una comunicación fluida entre el cerebro y la prótesis.

La retroalimentación háptica se identifica como vital para proporcionar una respuesta sensorial que enriquece el uso de la prótesis. Desde la perspectiva del aprendizaje automático, se enfatiza la importancia de la regresión logística, una técnica de machine learning que es instrumental en la mejora de las decisiones dentro del desarrollo de prótesis mecatrónicas.

Por último, se considera el papel del kit Aura como biosensor, una herramienta emergente para la medición precisa de las señales biológicas, que potencialmente puede incrementar la interacción entre el usuario y su prótesis. Estos elementos forman el fundamento teórico sobre el cual se construirá el análisis y desarrollo del sistema mecatrónico experimental para el control de una prótesis de mano.

### **6.1 BIOMECÁNICA DE LA MANO HUMANA**

La biomecánica de la mano humana es un campo interdisciplinario que combina conocimientos de la biología, física, matemáticas e ingeniería para describir y analizar las

propiedades mecánicas del movimiento y la deformación de la mano humana (Zhang et al., 2020b).

### **6.1.1 Anatomía de la Mano**

La mano humana es una compleja estructura formada por 27 huesos, que se dividen en tres grupos principales: el carpo, metacarpo y las falanges (Brand & Hollister, 1993).

- ***Carpo***

El carpo consta de ocho huesos pequeños dispuestos en dos filas, que forman la "base" de la mano. Estos huesos son el escafoides, semilunar, piramidal, pisiforme, trapecio, trapecoide, grande y ganchoso. Juntos, estos huesos proporcionan una base flexible y resistente para el resto de la mano.

- ***Metacarpo***

Los metacarpianos son cinco huesos largos que se extienden desde el carpo hasta las falanges. Estos huesos forman el "cuerpo" de la mano y proporcionan una estructura de soporte para los dedos.

- ***Falanges***

Las falanges son los huesos de los dedos. Cada dedo tiene tres falanges (proximal, media y distal), excepto el pulgar, que solo tiene dos (proximal y distal).

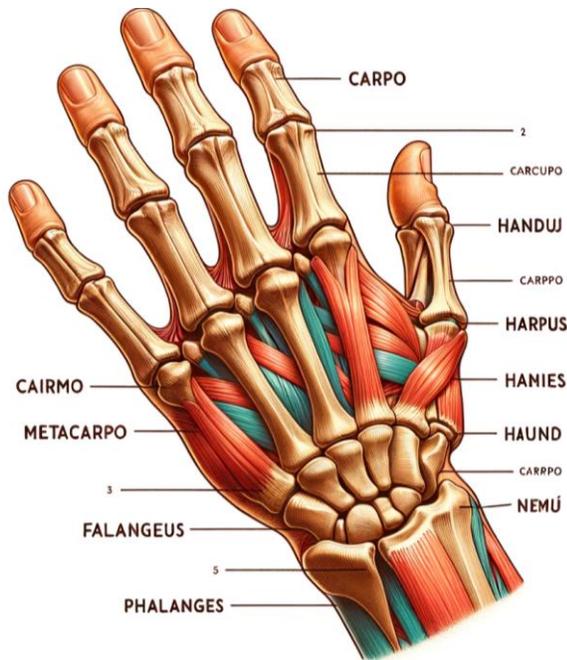


Figura 1. Carpo, Metacarpo y Falanges (generada por DALL-E-3 Operated by Poe)

Además de los huesos, la mano también contiene una red compleja de articulaciones, ligamentos, tendones, músculos y nervios que permiten un amplio rango de movimientos y sensaciones. Los músculos extrínsecos, que se originan en el antebrazo y se insertan en la mano, son responsables de los movimientos gruesos, mientras que los músculos intrínsecos, que se encuentran completamente dentro de la mano, son responsables de los movimientos finos y precisos (Brand & Hollister, 1993).

### 6.1.2 Fisiología de la Mano

La mano es una de las partes más sensibles y versátiles del cuerpo humano. Cuenta con una alta concentración de terminaciones nerviosas, lo que le permite sentir una amplia gama de sensaciones, incluyendo presión, temperatura, dolor y vibración.

La mano recibe su inervación a través de tres nervios principales: el nervio radial, el nervio mediano y el nervio cubital. Estos nervios transmiten información sensorial desde la mano al cerebro y llevan señales motoras desde el cerebro a los músculos de la mano. Por lo tanto, cualquier daño a estos nervios puede tener un impacto significativo en la función de la mano (Buchholz & Armstrong, 1992)

### **6.1.3 Biomecánica de la Mano**

La biomecánica de la mano puede ser descrita en términos de cinemática (el estudio del movimiento sin considerar las fuerzas que lo causan) y dinámica (el estudio del movimiento y las fuerzas que lo causan).

Desde un punto de vista cinemático, la mano puede ser modelada como un sistema de segmentos rígidos (los huesos) conectados por articulaciones que permiten el movimiento en uno o más planos. Cada articulación tiene uno o más grados de libertad, que son las direcciones en las que puede moverse. La suma total de los grados de libertad en la mano es lo que permite su amplio rango de movimientos.

Desde un punto de vista dinámico, la mano puede ser modelada como un sistema de palancas, con los músculos proporcionando la fuerza para mover las palancas (los huesos) alrededor de los fulcros (las articulaciones). El estudio de la biomecánica de la mano desde una perspectiva dinámica implica el análisis de las fuerzas y los momentos de fuerza (torques) que actúan en la mano durante diversos movimientos y actividades (Tubiana & Valentin, 1964).

### **6.1.4 Biomecánica de la Prehensión**

La habilidad de la mano para agarrar y manipular objetos es fundamental para muchas actividades de la vida diaria. Hay dos tipos principales de prehensión: la prehensión cilíndrica y la de pinza.

La prehensión cilíndrica implica el uso de toda la mano para envolver un objeto, como cuando agarras una taza de café. En este tipo de prehensión, los dedos y el pulgar trabajan juntos para crear una "jaula" alrededor del objeto, y los músculos de la mano y el antebrazo proporcionan la fuerza para sujetar el objeto.

La prehensión de pinza, por otro lado, implica el uso del pulgar y uno o más dedos para sujetar un objeto, como cuando se recoge una llave con el pulgar y el índice. En este tipo de prehensión, el pulgar y los dedos actúan como dos palancas opuestas que pivotan alrededor de una articulación común.

El estudio de la biomecánica de la prehensión puede implicar el análisis de la posición y orientación de los dedos y el pulgar, las fuerzas aplicadas por los dedos y el pulgar, y la coordinación de los músculos de la mano y el antebrazo durante la prehensión (Lundström, 1984).

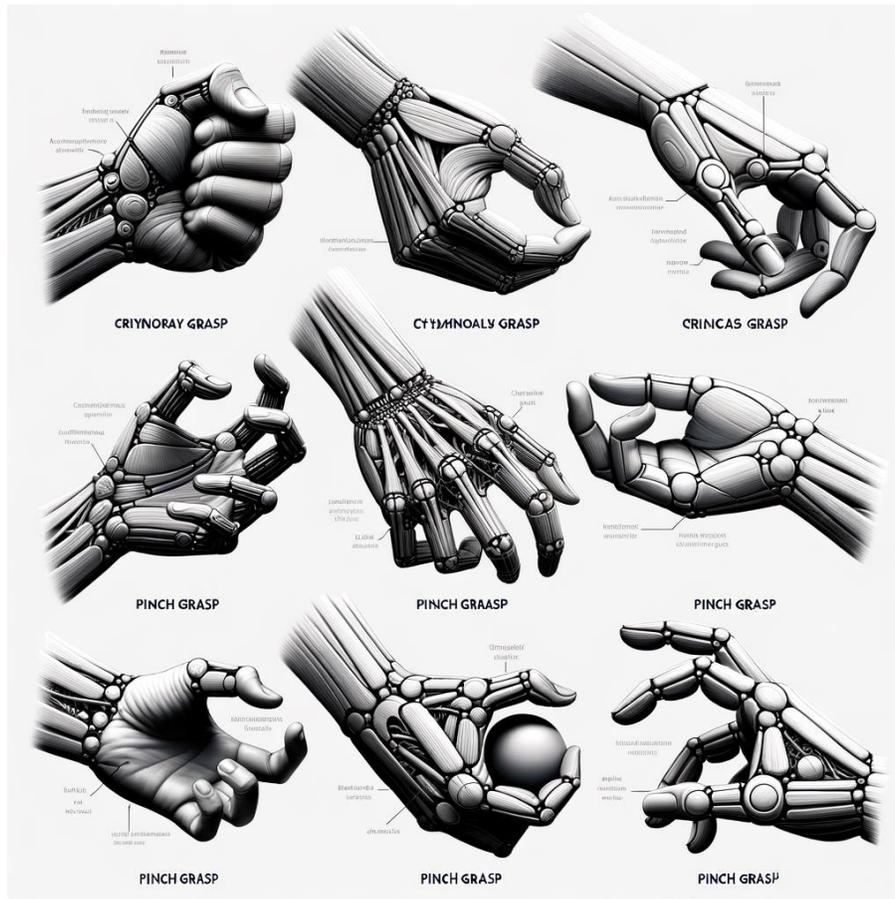


Figura 2. Biomecánica de la prehensión (generada por DALL-E-3 Operated by Poe)

### 6.1.5 Aplicaciones de la Biomecánica de la Mano

La comprensión de la biomecánica de la mano tiene muchas aplicaciones prácticas. En medicina, puede ayudar a los médicos a diagnosticar y tratar una variedad de condiciones que afectan a la mano, incluyendo artritis, lesiones por esfuerzo repetitivo, y lesiones traumáticas. También puede ser útil en la rehabilitación, ayudando a los terapeutas a diseñar ejercicios y actividades que mejoren la función de la mano.

En ingeniería, los principios de la biomecánica de la mano pueden ser utilizados para diseñar herramientas y equipos más ergonómicos, que reduzcan el riesgo de lesiones y mejoren la eficiencia y la comodidad.

Finalmente, en robótica, el estudio de la biomecánica de la mano puede ayudar a los ingenieros a diseñar robots más sofisticados y versátiles. Por ejemplo, los robots humanoides pueden ser equipados con manos que imitan la estructura y función de la mano humana, permitiéndoles realizar una amplia gama de tareas. La biomecánica de la mano es un campo de estudio fascinante y dinámico, que ofrece una gran cantidad de oportunidades para la investigación y la aplicación práctica (Cutkosky et al., 2008).

## **6.2 SEÑALES ELECTROENCEFALOGRÁFICAS (EEG)**

La electroencefalografía (EEG) es un método de registro de la actividad eléctrica del cerebro. Se utiliza en una variedad de disciplinas, como la neurociencia, la psicología y la medicina. Este marco teórico abordará los aspectos clave de las señales EEG, incluyendo su naturaleza, su adquisición, su análisis y sus aplicaciones.(Jaseja, 2023).

### **6.2.1 Naturaleza de las Señales EEG**

Las señales EEG son una representación de la actividad eléctrica del cerebro. Esta actividad se genera principalmente por las neuronas, las células nerviosas del cerebro que se comunican entre sí a través de impulsos eléctricos. Las señales EEG capturan las fluctuaciones de voltaje resultantes de los flujos iónicos dentro de las neuronas. Es importante destacar que las señales EEG representan la actividad de grupos de neuronas, no de neuronas individuales. Un solo electrodo EEG puede captar las señales de millones de neuronas simultáneamente. Por lo tanto, las señales EEG reflejan la actividad colectiva del cerebro, no la actividad de las neuronas individuales (Buzsáki et al., 2012).

Desde 1920, el Dr. Hans Berger señaló que existían cambios de potenciales eléctricos en el cerebro que se relacionaban a diferentes condiciones a las que sean sometidos los pacientes. Este hecho ha despertado gran interés en la comunidad científica, y se han realizado diferentes investigaciones en este campo; entre ellas,

algunas con la finalidad de obtener una vía de comunicación directa entre el cerebro humano y algunos dispositivos mecánicos externos (Sáez, s. f.). Las señales eléctricas producidas por el cerebro son generadas por la diferencia de potencial en la membrana celular de las neuronas y este proceso es la base del funcionamiento de nuestro sistema nervioso. La electroencefalografía registra y evalúa la actividad eléctrica producida por la actividad neuronal al interior del cerebro. Para la adquisición y registro de estas señales bioeléctricas se utilizan diferentes tipos de electrodos. Si se usan electrodos superficiales en la base del cráneo (mediante electrodos basales), a las señales registradas se les llamará EEG o electroencefalograma, si se utiliza electrodos quirúrgicos de superficie se denomina EcoG o electrocorticograma, igualmente se pueden usar micro electrodos quirúrgicos de aplicación profunda (PortalClinic s. f.).

En las señales provenientes de la actividad cerebral (EEG), se puede registrar la tensión y la frecuencia, entre otras. Esta actividad es muy compleja ya que presenta grandes variaciones, dependiendo de la localización de los electrodos, y del paciente que se esté tratando. Según las investigaciones en este campo, esto se debe a la infinidad de conexiones neuronales y a que la estructura craneal no es uniforme, también se presentan variaciones de acuerdo al estado mental del paciente, a los pensamientos y al movimiento del cuerpo.

### **6.2.2 Adquisición de Señales EEG**

La adquisición de señales EEG implica el uso de un conjunto de electrodos que se colocan en el cuero cabelludo. Estos electrodos detectan las fluctuaciones de voltaje producidas por la actividad cerebral. Las señales se amplifican y se registran para su posterior análisis (Luck, 2014).

- ***Ubicación de los electrodos para el registro del EEG.***

La FISE (Federación Internacional de Sociedades de Electroencefalografía) definió un sistema estandarizado conocido como el sistema 10-20. Este sistema asegura que los electrodos cubran todas las áreas del cerebro y permite la comparación de los resultados entre diferentes sujetos y estudios (Klem, Lüders, et al., 1999). Para establecer la posición de cada electrodo sobre el cuero cabelludo, el estándar 10-20 se basa en las

medidas de las intersecciones que separan a los electrodos con una distancia relativa del 10% al 20% por ciento de la distancia total de la línea que se ubican los electrodos.

- **Técnica de medición para el registro del EEG**

La técnica de medición se basa en puntos de referencia estándar del cráneo. Concretamente, el nasion, el inion y los puntos preauriculares izquierdo y derecho. Los puntos preauriculares se palpan como depresiones en la raíz del cigoma, justo delante del tragus (Klem, Lüders, et al., 1999). La primera medición se realiza en el plano anteroposterior a través del vértice, tomada desde el nasion hasta el inion. Esta medida se divide en 5 áreas separadas (véase la Figura 3). La primera marca se coloca en el 10% de la medida total y se etiqueta como Fp. La segunda, tercera, cuarta y quinta marcas se colocan a intervalos del 20% de la medida total y se etiquetan como F, C, P y O. Obsérvese que la marca O se situaría en el 10% de la medida por encima del inion. Las expresiones Fp, F, C, P y O representan las áreas fronto-polar, frontal, central, parietal y occipital, respectivamente.

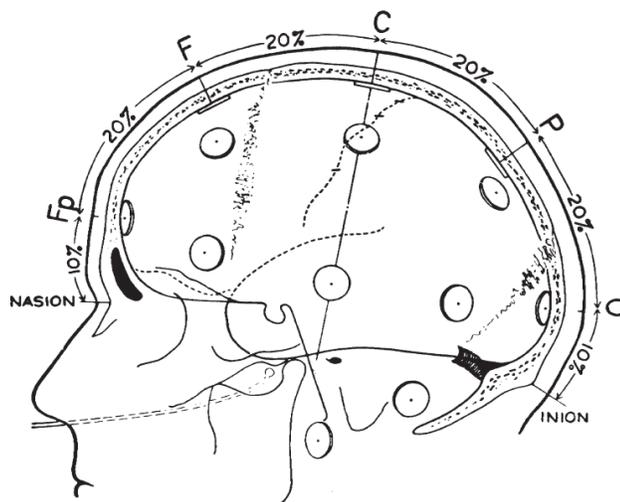


Figura 3. Vista lateral del cráneo para mostrar los métodos de medición desde el nasión hasta el inión en la línea media. Fuente (Klem, Lüders, et al., 1999)

La medición lateral del cráneo se realiza en el plano coronal central, pasando por el punto preauricular izquierdo, el vértice C y el punto preauricular derecho (véase la Figura 4). Se coloca una marca en el 10% de esta medida y se etiqueta como T,

representando el área temporal. Luego, se colocan marcas en el 20% de la medida lateral y se etiquetan como C izquierdo y C derecho, marcando también el vértice C.

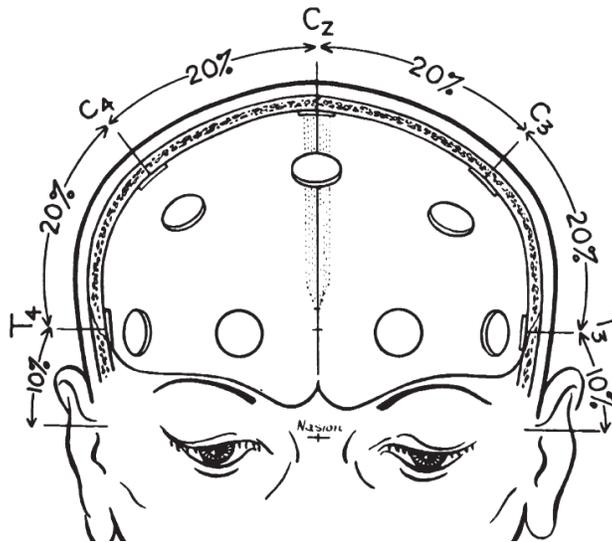


Figura 4. Vista frontal del cráneo que muestra el método de medición de la línea central de electrodos. Fuente (Klem, Lüders, et al., 1999)

La circunferencia de los lóbulos temporales se mide desde la posición central Fp hasta la posición central O (véase la Figura 5). Se marca el 10% de esta medida para indicar la ubicación del electrodo Fp izquierdo o derecho. Luego, se marcan puntos a intervalos del 20% y se etiquetan como frontal inferior, temporal medio, temporal posterior y occipital izquierdo o derecho (las posiciones del electrodo temporal medio están marcadas como superpuestas). La distancia restante del 10% desde las marcas occipitales izquierda y derecha representa la posición central O.

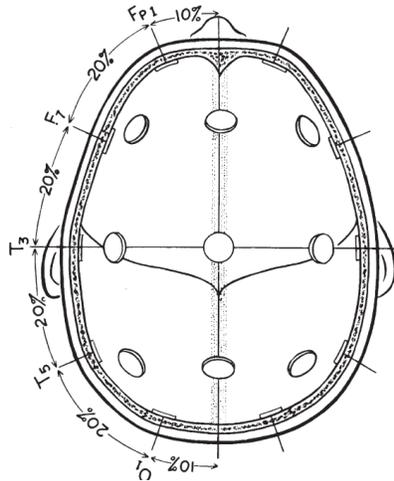


Figura 5. Vista superior con corte transversal del cráneo a través de la línea temporal de electrodos que ilustra el sistema  $10\pm 20$  aplicado en esta dirección. Fuente (Klem, Lüders, et al., 1999)

Una medición coronal en la parte posterior del cráneo se realiza desde la marca temporal posterior izquierda hasta la posición central P. Esta medida se divide en segmentos del 25% y se marcan como P lateral izquierda, P central y P lateral derecha (véase la Figura 6).

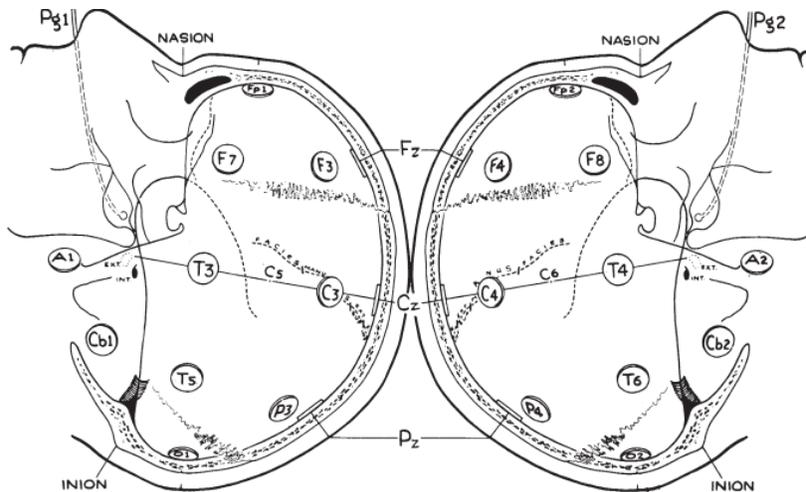


Figura 6. La vista lateral de los hemisferios izquierdo y derecho mostrando todas las posiciones estándar de los electrodos. Fuente (Klem, Lüders, et al., 1999)

Las mediciones proporcionadas determinan la ubicación de 19 de los 21 electrodos utilizados en el sistema de  $10\pm 20$  electrodos (véase la Figura 7). Los dos electrodos restantes se colocaron en los lóbulos de las orejas y se llamaron electrodos auriculares.

Las posiciones de los electrodos se nombraron según las áreas corticales que registran, excepto los electrodos "C", que se denominaron centrales porque se encuentran sobre el surco central.

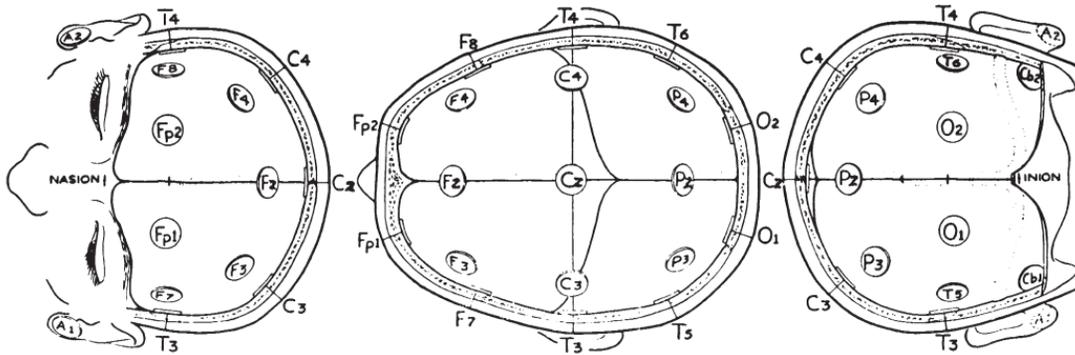


Figura 7. Vistas frontal superior y posterior que muestran todas las posiciones estándar de los electrodos. Fuente (Klem, Lüders, et al., 1999)

### 6.2.3 Análisis de Señales EEG

Diferentes técnicas de registro y adquisición de la actividad cerebral han sido empleadas a través de los años, como por ejemplo la magneto encefalografía (MEG), la Tomografía por Emisión de Positrones (PET), o la resonancia magnética funcional (fMRI). El problema principal de estas técnicas es que utilizan equipos biomédicos altamente costosos. Otro de los inconvenientes es el registro de la actividad cerebral de los pacientes, que está ligado con el flujo sanguíneo y en numerosas ocasiones se puede tardar bastante tiempo en que este se regule, para que se pueda registrar correctamente la actividad cerebral. Debido a los inconvenientes mencionados, en la actualidad la electroencefalografía es la técnica más usada para el registro de la actividad cerebral (Leuthardt et al., 2004). Las señales EEG se caracterizan por sus patrones de frecuencia. Estos patrones pueden ser analizados utilizando varias técnicas, incluyendo la transformada de Fourier, que descompone una señal en sus componentes de frecuencia. Las principales bandas de frecuencia en las señales EEG son: delta (0.5-4 Hz), theta (4-8 Hz), alfa (8-12 Hz), beta (12-30 Hz) y gamma (30-100 Hz) (véase Figura 8). Cada banda de frecuencia se asocia con diferentes estados y funciones cerebrales (Buzsáki & Draguhn, 2004).

Además de las técnicas de análisis de frecuencia, existen otros métodos para analizar las señales EEG, incluyendo el análisis de la conectividad funcional (que examina la coherencia entre las señales de diferentes regiones cerebrales) y el análisis de la complejidad (que examina la irregularidad y la imprevisibilidad de las señales EEG) (Stam, 2005).

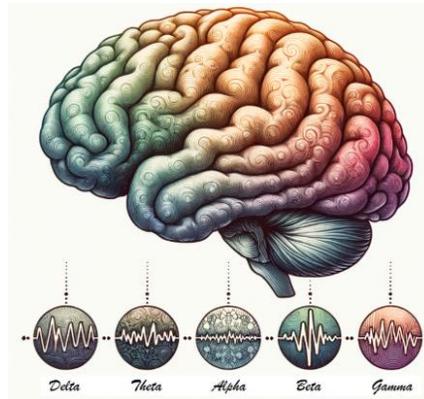


Figura 8. Principales ondas neuronales generadas en el cerebro (generada por DALL-E-3 Operated by Poe)

En la Tabla I, se puede observar la clasificación de los ritmos principales de las señales EEG.

Tabla I. Ritmos característicos en señales EEG clasificados por su frecuencia («Ondas cerebrales y su significado», 2019)

RITMO CARACTERÍSTICO	INTERVALO DE FRECUENCIA (Hz)	AMPLITUD ( $\mu V$ )	CARACTERÍSTICAS GENERALES
<b>Delta</b>	0,5 – 3,5	20 – 200	Sueño, reparación, resolución de problemas complejos, inconsciencia, profunda inconsciencia
<b>Theta</b>	4 – 8	20 – 100	Creatividad, percepción, estados profundos, inconsciencia, estado meditativo óptimo, depresión, ansiedad, distracción
<b>Alpha</b>	8 – 14	20 – 60	Alerta y tranquilidad, preparación, meditación, profundamente relajado.

<b>Beta</b>	14 – 26	2 – 20	Pensar, enfocar, atención sostenida, tensión, estado de alerta, emoción.
<b>Gamma</b>	25 – 100	5 – 10	Aprendizaje, procesamiento cognitivo, tareas de resolución de problemas, agudeza mental, actividad cerebral, organización del cerebro.

A continuación, se presenta la descripción de los ritmos característicos asociados a las señales EEG.

- **Ritmo Delta ( $\delta$ ):** conocido como la onda del sueño. Este ritmo aparece generalmente en estados de sueño profundo. Su amplitud varía de los 20 a 200  $\mu$ V, y su rango de frecuencia oscila entre 0,5 y 3,5 Hz (En et al., 2018).
- **Ritmo Theta ( $\theta$ ):** se presenta generalmente con la activación del lóbulo temporal, su banda de frecuencia está entre los 4 y 8 Hz y su amplitud varía entre los 20 y 100  $\mu$ V. Se presenta frecuentemente en niños o en adultos que están sometidos a niveles de estrés (En et al., 2018).
- **Ritmo Alfa ( $\alpha$ ):** este ritmo corresponde al estado de relajación, en donde la persona tiene poca actividad mental o se encuentra con los ojos cerrados. Este ritmo se atenúa cuando la persona inicia alguna clase de actividad mental que requiera concentración. Las señales asociadas a este ritmo presentan una frecuencia comprendida entre los 8 y 14 Hz, una amplitud de entre 20 y 60  $\mu$ V; la fuente principal de estas señales se encuentra en la región occipital del cerebro (En et al., 2018).
- **Ritmo Beta ( $\beta$ ):** su amplitud se encuentra en el rango entre los 2 y 20  $\mu$ V y su frecuencia entre los 14 y 26 Hz. Este ritmo está vinculado con los movimientos de las extremidades. Este ritmo se asocia a un estado mental de concentración por parte de la persona y se puede encontrar principalmente en la región frontal y central del cerebro (En et al., 2018).
- **Ritmo Gamma ( $\gamma$ ):** Las ondas gamma son las ondas cerebrales de mayor frecuencia, con una frecuencia de entre 30 y 100 Hz. Se asocian a procesos cognitivos complejos, como la atención, la concentración, el aprendizaje y la memoria. También se relacionan con el estrés y la ansiedad (En et al., 2018).

#### **6.2.4 Aplicaciones de las Señales EEG**

Las señales EEG tienen una amplia gama de aplicaciones. En medicina, se utilizan para diagnosticar y monitorizar una variedad de condiciones, incluyendo la epilepsia, los trastornos del sueño, y las lesiones cerebrales. También se utilizan en la investigación del cerebro para estudiar la función cerebral normal y anormal (Hirsch et al., 2021).

En neurociencia y psicología, las señales EEG se utilizan para estudiar los procesos cognitivos y emocionales. Por ejemplo, se pueden utilizar para investigar la atención, la memoria, el lenguaje, y las emociones

Además, las señales EEG también se utilizan en la interfaz cerebro-computadora (BCI), una tecnología que permite a las personas controlar dispositivos externos con su actividad cerebral. Las aplicaciones de BCI incluyen la asistencia a personas con discapacidades, la mejora del rendimiento humano, y el entretenimiento (Leuthardt et al., 2004).

### **6.3 TÉCNICAS DE PROCESAMIENTO DE SEÑALES EEG**

El procesamiento de señales EEG (electroencefalografía) desempeña un papel fundamental en la interpretación de la compleja actividad cerebral y es indispensable para el avance de la neurociencia y la medicina. La señal EEG, que es el registro de la actividad eléctrica del cerebro, es extremadamente rica en información, pero también altamente susceptible al ruido y a las interferencias, tanto biológicas como ambientales. Por ello, el procesamiento preciso de estas señales es esencial para discernir patrones significativos y obtener *insights* confiables que puedan aplicarse en la detección temprana, diagnóstico y monitoreo de trastornos neurológicos, así como en la investigación de las dinámicas cerebrales subyacentes a diversas funciones cognitivas y estados de conciencia. (Balam et al., 2021)

#### **6.3.1 Preprocesamiento**

El preprocesamiento de señales EEG es una etapa crítica en la cadena de procesamiento de datos que tiene como objetivo mejorar la calidad de la señal para

análisis posteriores. Esta fase es fundamental ya que las señales EEG suelen estar contaminadas con varios tipos de ruido y artefactos que pueden distorsionar la interpretación y análisis de los datos cerebrales. El preprocesamiento engloba una serie de técnicas destinadas a mejorar la relación señal-ruido y a preparar las señales para el procesamiento y análisis más detallado. (Universidad Autónoma Metropolitana et al., 2017).

- **Filtrado**

El filtrado es una de las técnicas más básicas y críticas del preprocesamiento. Se utilizan filtros para eliminar las frecuencias de señal no deseadas. (Quintero-Rincon et al., 2012).

- **Filtros de Paso Bajo:** Atenúan las frecuencias por encima de un umbral específico, eliminando el ruido de alta frecuencia, como el generado por la actividad muscular o los artefactos electromagnéticos, véase Figura 9.

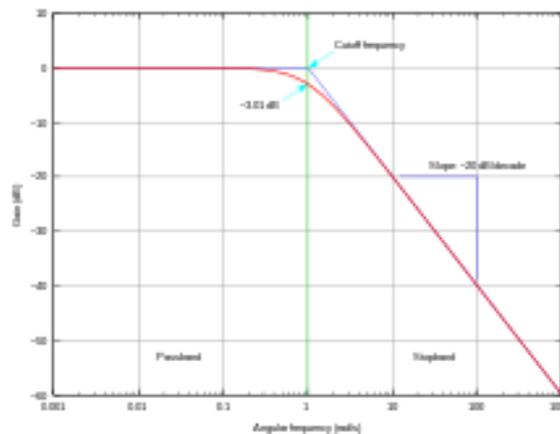


Figura 9. Filtros de Paso Bajo («Filtro paso bajo», 2022)

- **Filtros de Paso Alto:** Eliminan las frecuencias inferiores a un umbral determinado, reduciendo así el ruido de movimiento lento, como el drift eléctrico, véase Figura 10.

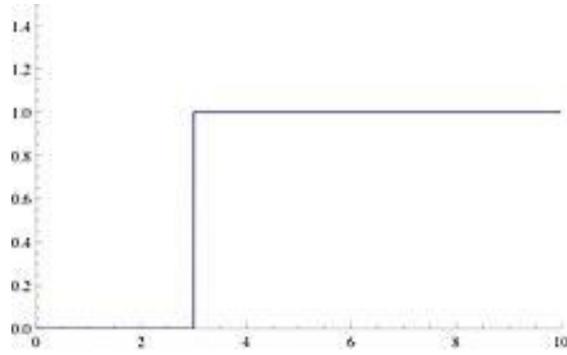


Figura 10. Filtro pasa alto («Filtro paso alto», 2022)

- **Filtros de Banda:** Permiten el paso de un rango específico de frecuencias, eliminando frecuencias por debajo y por encima de ese rango, véase Figura 11.

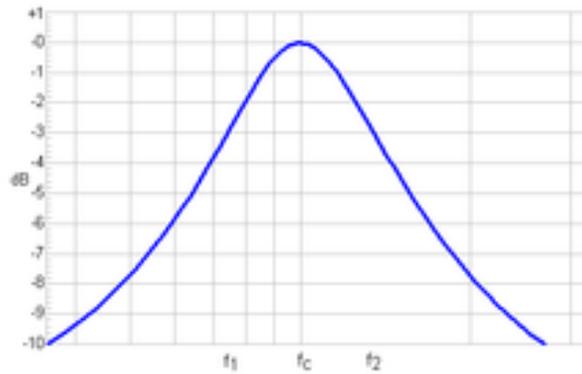
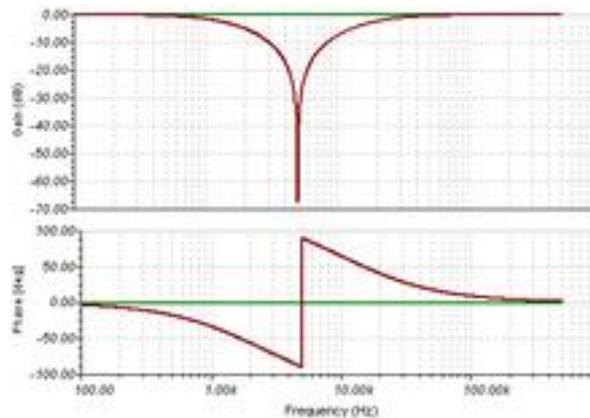


Figura 11. Filtro Pasa Banda («Filtro paso banda», 2023)

- **Filtros Notch:** Se utilizan específicamente para eliminar frecuencias muy específicas, como la interferencia de la línea eléctrica a 50 o 60 Hz, véase Figura 12.



▪ **Eliminación de Artefactos**

Los artefactos son señales no cerebrales que pueden ser causadas por movimiento, parpadeo, latidos del corazón, etc. Su eliminación o reducción es crucial para un análisis fiable. (López Callejo, 2019)

- **Análisis de Componentes Independientes (ICA):** Separa fuentes de señal estadísticamente independientes, lo que permite identificar y eliminar componentes relacionados con artefactos.
- **Descomposición Wavelet:** Permite la descomposición de la señal en componentes a diferentes escalas de tiempo y frecuencia, facilitando la identificación y eliminación de artefactos transitorios.
- **Eliminación Manual:** A pesar de los avances en métodos automáticos, en algunos casos es necesaria la inspección visual y la eliminación manual de segmentos de datos con artefactos.

▪ **Re-referenciación**

La actividad EEG se registra en relación con un punto de referencia. La elección de este punto de referencia puede afectar la interpretación de la señal (Torres-García et al., 2013a):

- **Re-referenciación Promedio:** La señal de cada electrodo se re-referencia a la media de todas las señales, lo que puede aumentar la relación señal-ruido.
- **Re-referenciación a un Electrodo Específico:** Seleccionar un electrodo como referencia puede ser útil cuando se conoce la fuente del ruido.

▪ **Normalización**

La normalización ajusta la escala de las señales EEG para que sean más comparables entre sujetos o sesiones. Esto es útil para análisis posteriores que asumen que la señal tiene una distribución específica o rango (Torres-García et al., 2013b).

- **Segmentación**

La señal EEG a menudo se segmenta en épocas, que son ventanas temporales de la señal. Esto es útil para analizar eventos específicos, como los potenciales evocados relacionados con estímulos particulares (Cerino et al., 2023).

- **Detrending**

La eliminación de tendencias lineales o polinomiales puede ser necesaria para evitar sesgos en el análisis de la frecuencia, especialmente cuando se estudian fenómenos oscilatorios (Cerino et al., 2023).

### **6.3.2 Análisis en el Dominio de la Frecuencia**

El análisis en el dominio de la frecuencia se refiere al estudio de cómo varía la señal de EEG en función de la frecuencia. Este tipo de análisis es muy revelador, ya que la actividad cerebral se manifiesta a través de oscilaciones en distintas bandas de frecuencia, cada una asociada con diferentes estados o procesos cognitivos.

- **Transformada de Fourier (FFT)**

La Transformada Rápida de Fourier (FFT, por sus siglas en inglés) es una técnica matemática que descompone una señal temporal en sus componentes de frecuencia. Es una herramienta esencial en el procesamiento de señales EEG, ya que permite la transición de la señal del dominio del tiempo al dominio de la frecuencia, revelando las frecuencias que componen la señal original y su respectiva amplitud. Este análisis es fundamental para identificar ritmos cerebrales y evaluar su relevancia en diferentes contextos clínicos y cognitivos. La FFT es especialmente útil debido a su eficiencia computacional, lo que permite el análisis en tiempo real o el procesamiento de grandes conjuntos de datos de EEG. La salida de la FFT es un espectro de frecuencia que muestra la amplitud (o potencia) de las señales a lo largo de un rango de frecuencias (*FFT*), como se muestra en la figura XX.



Figura 13. Transformada de Fourier (Transformadas Wavelet | Multimedia, s. f.)

#### ▪ **Espectro de Potencia**

Al aplicar la FFT a una señal EEG, se obtiene un espectro de frecuencias que muestra cómo se distribuye la potencia de la señal a través de las distintas frecuencias. El espectro de potencia es una representación cuantitativa de la distribución de energía de la señal EEG en sus componentes frecuenciales. Las principales bandas de frecuencia son (Medina et al., s. f.):

- **Delta ( $\delta$ ):** < 4 Hz, asociadas con el sueño profundo y estados de inconsciencia.
- **Theta ( $\theta$ ):** 4-7 Hz, relacionadas con la somnolencia, la meditación y la creatividad.
- **Alpha ( $\alpha$ ):** 8-13 Hz, típicamente asociadas con un estado de reposo relajado y la coordinación cerebro-cuerpo.
- **Beta ( $\beta$ ):** 13-30 Hz, vinculadas a la actividad mental activa, la concentración y la ansiedad.
- **Gamma ( $\gamma$ ):** > 30 Hz, relacionadas con el procesamiento cognitivo de alto nivel y la integración de la información sensorial.

La cuantificación de la potencia en estas bandas es crucial para muchas aplicaciones, como el diagnóstico de trastornos del sueño, la evaluación de la carga cognitiva, o el estudio de estados de meditación y conciencia. Además, anomalías en el espectro de potencia de estas bandas pueden indicar patologías neurológicas o psiquiátricas.

El análisis del espectro de potencia puede hacerse en términos absolutos, mostrando la potencia de cada banda de frecuencia, o en términos relativos, mostrando la proporción de la potencia de una banda con respecto al total. Este análisis puede complementarse

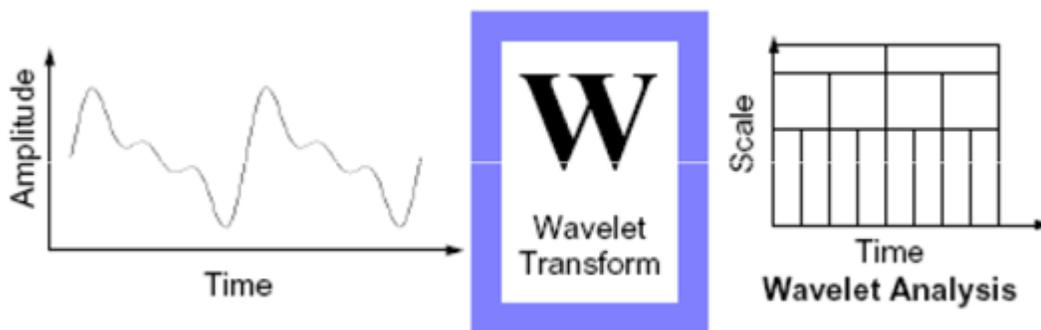
con métodos estadísticos para comparar espectros de potencia entre distintas condiciones o grupos de sujetos (OMS 2023).

### 6.3.3 Análisis en el Dominio del Tiempo-Frecuencia

El análisis en el dominio del tiempo-frecuencia implica examinar cómo cambian las componentes frecuenciales de una señal EEG con el tiempo. Este enfoque es especialmente útil para señales no estacionarias, cuyas propiedades estadísticas varían con el tiempo, como es el caso de las señales EEG. Este tipo de análisis proporciona una visión más completa y dinámica de la actividad cerebral.

- **Transformada Wavelet**

La Transformada Wavelet es una técnica matemática que ofrece una representación simultánea de una señal en el tiempo y la frecuencia. A diferencia de la FFT, que proporciona información de la frecuencia sin una localización temporal específica, la Transformada Wavelet descompone la señal en componentes que varían en frecuencia y se localizan en el tiempo. Esto se logra mediante el uso de funciones "wavelet" que pueden dilatarse o contraerse y trasladarse a lo largo de la señal. Esta capacidad de adaptarse a diferentes escalas hace que la Transformada Wavelet sea particularmente adecuada para analizar señales EEG, que pueden contener eventos transitorios o no estacionarios como los potenciales evocados o las ráfagas de actividad en determinadas bandas de frecuencia. La representación wavelet es particularmente útil para identificar y caracterizar dinámicas cerebrales locales tanto en el tiempo como en la frecuencia (Zamarrón Sobrinos, 2019).



- **Entropía Espectral**

La entropía espectral es una medida cuantitativa que refleja la complejidad y el desorden de la señal EEG en el dominio de la frecuencia. Se deriva del concepto de entropía en la teoría de la información, que caracteriza la incertidumbre o la imprevisibilidad de la información contenida en una señal. En el contexto de las señales EEG, la entropía espectral se utiliza para estimar la regularidad y la predictibilidad de la actividad cerebral en diferentes bandas de frecuencia. Una entropía espectral baja indica que la potencia de la señal está concentrada en unas pocas frecuencias (mayor regularidad), mientras que una alta entropía espectral sugiere una distribución más uniforme de la potencia a través de un rango más amplio de frecuencias (mayor desorden) (Jeong, 2004).

Esto puede tener aplicaciones clínicas significativas, por ejemplo, en el monitoreo de la conciencia en pacientes bajo anestesia, donde una disminución en la complejidad de la señal (reducción en la entropía espectral) puede indicar una profundización del estado de inconsciencia. La entropía espectral también puede servir para analizar la capacidad del cerebro para procesar información diversa y su eficiencia en la realización de ciertas tareas cognitivas.

#### 6.3.4 Análisis Espacial

El análisis espacial del EEG se enfoca en la localización y distribución de la actividad eléctrica cerebral en diferentes regiones del cuero cabelludo y, por inferencia, en el cerebro subyacente. Este análisis es crucial para comprender la función cerebral y para diagnosticar y tratar trastornos neurológicos (Arias & Martínez, 2023)

- **Topografía Cerebral**

La topografía cerebral implica la representación visual de la actividad eléctrica registrada en el cuero cabelludo. Esto se logra mediante mapas de colores que muestran la amplitud o la potencia de las señales EEG en diferentes localizaciones espaciales.

Estos mapas son conocidos como mapas topográficos o mapas de "Brain mapping" (Muñoz-Ruata, 1999).

- Mapas de Amplitud: Representan la intensidad de la señal EEG en diferentes puntos del cuero cabelludo en un momento dado.
- Mapas de Potencia: Muestran la distribución de la potencia en diferentes bandas de frecuencia en la superficie del cuero cabelludo.

La topografía cerebral es particularmente útil para identificar patrones de actividad que son típicos de ciertas condiciones neurológicas, como la epilepsia, o para observar la distribución espacial de la actividad cerebral durante tareas cognitivas específicas. También se utiliza en neuro *feedback* y en la investigación del sueño.

- **Modelado de Fuentes**

El modelado de fuentes es un conjunto de técnicas computacionales que se utilizan para estimar la ubicación de las fuentes neuronales generadoras de las señales eléctricas medidas por el EEG en la superficie del cuero cabelludo. Dos de los métodos utilizados para el modelado de fuentes son (Valdés Rodríguez, 1997):

- Mínimos Cuadrados Recursivos (RLS): Es un enfoque adaptativo que actualiza las estimaciones de las fuentes neuronales a medida que se recibe nueva información. Es útil para rastrear la actividad cerebral en tiempo real.
- BEAMFORMING: Es una técnica que utiliza la información espacial de los sensores para dirigir la sensibilidad del algoritmo hacia una localización específica del cerebro, como si se enfocara un haz. Esto permite identificar las regiones del cerebro que están activas durante una tarea o evento específico.

El modelado de fuentes ayuda a superar la limitación de la baja resolución espacial del EEG. Al aplicar estos métodos, los investigadores y los clínicos pueden obtener una estimación de dónde en el cerebro se originan las señales medidas en el cuero cabelludo, lo cual es importante para la localización de la actividad epiléptica, la planificación quirúrgica, y el estudio de la función cerebral relacionada con diversas tareas cognitivas y estados emocionales.

### 6.3.5 Métodos Estadísticos y de Aprendizaje Automático

Los métodos estadísticos y de aprendizaje automático son herramientas esenciales para el análisis de datos EEG, ya que permiten la extracción de patrones significativos, la reducción de la dimensionalidad y la clasificación de estados mentales o la predicción de variables clínicas. Estos métodos pueden manejar la complejidad y la alta dimensionalidad de los datos EEG, lo que es particularmente útil en la investigación y el diagnóstico neurológico (Ein Shoka et al., 2023)

#### ▪ **Análisis de Componentes Principales (PCA)**

El Análisis de Componentes Principales (PCA) es una técnica estadística que transforma los datos originales en un conjunto de valores de componentes ortogonales llamados componentes principales. El objetivo de PCA es reducir la dimensionalidad de los datos mientras se retiene la mayor cantidad de información posible. En el contexto de los datos EEG:

- Reducción de Ruido: PCA puede ayudar a identificar y eliminar componentes que representan ruido o artefactos.
- Visualización: La reducción de la dimensionalidad facilita la visualización de la estructura de los datos.
- Análisis Simplificado: Al reducir el número de variables, PCA facilita el análisis estadístico y de aprendizaje automático posterior.

PCA es especialmente útil en la etapa previa al procesamiento de los datos, permitiendo a los investigadores y clínicos concentrarse en la información más relevante para sus análisis (Fanjul, 2022).

#### ▪ **Clasificación y Regresión**

Las técnicas de aprendizaje automático se aplican para identificar patrones complejos en los datos EEG y hacer predicciones o clasificaciones basadas en esos patrones (Santos, s. f.):

- Máquinas de Vectores de Soporte (SVM): SVM es un método de aprendizaje supervisado que busca el hiperplano que mejor separa las clases de datos en un espacio de características de alta dimensión. Es ampliamente utilizado para la clasificación de patrones de actividad cerebral.
- Redes Neuronales: Las redes neuronales son modelos computacionales inspirados en el cerebro que pueden capturar relaciones no lineales entre las características. Son particularmente útiles en la clasificación de estados mentales y en la detección de patrones complejos en los datos EEG.
- Regresión Logística: Es una técnica estadística que modela la probabilidad de una variable categórica en función de una o más variables independientes. Se utiliza en el EEG para predecir la probabilidad de un evento, como una crisis epiléptica o la respuesta a un estímulo.

Estos métodos pueden ser utilizados para:

- Clasificación de Estados Mentales: Distinguir entre diferentes estados cognitivos o emocionales, como la atención vs. la distracción, o el estrés vs. la relajación.
- Predicción de Variables Clínicas: Predecir la respuesta al tratamiento, la probabilidad de una enfermedad o el resultado de una cirugía.

### 6.3.6 Métodos Avanzados

Los métodos avanzados en el análisis de señales EEG se centran en comprender la complejidad de las interacciones neuronales y la estructura de las redes cerebrales. Estos enfoques son fundamentales para desentrañar los patrones de comunicación dentro del cerebro y pueden proporcionar *insights* importantes sobre los mecanismos neuronales subyacentes a diversos procesos cognitivos y trastornos (Farina et al., 2014b).

#### ▪ **Conectividad Funcional**

La conectividad funcional se refiere a la interacción temporal entre regiones cerebrales, la cual puede ser inferida a partir de las señales EEG. Se considera que dos o más regiones del cerebro están funcionalmente conectadas si las señales que ellas generan están correlacionadas o sincronizadas de alguna manera (Proal et al., 2011).

- **Coherencia:** Es una medida de la correlación entre las señales de dos regiones cerebrales en el dominio de la frecuencia. La coherencia alta indica una posible conexión funcional entre las regiones.
- **Conectividad Efectiva:** A diferencia de la conectividad funcional que es no direccional, la conectividad efectiva se refiere a la influencia que una región cerebral ejerce sobre otra. Métodos como el modelado de ecuaciones estructurales (SEM) y los modelos de variables latentes dinámicas (DLM) pueden ser utilizados para estudiar la conectividad efectiva.

- ***Análisis de Redes Complejas***

El análisis de redes complejas aplicado a las señales EEG utiliza la teoría de grafos para describir y cuantificar la estructura y dinámica de las redes neuronales. En este contexto, los nodos representan regiones cerebrales y las aristas representan sus conexiones funcionales o estructurales (Universitat Politècnica De València, 2014).

- **Características de la Red:** Se analizan características como la centralidad, la densidad, el camino más corto, la modularidad y la eficiencia de la red, proporcionando información sobre cómo las regiones cerebrales se interconectan y trabajan conjuntamente.
- **Resiliencia y Robustez:** Estos análisis también pueden revelar cómo la red responde a daños o fallos en regiones específicas, lo cual es relevante para entender trastornos neurológicos que implican la desconexión de áreas cerebrales.

## **6.4 MECATRÓNICA Y DISEÑO DE PRÓTESIS**

La mecatrónica es una disciplina interdisciplinaria que combina principios de la ingeniería mecánica, electrónica, informática y sistemas de control para el diseño de sistemas complejos. Esta integración permite el desarrollo de productos y sistemas inteligentes con capacidades mejoradas para adaptarse e interactuar de manera más eficiente con su entorno (R. H. Bishop, 2002)

#### 6.4.1 Aplicación de la Mecatrónica en Diseño de Prótesis

La mecatrónica es una disciplina que fusiona la mecánica, la electrónica, el control y la informática para diseñar y construir sistemas complejos como las prótesis modernas. Estos sistemas buscan reemplazar miembros perdidos o dañados y restaurar su funcionalidad. Los componentes mecatrónicos específicos en prótesis incluyen actuadores, sensores, microcontroladores, procesadores, así como software y algoritmos de control. A continuación, se explora cada uno de estos componentes en detalle. (Pons, 2008)

#### 6.4.2 Componentes Mecatrónicos en Prótesis

- **Actuadores:**

Los dispositivos que imitan la capacidad muscular son cruciales en el diseño de prótesis avanzadas, permitiendo movimientos precisos y controlados (Tagliamonte & Accoto, 2014).

- **Definición y Funcionalidad**

- Los actuadores son elementos clave en la prótesis que convierten señales eléctricas en movimiento mecánico. Imitan la función muscular y son responsables de la realización de movimientos articulares en las prótesis.

- **Tipos y Tecnologías**

- Motores eléctricos: Estos son comunes en prótesis robóticas debido a su capacidad de proveer movimientos precisos y su controlabilidad. Los motores de corriente continua (DC) y los servomotores son ejemplos prominentes (Ver Figura 15).

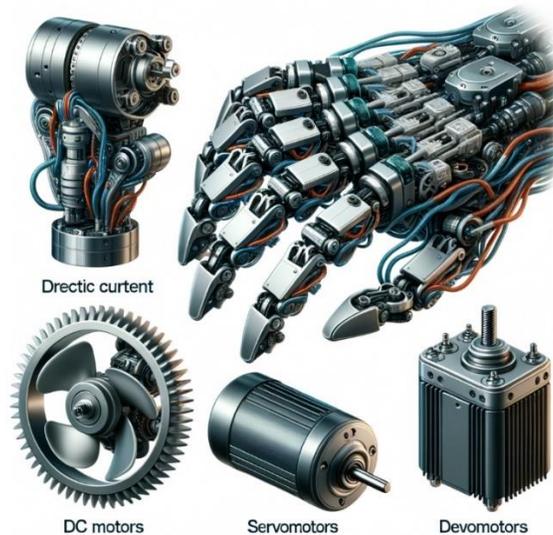


Figura 15. Principales Actuadores (generada por DALL-E-3 Operated by Poe)

- Músculos artificiales: Estos están basados en tecnologías emergentes como polímeros electroactivos y aleaciones de memoria de forma, los cuales pueden contraerse o expandirse en respuesta a estímulos eléctricos o térmicos, respectivamente.
- Actuadores híbridos: Combinan diferentes tecnologías para mejorar el rendimiento, como la suavidad de los músculos artificiales con la potencia de los motores eléctricos.

- **Desafíos y Soluciones**

- Control y Retroalimentación: Integrar sistemas de control que permitan a los actuadores responder a señales complejas y variables de manera eficiente.
- Simulación de la Propiocepción: Replicar la sensación de la posición y movimiento del miembro que es natural en las extremidades biológicas.
- Eficiencia Energética: Desarrollar actuadores que consuman menos energía sin sacrificar rendimiento, lo cual es crítico para la portabilidad y autonomía de las prótesis.

- **Sensores:**

Son esenciales para proporcionar la información necesaria para las decisiones de control, como la detección de fuerza, posición y velocidad (Dollar & Herr, 2008).

- **Importancia y Aplicaciones**

Los sensores en prótesis mecatrónicas son dispositivos que recopilan información sobre el estado de la prótesis y su entorno. Esta información es crucial para realizar ajustes en tiempo real y asegurar una operación segura y efectiva.

- **Tipos y Funciones**

- Sensores de Fuerza y Torsión: Miden la fuerza aplicada o la carga que soporta la prótesis, lo cual es vital para evitar daños por sobrecarga.
- Sensores de Posición y Movimiento: Como los potenciómetros y goniómetros, que detectan la posición de las articulaciones protésicas.
- Sensores de Inercia: Acelerómetros y giroscopios proporcionan información sobre la orientación y aceleración, permitiendo ajustes para mantener el equilibrio.

- ***Microcontroladores y Procesadores:***

Estos sistemas son responsables del procesamiento de datos y la toma de decisiones, lo que permite a las prótesis operar de manera autónoma (Farina et al., 2014c).

- **Rol Clave y Características**

Microcontroladores y procesadores son el 'cerebro' de la prótesis, interpretando datos de los sensores y enviando comandos a los actuadores.

- **Aspectos Técnicos**

- Capacidad de Procesamiento: Deben ser capaces de procesar grandes volúmenes de datos con latencia mínima para una respuesta en tiempo real.
- Interconectividad: La capacidad de comunicarse con otros dispositivos y sistemas, incluyendo interfaces de usuario y redes de datos médicos.

- **Desafíos y Consideraciones**

- Interfaz Neural: La integración con señales neuronales para un control más natural y directo de la prótesis.
- Seguridad y Fiabilidad: Los sistemas deben ser robustos para prevenir fallos que podrían resultar en lesiones.

- **Software y Algoritmos de Control:**

Los algoritmos avanzados son necesarios para interpretar las señales de los sensores y traducirlas en movimientos naturales y eficientes (Zheng & Shen, 2015).

- **Necesidad y Función**

El software y los algoritmos de control constituyen la inteligencia que dirige cómo la prótesis interpreta los datos de los sensores y cómo actúa en consecuencia.

- **Tipos y Estrategias**

- Algoritmos de Control PID: Estos algoritmos mantienen el comportamiento de la prótesis dentro de parámetros deseables ajustando los errores entre la posición deseada y la real.
- Control Basado en Modelo: Utiliza modelos matemáticos de la prótesis y del miembro amputado para predecir y mejorar el control del movimiento.
- Control Adaptativo y Predictivo: Algoritmos que se ajustan a los cambios en el comportamiento del usuario y predicen la acción siguiente para un movimiento más fluido y natural.

- **Innovaciones y Avances**

- Aprendizaje Profundo y Redes Neuronales: Estos enfoques pueden manejar la complejidad de la interpretación de señales sensoriales y motoras para movimientos que se asemejen más a las extremidades biológicas.
- Control Cognitivo: Integración de señales cognitivas para anticipar la intención del movimiento antes incluso de que se inicie muscularmente.

### 6.4.3 Diseño de Prótesis

- **Identificación de Requerimientos:** Este proceso implica una evaluación detallada de las necesidades del usuario, incluyendo el análisis de la marcha, la funcionalidad deseada y las limitaciones individuales (Ziegler-Graham et al., 2008b).
- **Modelado y Simulación:** Se aplican técnicas de modelado y simulación computacional para predecir el comportamiento de la prótesis y realizar ajustes antes de la fabricación (Major Extremity Trauma Research Consortium (METRC), 2023).

- **Fabricación:** Las tecnologías de fabricación avanzadas, como la impresión 3D, permiten la producción de componentes personalizados con alta precisión y adaptabilidad anatómica (J. M. Zuniga et al., 2016).
- **Integración de Sistemas:** La integración efectiva de componentes es clave para el funcionamiento óptimo de las prótesis mecatrónicas, asegurando que los distintos subsistemas trabajen armónicamente (Hargrove et al., 2013).
- **Pruebas y Calibración:** Las pruebas son fundamentales para validar el rendimiento de la prótesis y para ajustar los parámetros de control que maximizarán la funcionalidad para el usuario (Morgenroth et al., 2012).
- **Entrenamiento y Rehabilitación:** Los programas de entrenamiento personalizados son esenciales para que los usuarios aprendan a utilizar las prótesis mecatrónicas de manera efectiva, lo que a menudo incluye el uso de realidad virtual y otros métodos de biofeedback (Perry et al., 2007)

#### 6.4.4 Avances y Desafíos Actuales

- **Interfaz con el Usuario:** Los sistemas de interfaz cerebro-computadora y las tecnologías mioeléctricas están siendo explorados para mejorar la comunicación entre el usuario y la prótesis (Wolpaw et al., 2002)
- **Materiales Avanzados:** La investigación en nuevos materiales busca crear prótesis más ligeras, más resistentes y que ofrezcan una apariencia estética mejorada (Safari, 2020)
- **Personalización y Asequibilidad:** Se trabaja en el desarrollo de prótesis que sean al mismo tiempo personalizadas y accesibles para una mayor población (Cuellar et al., 2019)
- **Realimentación Sensorial:** La incorporación de la retroalimentación sensorial es una importante área de investigación, con el objetivo de proporcionar sensaciones táctiles y mejorar la utilidad de las prótesis (Sensing & Dosen, 2020).

## 6.5 INTERFAZ CEREBRO-COMPUTADORA (BCI)

Una interfaz cerebro-computadora (BCI) es un sistema de comunicación que no depende de la actividad muscular normal y las vías nerviosas periféricas. Esta tecnología permite una interacción directa entre el cerebro y los dispositivos externos, generalmente computadoras o máquinas, utilizando señales neuronales (Wolpaw et al., 2002)

### 6.5.1 Tipos de BCI

Las BCI se clasifican generalmente según el método de adquisición de señales cerebrales, que puede ser invasivo, semi-invasivo, no invasivo y recientemente, híbrido (combina métodos). Los sistemas invasivos ofrecen señales limpias y precisas pero presentan mayores riesgos, mientras que los no invasivos son más seguros pero con señales más ruidosas (Lebedev & Nicolelis, 2006b).

#### ▪ **Invasivas:**

- **Descripción:** Implican la implantación directa de electrodos en el tejido cerebral.
- **Señales:** Proporcionan alta resolución y señales precisas.
- **Riesgos:** Presentan riesgos significativos como infecciones, rechazo y daño al tejido cerebral.
- **Implicaciones Éticas y Sociales:**
  - Cuestiones de seguridad a largo plazo y efectos secundarios.
  - Consideraciones sobre la privacidad cerebral, ya que pueden ser capaces de decodificar pensamientos y emociones con alta fidelidad.
  - El impacto en la identidad personal y la autonomía, especialmente en el caso de dispositivos que pueden influir en la actividad cerebral.

#### ▪ **Semi-Invasivas:**

- **Descripción:** Se colocan dispositivos en la superficie del cráneo, pero bajo el cuero cabelludo.
- **Señales:** Mejor calidad de señal que los sistemas no invasivos, pero con menos riesgos que los invasivos.

- **Implicaciones Éticas y Sociales:**
  - Menor, pero aún significativo, riesgo quirúrgico y posibles efectos a largo plazo.
  - Debates sobre el consentimiento informado y la competencia para usuarios con discapacidades graves.
- **No Invasivas:**
  - **Descripción:** Sensores colocados en la superficie del cuero cabelludo, como el EEG.
  - **Señales:** Más ruidosas y de menor resolución que los sistemas invasivos.
  - **Implicaciones Éticas y Sociales:**
    - Problemas de accesibilidad y la posibilidad de brechas sociales si el acceso a la tecnología BCI de alta calidad se limita a individuos con más recursos.
    - Consideraciones sobre el uso de datos y la privacidad, dado que incluso señales ruidosas pueden contener información personal.
- **Híbridas:**
  - **Descripción:** Combinan métodos invasivos y no invasivos para mejorar la calidad de las señales y la funcionalidad.
  - **Señales:** Buscan un equilibrio entre calidad de señal y minimización de riesgos.
  - **Implicaciones Éticas y Sociales:**
    - Desafíos éticos combinados de los sistemas invasivos y no invasivos.
    - Preguntas sobre cómo regular y controlar tecnologías que se encuentran en el límite de las categorías tradicionales.

### 6.5.2 Componentes Clave de un BCI

- **Adquisición de Señales:** Se refiere a la captura de la actividad cerebral, ya sea a través de electrodos en el cuero cabelludo (EEG) o por medios más invasivos como los electrodos intracorticales (Vidal, 1973b).
- **Procesamiento de Señales:** Este paso implica la filtración, amplificación y decodificación de las señales cerebrales para interpretar las intenciones del usuario (Wolpaw et al., 1991).

- **Salida de Comandos:** Convertir las señales decodificadas en comandos para controlar dispositivos externos, como computadoras o prótesis robóticas (Pfurtscheller et al., 2000).

### 6.5.3 Aplicaciones de las BCI

- **Medicina y Rehabilitación:** Las BCI son especialmente prometedoras en el campo de la rehabilitación de pacientes con lesiones del sistema nervioso, como en casos de accidentes cerebrovasculares o lesiones de la médula espinal (Dobkin, 2007)
- **Control de Prótesis y Exoesqueletos:** Permiten a las personas con amputaciones o parálisis controlar prótesis robóticas de manera intuitiva (L. Hochberg et al., 2006)
- **Comunicación Mejorada:** Las BCI brindan medios de comunicación para personas con condiciones severas de bloqueo motor, como la esclerosis lateral amiotrófica (ALS) (Birbaumer & Cohen, 2007)

## 6.6 RETROALIMENTACIÓN HÁPTICA

La retroalimentación háptica, también conocida como tacto háptico, es una tecnología que simula la experiencia del tacto al aplicar fuerzas, vibraciones o movimientos al usuario. Esta tecnología permite a los usuarios recibir información táctil de dispositivos electrónicos, lo que puede mejorar la interacción del usuario con simulaciones virtuales o controles remotos (Srinivasan & Basdogan, 1997).

### 6.6.1 Tipos de Retroalimentación Háptica

- **Táctil:** Se refiere a las sensaciones que se pueden percibir a través de la piel, como la textura, el calor o la vibración.
- **Cinestésica:** Se relaciona con la percepción del movimiento y la posición del cuerpo, incluyendo la sensación de fuerza y resistencia.

### 6.6.2 Componentes Clave de la Retroalimentación Háptica

- **Actuadores:** Dispositivos como motores de vibración o exoesqueletos que crean la respuesta háptica física.

- **Sensores:** Dispositivos que detectan la interacción del usuario y envían señales a un controlador para ajustar la respuesta háptica.
- **Controladores:** Sistemas electrónicos o software que procesan la entrada del sensor y dirigen el actuador para proporcionar la respuesta háptica adecuada.

### 6.6.3 Aplicaciones de la Retroalimentación Háptica

- **Simuladores de Entrenamiento:** Se utiliza en simuladores de vuelo y médicos para proporcionar una experiencia más realista durante el entrenamiento (Salisbury et al., 2004).
- **Dispositivos Móviles y Videojuegos:** Mejora la experiencia de usuario al proporcionar un *feedback* táctil durante la interacción con la interfaz (Hoggan et al., 2008).
- **Teleoperación y Robótica:** Permite a los operadores sentir las fuerzas que se aplicarían en un entorno remoto, como en la cirugía robótica (Davies, 2000).

### 6.6.4 Desafíos y Consideraciones en la Retroalimentación Háptica

- **Realismo:** Crear sensaciones que sean lo suficientemente realistas como para engañar al cerebro puede ser extremadamente complicado, especialmente al simular texturas o propiedades de materiales complejos.
- **Latencia:** La respuesta rápida es crucial para mantener la ilusión de la interacción directa. La latencia puede romper la inmersión y afectar el rendimiento del usuario.
- **Integración Multisensorial:** La retroalimentación háptica a menudo debe combinarse con otras señales sensoriales, como visuales o auditivas, para crear una experiencia convincente y útil.

## 6.7 MACHINE LEARNING

El aprendizaje automático, o Machine Learning (ML), es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos capaces de aprender de los datos y hacer predicciones o tomar decisiones basadas en ellos. Se clasifica principalmente en

tres categorías: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo (Hastie et al., 2009)

### 6.7.1 Aprendizaje Supervisado

Es el enfoque de Machine Learning más común, donde el algoritmo aprende de un conjunto de datos etiquetado, intentando hacer predicciones o decisiones basadas en esa información. Los algoritmos de aprendizaje supervisado pueden dividirse en dos categorías principales: clasificación y regresión (C. M. Bishop, 2023)

#### ▪ *Clasificación*

- **K-Nearest Neighbors (KNN):** Algoritmo no paramétrico que clasifica un nuevo punto de datos basándose en cómo sus 'k' vecinos más cercanos están clasificados.
- **Árboles de Decisión:** Herramienta de predicción que utiliza un modelo de decisiones y sus posibles consecuencias, recurriendo a un gráfico en forma de árbol.
- **Redes Neuronales y Deep Learning:** Sistemas computacionales inspirados en las redes neuronales biológicas que constan de capas de nodos o "neuronas".

#### ▪ *Regresión*

- **Regresión Lineal:** Busca modelar la relación entre dos variables ajustando una ecuación lineal a los datos observados.
- **Regresión Ridge/Lasso:** Métodos de regresión que incluyen una penalización en los coeficientes para evitar el sobreajuste y mejorar la generalización.

### 6.7.2 Aprendizaje No Supervisado

El aprendizaje no supervisado trabaja con datos que no han sido etiquetados, clasificados o categorizados, y el algoritmo intenta actuar sobre esos datos sin guía previa (Hastie et al., 2009).

#### ▪ *Clustering*

- **K-Means:** Particiona 'n' observaciones en 'k' clusters en los cuales cada observación pertenece al cluster con la media más cercana.

- **Clustering Jerárquico:** Método de análisis de clusters que busca construir una jerarquía de clusters.
- **DBSCAN:** Basado en densidad, este algoritmo agrupa puntos que están estrechamente empaquetados juntos, marcando como outliers los puntos que están solos en regiones de baja densidad.
- **Reducción de Dimensionalidad**
- **Análisis de Componentes Principales (PCA):** Técnica para simplificar la complejidad de espacios de datos dimensionales altos reduciéndolos a sus componentes más significativos.
- **Auto encoders:** Redes neuronales utilizadas para aprender representaciones eficientes de los datos, típicamente para la reducción de la dimensionalidad.
- **Reglas de Asociación**
- **Algoritmo Apriori:** Método que identifica los ítems frecuentes en conjuntos de datos y deduce las reglas de asociación que destacan las relaciones generales entre los ítems.

### 6.7.3 Aprendizaje por Refuerzo

El aprendizaje por refuerzo es un tipo de Machine Learning en el que un agente aprende a tomar decisiones secuenciales. Recibe retroalimentación en forma de recompensas y castigos a medida que interactúa con un entorno dinámico (SYNCED, 2017).

- **Q-Learning:** Algoritmo de aprendizaje por refuerzo que busca aprender la calidad de las acciones indicando qué tan útil es una acción para ganar alguna recompensa futura.
- **Política de Gradientes:** Método que ajusta las políticas directamente, mejorando las probabilidades de acciones que llevan a mayores recompensas.
- **Aprendizaje Profundo por Refuerzo:** Combina redes neuronales profundas con un marco de aprendizaje por refuerzo para tomar decisiones.

#### 6.7.4 Regresión Logística en el Desarrollo de Prótesis Mecatrónicas

La regresión logística, dentro del campo de las prótesis mecatrónicas, juega un papel fundamental en la interpretación de señales biológicas para la clasificación de intenciones motoras y la toma de decisiones autónomas por parte de los sistemas inteligentes de prótesis (Fiuza Pérez & Rodríguez Pérez, 2000). A continuación, se detalla cómo este modelo estadístico se integra en el desarrollo y mejora de prótesis mecatrónicas.

- **Fundamentos en Prótesis Mecatrónicas**

Señales biológicas como variables independientes:

- Electromiografía (EMG): Señales eléctricas generadas por los músculos que pueden ser usadas como predictores para determinar la intención de movimiento del usuario de la prótesis.
- Sensores de Presión: Usados para detectar la interacción del usuario con su entorno y ajustar el agarre de la prótesis.

- **Variable Dependiente Binaria**

- Acción de la Prótesis: Por ejemplo, abrir o cerrar la mano protésica, donde 1 representa "cerrar" y 0 "abrir".

- **Modelo de Regresión Logística en Prótesis Mecatrónicas**

El modelo se ajusta para predecir la probabilidad de que se ejecute una acción específica basada en los *inputs* sensoriales. La ecuación del modelo puede incluir términos para las señales EMG, la fuerza aplicada, la posición de la extremidad, y otros factores relevantes (Mirete, s. f.).

- **Evaluación del Modelo**

En el contexto de las prótesis mecatrónicas, las métricas de rendimiento no solo incluyen la precisión del modelo, sino también la velocidad de la respuesta y cómo afecta la usabilidad y la aceptación del usuario.

- **Aplicaciones Específicas**
- **Control Adaptativo**
- Auto calibración: Modelos que pueden ajustarse en tiempo real para adaptarse a cambios en las señales EMG debido a la fatiga muscular o a cambios de posición.
- **Clasificación de Gestos**
- Intención del Usuario: Distinguir entre diferentes gestos pretendidos por el usuario para controlar la prótesis con alta precisión y naturaleza.

## 6.8 KIT AURA COMO BIOSENSOR

Los biosensores son dispositivos que combinan un componente biológico con un detector fisicoquímico para medir la presencia o concentración de sustancias biológicas. Los electroencefalogramas (EEG) son una aplicación importante de los biosensores, permitiendo monitorear la actividad eléctrica del cerebro para diversas aplicaciones clínicas y de investigación. El desarrollo de tecnologías accesibles como el Kit Aura de Mirai Innovation representa un avance significativo en la democratización de estas herramientas (“Aura Through Time,” 2023.).

### 6.8.1 Desarrollo Tecnológico del Kit Aura

- **Aura 00 / 2018 véase Figura 16**

Con una sólida experiencia en neurociencia cognitiva aplicada y tecnologías EEG, el Dr. Christian Peñaloza identificó la necesidad de desarrollar dispositivos EEG más económicos. Esta visión se materializó con el lanzamiento de Aura 00, un sistema que significó un avance notable en la reducción de costos de los equipos EEG profesionales. Ofrecido a un precio de \$3,500, Aura 00 se presentó como una alternativa asequible frente a los modelos tradicionales que usualmente cuestan entre \$15,000 y \$16,000. El sistema Aura 00 incluía un software especializado, una placa de biosensores y una gorra EEG, todos estos componentes fueron diseñados y producidos internamente, fortaleciendo la innovación y accesibilidad del producto.



1st Aura Prototype

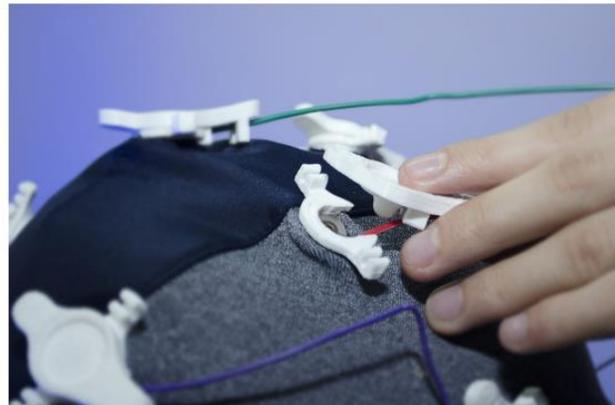


1st Aura Case

Figura 16 Aura 00 ("Aura Through Time," 2023.)

▪ **Aura 01 / 2019 véase Figura 17**

La colaboración del Dr. Christian Peñaloza con la O design studio de México condujo al desarrollo de Aura 01, una versión mejorada del dispositivo EEG anterior. Este nuevo modelo se destacó por un diseño más formal y patrones optimizados para la gorra EEG, elevando tanto su funcionalidad como su apariencia. Además, se implementaron mejoras técnicas significativas, incluyendo la producción de electrodos mediante impresión 3D, lo que no solo mejoró la estética del dispositivo, sino también su rendimiento general.



Aura Cap 01

Figura 17 Aura 01 ("Aura Through Time," 2023.)

- **Aura 02 / 2022 véase Figura 18**

Mirai Innovation, siempre atenta a la evolución tecnológica y a las necesidades cambiantes de sus clientes, lanzó Aura 02 como parte de su compromiso con la innovación continua. Este nuevo modelo fue desarrollado en colaboración con exalumnos y diseñadores industriales, logrando un diseño integrado que mantiene una coherencia estética entre la placa de biosensores y la gorra EEG. Además, se mejoró la experiencia de usuario introduciendo serigrafía en la gorra EEG para indicar claramente la posición de los electrodos. También se optimizó el diseño del estuche del biosensor usando sinterización láser selectiva (SLS), mejorando su resistencia y reduciendo su grosor, lo que resultó en un dispositivo más robusto y elegante.



*Figura 18 Aura 02 (“Aura Through Time,” 2023.)*

- **Importancia del Desarrollo**

El progreso de tecnologías como el Kit Aura es crucial en campos como la neurociencia, la robótica y la psicología, entre otros. La disponibilidad de herramientas económicas y de alta calidad permite a un rango más amplio de investigadores y profesionales acceder a equipos antes prohibitivos.

- ***Impacto en la Investigación y la Industria***

La serie de dispositivos Aura ha permitido a investigadores y científicos adentrarse en el estudio del cerebro humano con una inversión inicial más baja, pudiendo así expandir la frontera del conocimiento y la aplicación práctica en áreas como la detección temprana de enfermedades neurológicas, interfaces cerebro-computadora y monitoreo del bienestar mental.

## 7 METODOLOGÍA

---

La metodología V, también conocida como modelo V o desarrollo en V, es un modelo de desarrollo que ilustra el proceso en forma de una V, donde cada paso de desarrollo (en la rama izquierda de la V) está asociado con un paso de prueba correspondiente (en la rama derecha de la V). La base de la V representa la implementación del código, y las ramas ascendentes representan la integración y las pruebas sistemáticas. Este modelo es especialmente valorado por su enfoque en la verificación y validación en cada etapa del desarrollo, lo que asegura la calidad y el correcto funcionamiento del sistema antes de avanzar a la siguiente fase, véase Figura 19.

Se ha escogido la metodología V por encima de la metodología de diseño mecatrónico tradicional debido a varias razones estratégicas y prácticas. La metodología V facilita una mayor visibilidad en el proceso de desarrollo, permitiendo una mejor gestión de riesgos y asegurando que cada componente del sistema mecatrónico sea probado rigurosamente antes de proceder a la siguiente etapa. Esto es particularmente importante en sistemas complejos como las prótesis de mano controladas por señales electroencefalográficas, donde la fiabilidad y la seguridad son de suma importancia.

En contraste, la metodología de diseño mecatrónico, aunque es holística y multidisciplinaria, no siempre enfatiza la correspondencia directa entre el desarrollo y las pruebas de la misma manera estructurada que el modelo V. La naturaleza iterativa del diseño mecatrónico puede ser ventajosa en proyectos que requieren una gran cantidad de exploración y adaptación durante el diseño, pero en el contexto del presente proyecto, la previsibilidad y el control sistemático del modelo V son preferibles para cumplir con los requisitos de seguridad y funcionamiento.

Además, la metodología V permite una integración más sencilla y directa de la retroalimentación háptica en el proceso de desarrollo. A medida que se avanza hacia arriba en la rama de integración de la V, se puede probar los subsistemas de control y los algoritmos de procesamiento de señales en conjunto con el sistema háptico para asegurar que funcionen de forma sinérgica.

Por estas razones, la metodología V ha sido seleccionada como el enfoque más adecuado para el desarrollo de este sistema mecatrónico, asegurando que cada paso de desarrollo sea validado y verificado de manera rigurosa, minimizando los riesgos y mejorando la confiabilidad del proyecto.

## 7.1 PASOS CLAVE EN LA METODOLOGÍA V

- **Izquierda de la V (Requisitos y Diseño del Sistema):**
  - **Definición de Requisitos:** Se especifican los requisitos del sistema y se entienden las expectativas de los usuarios finales.
  - **Diseño del Sistema:** Se traducen los requisitos en una arquitectura de sistema y se toman decisiones sobre la estructura general del sistema.
  - **Diseño Arquitectónico (o de Alto Nivel):** Se realiza el diseño de alto nivel para definir la interacción entre los componentes de alto nivel del sistema.
  - **Diseño Detallado (o de Bajo Nivel):** Se realiza el diseño de bajo nivel para definir el comportamiento exacto de los módulos individuales y los algoritmos que se implementarán.
- **Base de la V (Modelado y Análisis):**
  - **Implementación y Codificación:** En la base de la V, la implementación del código efectivamente se lleva a cabo, así como la realización del proceso ingenieril mecánico, eléctrico, electrónico y de programación necesarios.
- **Derecha de la V (Integración del Sistema):**
  - **Pruebas Unitarias:** Se prueban individualmente los componentes o unidades de código para asegurarse de que funcionan correctamente.
  - **Pruebas de Integración:** Se prueban las interacciones entre los módulos o componentes para asegurarse de que se integran correctamente.
  - **Pruebas del Sistema:** Se evalúa el sistema completo para asegurarse de que cumple con los requisitos especificados.

- **Pruebas de Aceptación del Usuario (UAT):** Los usuarios finales prueban el sistema en un entorno que simula las condiciones de operación reales para validar que el sistema cumple con sus necesidades y expectativas.

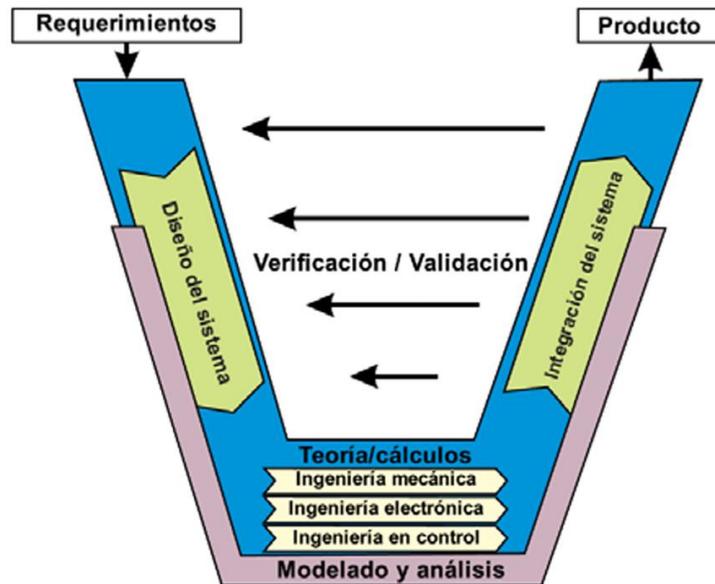


Figura 19. Metodología en V (Graessler & Hentze, 2020)

Para llevar a cabo el desarrollo de la metodología y dar respuesta a cada uno de los pasos claves de este modelo, se distribuyó el trabajo en 5 fases o etapas de trabajo de la siguiente manera:

## 7.2 REQUISITOS Y DISEÑO DEL SISTEMA

Previo al inicio de la fase de definición de requisitos del proyecto, conforme a la metodología V, se ha llevado a cabo una exhaustiva revisión bibliográfica. Este proceso sistemático ha incluido la identificación, el análisis y la síntesis de la literatura actual y relevante en los campos de las interfaces cerebro-computadora, la robótica avanzada y los sistemas de retroalimentación háptica. El resultado de esta indagación es un compendio detallado del estado del arte que no sólo refleja el panorama actual de las tecnologías implicadas, sino que también destaca las brechas de conocimiento y las oportunidades de innovación en el ámbito de la interacción hombre-máquina.

Conjuntamente, se ha procedido a una evaluación meticulosa de los requisitos técnicos y funcionales que el sistema a desarrollar debe satisfacer, en respuesta al desafío planteado: ¿Cómo puede un operador humano controlar una mano robótica con la mente y percibir retroalimentación háptica? Esta evaluación ha sido realizada a través de una metodología rigurosa que incluye el análisis de necesidades, la definición de especificaciones operacionales y la consideración de los estándares de seguridad y usabilidad aplicables. Esto constituye la Fase 1 de 5 fases o etapas del desarrollo de esta metodología.

### **7.2.1 FASE 1 Diseño de Ingeniería y Modelado**

Los objetivos fundamentales establecidos para el sistema se centran en los siguientes puntos:

- ***Definición de Requisitos:***
  - Realizar una búsqueda bibliográfica integral y compilar un estado del arte centrado en interfaces cerebro-computadora, robótica y retroalimentación háptica.
  - Identificar y documentar exhaustivamente los requisitos funcionales, no funcionales y del sistema. Esto incluirá entender las capacidades actuales de procesamiento de señales EEG, la mecánica y la cinemática de las manos robóticas, y los métodos de retroalimentación háptica.
  - Desarrollar escenarios de uso y casos de prueba a partir de los requisitos identificados, que guiarán el diseño y la validación del sistema. Por ejemplo, definir cómo el operador humano interactuará con la mano robótica y qué tipo de sensaciones se deben reproducir a través del sistema de retroalimentación háptica.
- ***Diseño del Sistema:***
  - Conceptualizar una arquitectura de sistema global que integre la adquisición y procesamiento de señales EEG, el control de la mano robótica, y el sistema de retroalimentación háptica.

- Establecer las especificaciones de alto nivel para el hardware (sensores EEG, actuadores para la mano robótica, dispositivos de retroalimentación háptica) y el software (algoritmos de procesamiento de señales, software de control, interfaces de usuario).
- **Diseño Arquitectónico (o de Alto Nivel):**
  - Desarrollar un diseño modular para que cada componente (procesamiento de señales EEG, control robótico, retroalimentación háptica) pueda ser diseñado, implementado y probado de forma independiente. Esto se verá reflejado más adelante en la fase de integración del sistema.
  - Crear diagramas de flujo y modelos que muestren la interacción entre los módulos del sistema y cómo se procesarán y transmitirán los datos a través del sistema como se muestra en la Figura 20:

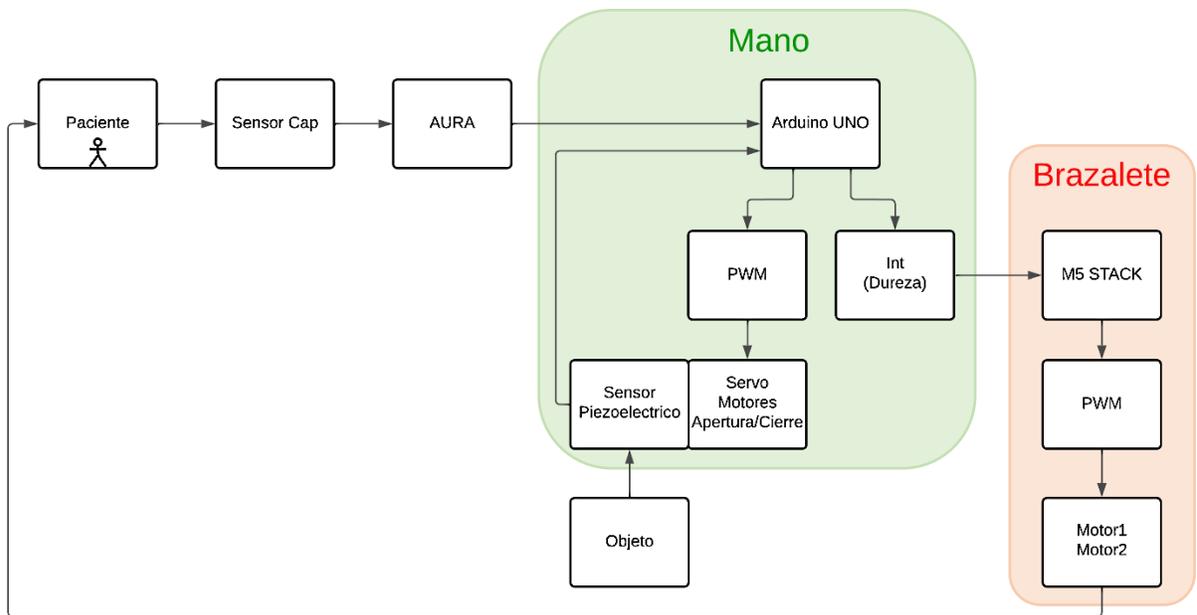


Figura 20. Diseño Arquitectónico. Fuente: Autor.

- ***Diseño Detallado (o de Bajo Nivel):***
  - Especificar los algoritmos de procesamiento de señales EEG que detectarán los patrones de pensamiento relacionados con el movimiento y la manipulación.
  - Diseñar el esquema de control detallado de la mano robótica, los algoritmos de control de motores y la integración de sensores.
  - Desarrollar un diseño para el sistema de retroalimentación háptica, que incluirá la selección de tecnologías para crear sensaciones táctiles y cómo estas se sincronizarán con las acciones de la mano robótica.
  
- ***Diseño Mecatrónico:***
  - Codificar los algoritmos de procesamiento de señales EEG en software, utilizando plataformas adecuadas y lenguajes de programación que aseguren la eficiencia y la fiabilidad del sistema en tiempo real,
  - Construir un prototipo de la mano robótica basado en el diseño («InMoov body parts library», s. f.), seleccionando materiales y componentes, ensamblando la estructura mecánica y la electrónica necesaria, e integrando los actuadores y sensores.

En la Figura 21 se presenta el modelo de ensamblaje CAD realizado en el software de diseño asistido por computador SolidWorks para la fabricación aditiva de los componentes.

Para su Construcción, se extraen las piezas de un fichero brindado por el diseño Opensource Inmoov («InMoov Body Parts Library», s. f.) en el que los autores brindan las piezas adecuadas para construir prótesis de diferentes partes del cuerpo. Las piezas para fabricación 3D se encuentran consignadas en una tabla en el Anexo , las cuales fueron fabricadas en PLA. Cabe resaltar que el diseño del ensamblaje de la prótesis de mano cuenta con 16 grados de libertad teniendo una independencia de movilidad en los dedos.

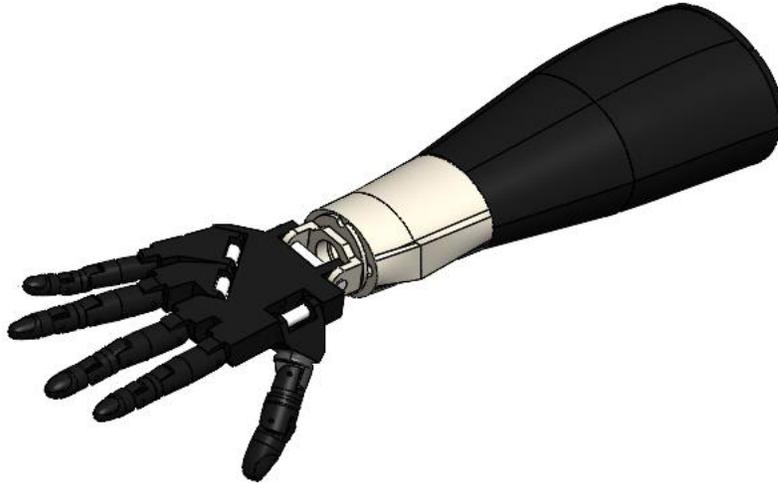


Figura 21. Diseño CAD de ensamblaje de mano mecánica. Fuente: Autor.

- Implementar el sistema de retroalimentación háptica, que incluirá el desarrollo de guantes con actuadores o sistemas de estimulación que proporcionen al operador la sensación de tacto o presión.

El proceso de diseño del sistema comienza con el modelado detallado de una caja en el software SolidWorks, específicamente diseñada para contener los micromotores de vibración. Esta fase inicial es crucial y está documentada visualmente en la Figura 22.

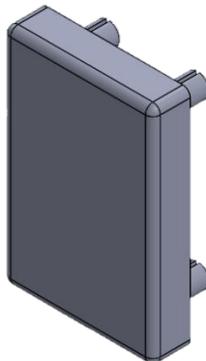


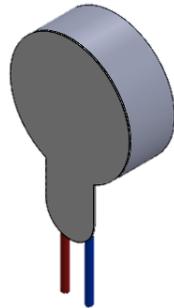
Figura 22. Diseño CAD Caja Micromotores. Fuente: Autor.

Tras completar el diseño de la primera caja, se procede a la fabricación de ocho cajas adicionales, las cuales están diseñadas para conectarse entre sí a través de una malla de material flexible TPU. Este ensamble proporciona la flexibilidad y adaptabilidad necesarias para el sistema, y se detalla en la Figura 23.

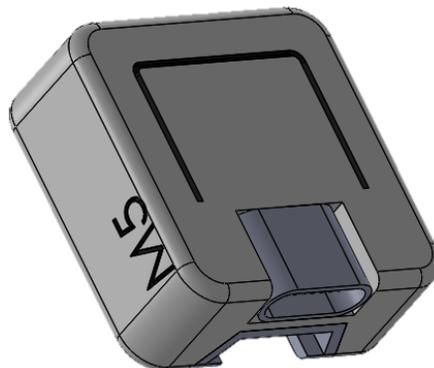


*Figura 23. Diseño CAD Malla para Cajas. Fuente: Autor.*

Una vez establecida la estructura de las cajas, el enfoque se desplaza hacia los componentes electrónicos del sistema. Se diseñan cuidadosamente los componentes comerciales, que incluyen el micromotor vibrador (Véase Figura 24) y el microcontrolador M5 Stack (Véase Figura 25), Ya que estos componentes son los que permiten la operatividad del producto final.



*Figura 24. Diseño CAD Micromotor. Fuente: Autor.*



*Figura 25. Diseño CAD de M5 stack. Fuente: Autor.*

El paso final, tras definir los componentes y la estructura física, consiste en realizar una simulación detallada del producto completo. En la Figura 26 se muestra el diseño CAD del dispositivo de retroalimentación propuesto, en el cual se integran los micromotores vibradores 1030 DC. Estos motores se activan electrónicamente al recibir una señal eléctrica que provoca el movimiento desigual de su eje, generando vibración. Por otro lado, el controlador M5 Stack desempeña el papel de microcontrolador basado en ESP32, que es adecuado para controlar y alimentar los motores vibradores, además de gestionar la comunicación entre la mano y el brazaletes.

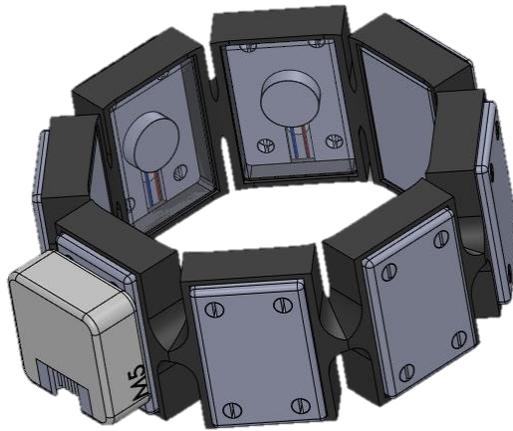


Figura 26. Diseño CAD de brazaletes feedback incorporando motores y M5 stack (microcontrolador). Fuente: Autor.

### 7.3 MODELADO Y ANÁLISIS

Alcanzando el vértice inferior de la metodología V, se encuentra la fase crítica de modelado y análisis. Esta etapa es el núcleo de la conversión conceptual del diseño conceptual y detallado en un sistema tangible y operativo. Aquí, los diversos componentes de software y hardware son desarrollados, integrados y codificados, culminando en la realización física del sistema de control de la mano robótica y la retroalimentación háptica. Esto constituye la Fase 2, Fase 3 y Fase 4, de 5 fases o etapas del desarrollo de esta metodología.

### 7.3.1 FASE 2 Construcción y Codificación Inicial

- **Construcción Mecánica del Prototipo de Mano Robótica**

En esta etapa se desarrolló y se realizó el ensamblaje de la estructura mecánica de la mano robótica, asegurando su funcionalidad en términos de movilidad y comprobando tal como se menciona en la fase del diseño mecatrónico, una independencia en los movimientos de los dedos y muñeca proporcionando 16 grados de libertad para una movilidad muy similar a una mano humana. Se parte haciendo un alistamiento de componentes mecánicos y electrónicos para el ensamblaje (véase Figura 27) del prototipo físico partiendo por el ensamblaje de la mano como se muestra en la Figura 28, seguido de la muñeca rotatoria (véase Figura 29) y finalizando con el antebrazo, junto a los servos actuadores (MG996R) que hacen que la mano abra y cierre, como se muestra en la Figura 30.



Figura 27. Selección de componentes mecánicos y electrónicos. Fuente: Autor.



Figura 28. Ensamblaje de mano robótica. Fuente: Autor.

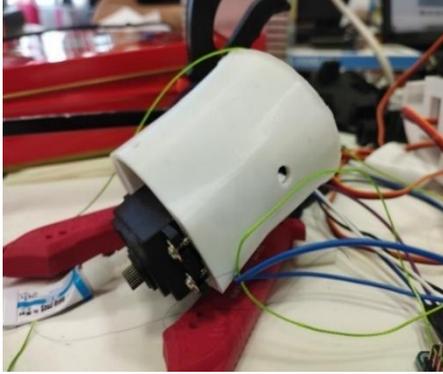


Figura 29. Ensamblaje de muñeca mecánica con actuator. Fuente: Autor.

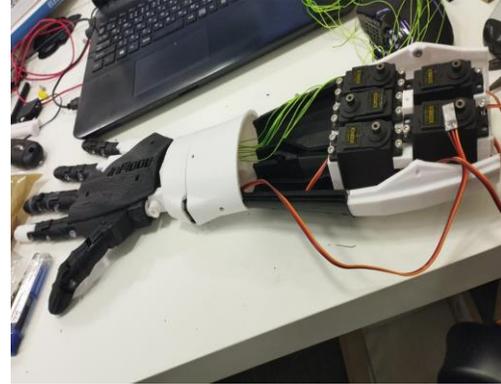


Figura 30. Ensamblaje mano, muñeca y actuadores electrónicos. Fuente: Autor.

#### ▪ **Codificación del Algoritmo en Arduino para el Control de la Mano Robótica**

Se realizó la Implementación de un algoritmo básico en una plataforma Arduino para gestionar la apertura y cierre de la mano robótica, su diagrama de flujo se puede ver en la Figura 31 y a continuación se da una explicación sobre el contenido y funcionamiento de este código (Anexo 1 Código Control Motores Prótesis

```
#include <Servo.h>
):
```

- El código realizado se ha implementado en la plataforma Arduino y está diseñado para controlar una mano robótica. Utiliza la librería Servo.h para manejar hasta cinco servomotores que actuarían como articulaciones de la mano robótica. A continuación, se detalla el funcionamiento del código:
- Se definen cinco objetos de tipo Servo, uno para cada dedo de la mano robótica. También se declara una variable angle que almacenará la posición deseada del servo (en grados), la cual se inicializa en 90 grados, un ángulo neutro para los dedos de la mano.
- En la función setup(), se inicializa la comunicación serial a 9600 baudios y se asocian los servomotores a los pines correspondientes del Arduino. Luego, se coloca cada servo en el ángulo inicial definido por la variable angle.
- La función loop() se ejecuta de manera continua y comprueba si se han recibido datos a través del puerto serial. Si se recibe un carácter, este se lee y, en función de su

valor, se ajusta la variable angle a 0, 180 o 90 grados, lo cual corresponde a las instrucciones de abrir, cerrar o detener los dedos de la mano robótica, respectivamente. Después de cualquier cambio, se llama a la función updateServos().

- o La función updateServos() verifica si el ángulo ha cambiado desde la última actualización. Si es así, actualiza la posición de todos los servomotores para reflejar el nuevo ángulo y almacena el valor actual de angle en previousAngle para comparaciones futuras.

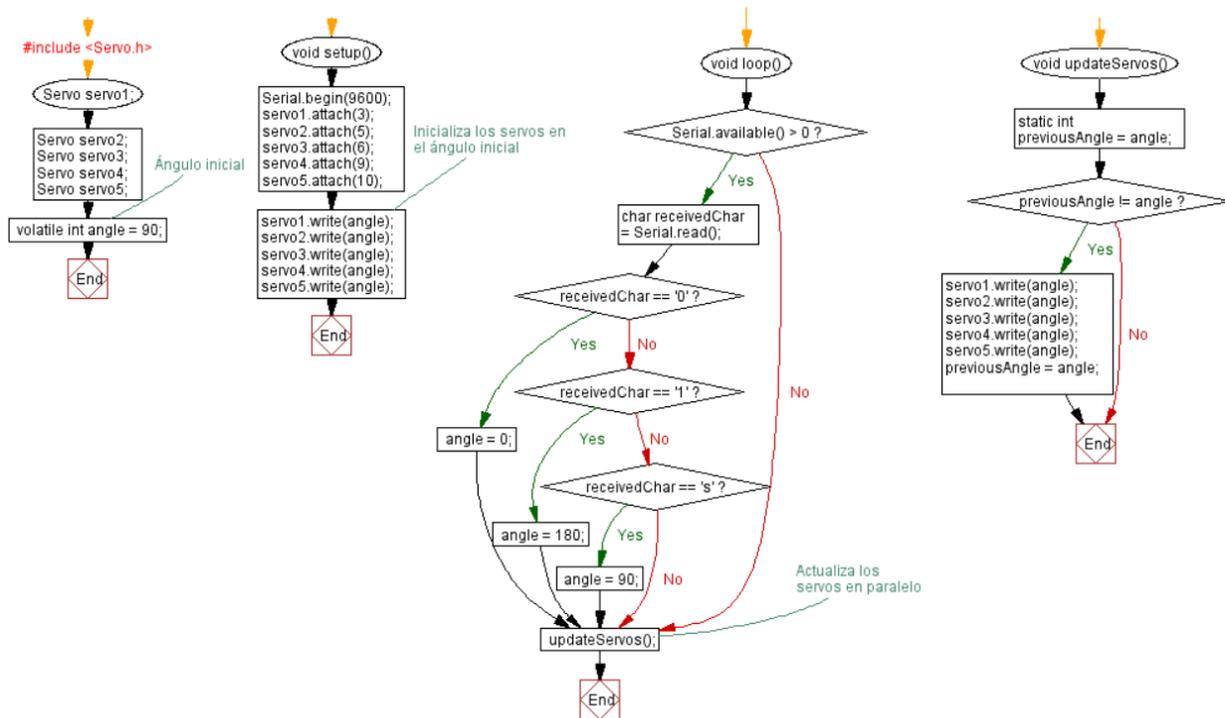


Figura 31. Diagrama de Flujo del Algoritmo en Arduino para el Control de la Mano Robótica. Fuente: Autor.

### Validación del Funcionamiento Mecánico

En esta etapa se hizo una validación del funcionamiento de los mecanismos de apertura y cierre de la mano robótica accionados por señales procedentes de los sensores mioeléctricos mediante pruebas de escritorio.

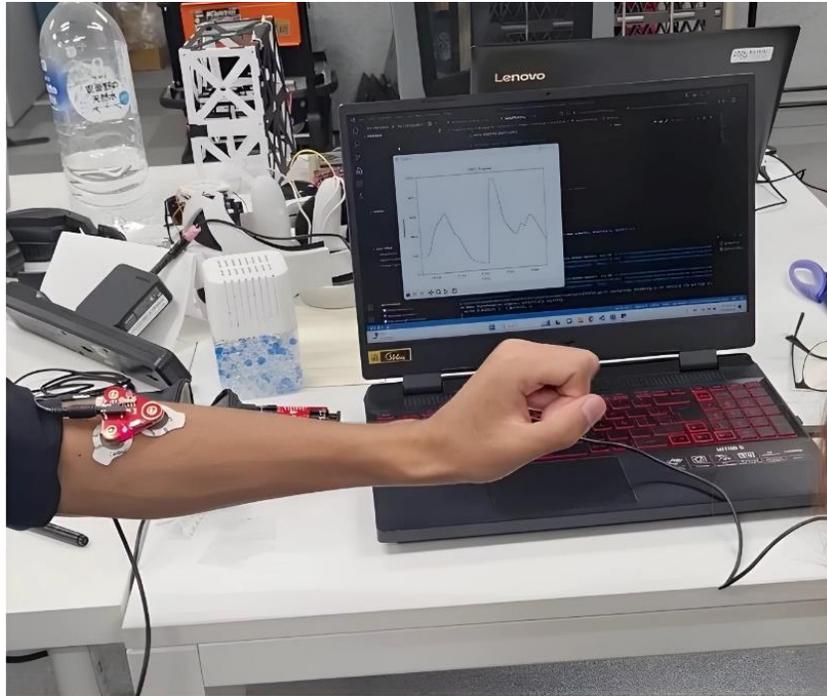


Figura 32. Funcionamiento de la mano con sensores mioeléctricos MyoWare. Fuente: Autor.

En la Figura 32 se observa la captación de la señal de los músculos por medio de los sensores MyoWare EMG, para el control de apertura o cierre de la mano robótica, permitiendo el accionamiento de los servomotores y validando el correcto funcionamiento del sistema mecánico.

En la interfaz gráfica de salida proporcionada por el Software Arduino se obtuvo un rango de la señal en valores de milivoltios a través del tiempo, dando como resultado la amplitud de señal en modo de diferencia de potencial obtenida al momento en que se tensionan los músculos del brazo ubicados en un lugar óptimo para su captación por medio de electrodos.

El sensor MyoWare es un dispositivo de electromiografía (EMG) que se utiliza para medir la actividad eléctrica de los músculos. La señal EMG captada por este sensor se mide típicamente en milivoltios (mV), reflejando que la actividad muscular genera señales eléctricas dentro de este rango de voltaje.

La gráfica que se visualiza en la pantalla de la computadora muestra probablemente la señal EMG en tiempo real o un conjunto de datos recopilados durante una sesión. Es relevante destacar que los rangos del eje Y (amplitud) y del eje X (tiempo) pueden ajustarse en el software empleado para visualizar y analizar los datos del sensor MyoWare, permitiendo así adaptar la presentación a las necesidades específicas del experimento o de la medición realizada.

Para una interpretación precisa de los datos mostrados en pantalla, es crucial disponer de información adicional sobre la configuración del dispositivo, incluyendo el rango de voltaje seleccionado para el eje Y y la escala de tiempo para el eje X. Adicionalmente, los picos y valles en la señal representan momentos de contracción y relajación muscular, respectivamente. Analizar estos datos en correlación con la actividad física realizada durante la medición puede proporcionar una comprensión más profunda de la función muscular y la respuesta a la estimulación.

### **7.3.2 FASE 3 Procesamiento de Señales y Machine Learning**

- ***Adquisición, Calibración y Preprocesamiento para el Entrenamiento de Modelos de Aprendizaje Automático***

Se realizó la captura y el ajuste fino de las señales electroencefalográficas emitidas por el biosensor AURA (ver anexo 11.10), un proceso crucial que prepara los datos para un análisis detallado y su procesamiento posterior. Este procedimiento incluye el tratamiento y la preparación de los datos, fundamentales para alimentar y entrenar el modelo de Machine Learning, con el objetivo de optimizar el rendimiento en la detección de patrones de movimiento. El proceso abarca cinco algoritmos que trabajarán de manera coordinada, los cuales se detallarán a continuación, asegurando así una integración eficaz entre la adquisición de señales y su aplicación práctica en sistemas de aprendizaje automático.ç

- **Código AURA (Algoritmo1):**

Este script de Python (.) involucra la transmisión de datos desde un dispositivo EEG que emite marcadores relacionados con la actividad cerebral u otras señales fisiológicas, y en la Figura 33 se presenta su respectivo diagrama de flujo.

- El script utiliza la librería pylsl para interactuar con una transmisión LSL (Lab Streaming Layer), que es un sistema para la transmisión sincronizada en tiempo de datos dentro de un entorno de laboratorio.
- El script comienza importando los módulos necesarios: datetime para manejar funciones relacionadas con el tiempo, pylsl para interactuar con la transmisión LSL, numpy para operaciones numéricas y time (aunque se importa, pero no se usa en el fragmento). Luego busca una transmisión de marcadores con el nombre 'AURA\_Power' en la red e intenta crear una entrada para leer datos de esta transmisión.
- Se define la función Time\_UP para comprobar si han pasado 10 segundos desde old, que se pasa a la función como un argumento. Si han pasado más de 10 segundos, reinicia el sello de tiempo old al tiempo actual y establece el booleano bo a False. El script espera a que el usuario presione enter para comenzar la primera parte del experimento.
- El primer bucle while recopila muestras de la entrada durante 10 segundos, agregando el vigésimo elemento de cada muestra a una lista llamada Abierto. Luego calcula el promedio de estos valores una vez que finaliza el bucle. El script espera a que el usuario presione enter nuevamente para comenzar la segunda parte del experimento.
- El segundo bucle while es similar al primero, pero recopila las muestras en una lista llamada Cerrado. Después de 10 segundos, también calcula el promedio de estos valores. El script calcula un valor de Threshold como la media de Abierto\_AVG y Cerrado\_AVG. Imprime el Threshold, el promedio del primer conjunto de muestras (Abierto\_AVG) y el promedio del segundo conjunto de muestras (Cerrado\_AVG), marcando el final del experimento.

Por último, guarda el Threshold en un archivo .npy (LIMITES.npy), que se puede cargar más tarde para análisis o uso posterior.

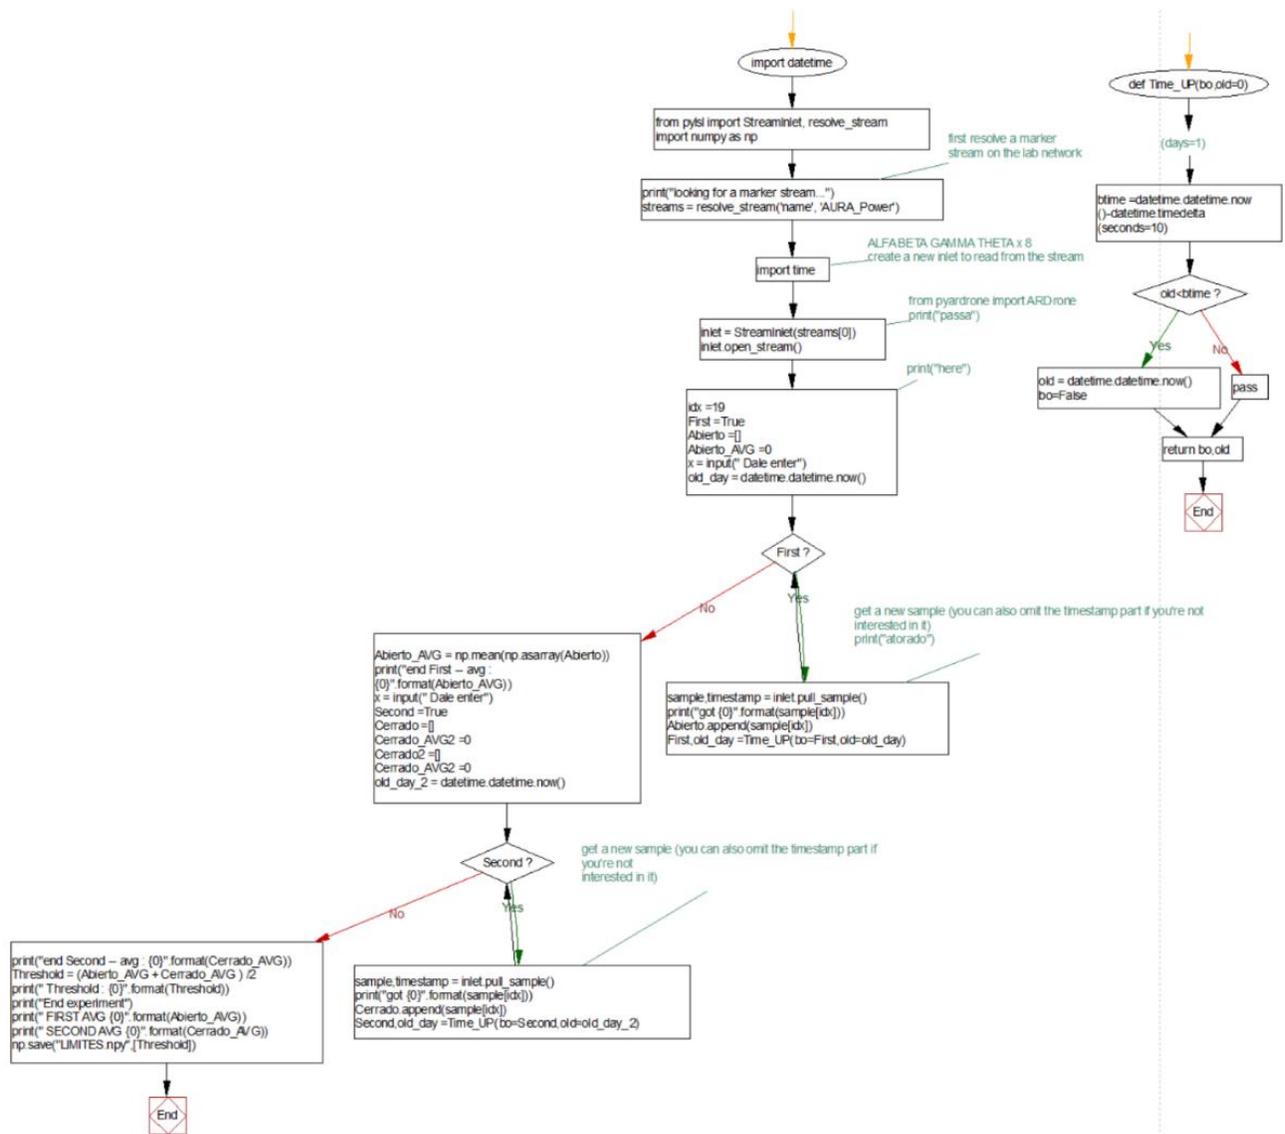


Figura 33. Diagrama de Flujo para el Código Aura. Fuente: Autor.

○ **LSL\_write (Algoritmo2):**

El script de Python (Anexo 3) simula datos de señales EEG y los transmite a través de un sistema LSL (Lab Streaming Layer). Está diseñado para imitar un flujo de datos procedente de un dispositivo OpenBCI, que es una plataforma de hardware y software de código abierto para la interfaz cerebro-computadora (BCI).

- **Importaciones:** Importa los módulos necesarios para su funcionamiento, incluyendo time, argparse, struct para trabajar con datos binarios, y pylsl para interactuar con el Lab Streaming Layer.
- **Configuración Inicial:** Define algunas constantes como la frecuencia de muestreo (freq), caracteres de fin de transmisión (EOT), configuración predeterminada del canal BCI (BCIsettings), y cabeceras y pies de página para mensajes OpenBCI (header y footer).
- **Configuración de LSL:** Se crea un StreamInfo para definir las características del flujo de datos (nombre, tipo, número de canales, frecuencia y el tipo de dato). Luego, se definen los metadatos de los canales y se crea un StreamOutlet para enviar datos.
- **Función synthesizeData:** Esta función genera datos sintéticos para cada canal, con diferentes tipos de señales en cada uno de los primeros cuatro canales:
  - El primer canal tiene una escala de amplitud más alta.
  - El segundo canal tiene una onda senoidal de 10 Hz.
  - El tercer canal tiene interferencia de 50 Hz.
  - El cuarto canal tiene interferencia de 60 Hz.
  - Los demás canales tienen un valor de 0.
- **Función main:** En el bucle infinito, esta función llama a synthesizeData para generar los datos, los empaqueta en bytes y los envía a través del StreamOutlet de LSL. La frecuencia de transmisión se mantiene en 250 Hz mediante un control de tiempo. Si se habilita la opción de registro (log), imprime los valores de los canales.
- **Argumentos de la línea de comandos:** Permite activar los registros (log) mediante un argumento en la línea de comandos.
- **Ejecución del script:** Si el script se ejecuta como el archivo principal, se configuran los argumentos de la línea de comandos y se llama a la función main.

El propósito de este script es proporcionar un mecanismo para desarrollar y probar aplicaciones EEG sin necesidad de hardware real, generando datos sintéticos que imitan las señales que se podrían obtener de un dispositivo EEG. Este tipo de herramientas son útiles para el desarrollo de software y algoritmos de procesamiento de señales, así como

para la formación y educación en el ámbito de las interfaces cerebro-computadora en la Figura 34 se ve el diagrama de flujo correspondiente al código LSL\_write.

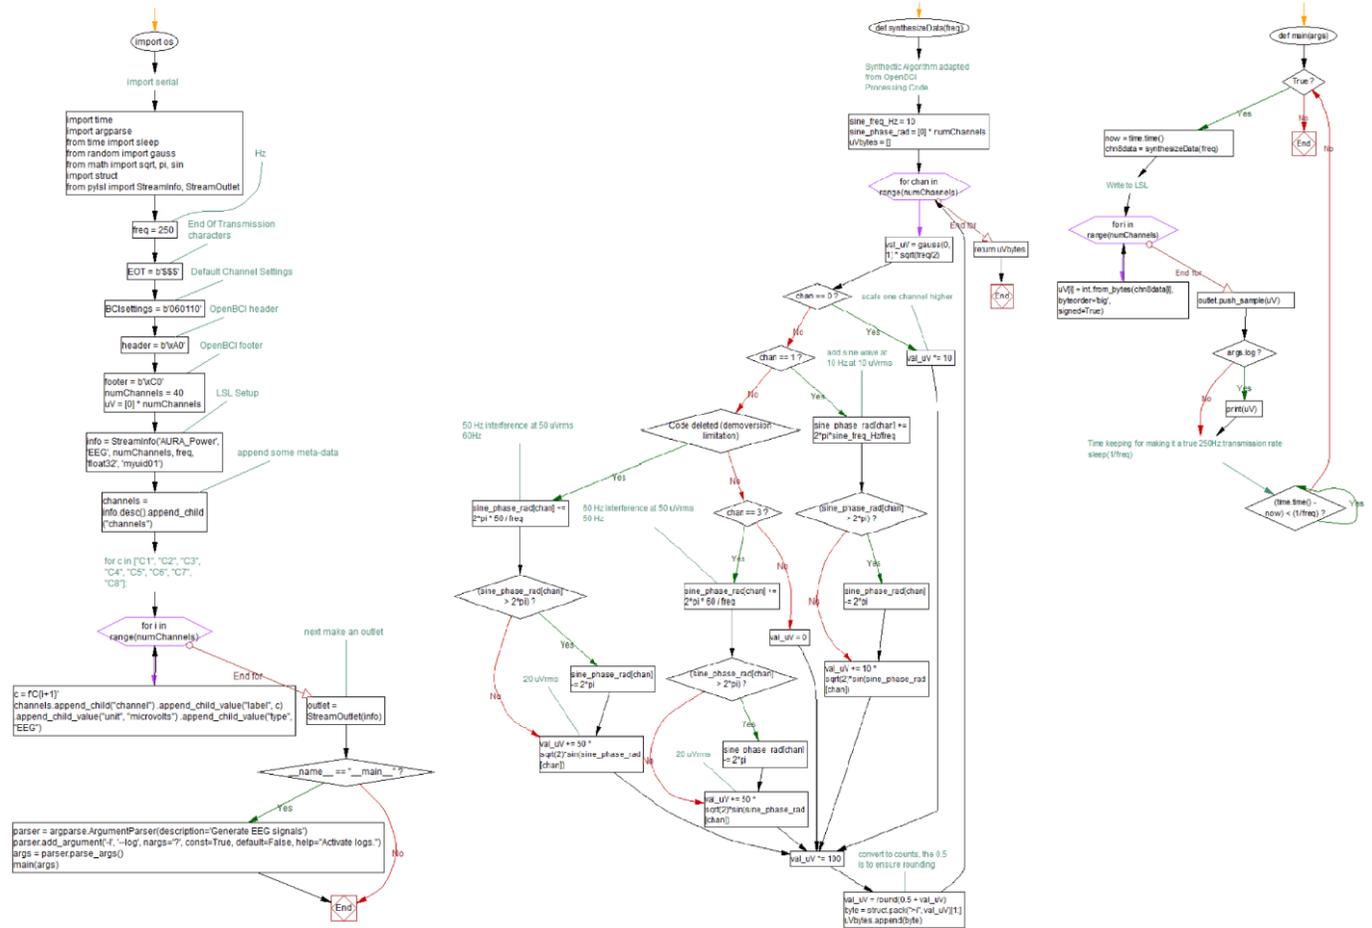


Figura 34. Diagrama de Flujo para el Código LSL\_write. Fuente: Autor.

○ **Iterative\_Get\_Data (Algoritmo3):**

El código en Python (Anexo 4) realiza una serie de pasos para procesar datos de electroencefalograma (EEG), específicamente para obtener información sobre la potencia de las ondas alfa en dos canales (C3 y C4) bajo distintas condiciones o tareas (descanso, movimiento de mano derecha, movimiento de mano izquierda) el diagrama de flujo de este algoritmo se puede ver en la Figura 35.

- **Función Get\_Alpha\_C3\_C4(directory\_name):**
  - Obtiene una lista de todos los directorios dentro del nombre de directorio proporcionado (directory\_name).
  - Inicializa una lista vacía llamada Trials para almacenar los datos de los ensayos.
  - Recorre cada subdirectorio encontrado para buscar archivos que contengan "FFT" en su nombre, lo que indica que son archivos con datos de la transformada rápida de Fourier (FFT).
  - Carga los datos de estos archivos utilizando np.loadtxt, asumiendo que están en formato CSV y los datos son cadenas de caracteres.
  - Extrae la potencia alfa de los canales C3 y C4 a partir de las columnas 18 y 22 del array de datos, respectivamente, desde la cuarta fila en adelante (ignorando las primeras tres filas).
  - Convierte estos datos en un array de NumPy y los añade a la lista Trials.
- **Función Average(lst):**
  - Calcula el promedio de una lista de valores numéricos que están en formato cadena de texto, convirtiéndolos a flotantes y sumándolos.
- **Función Get\_Trial\_Avg(Trials):**
  - Recorre cada ensayo en la lista Trials, calculando el promedio de la potencia alfa para los canales C3 y C4 utilizando la función Average.
  - Almacena los promedios en una nueva lista llamada Trial\_Avg.
- **Ejecución principal del script:**
  - Define las rutas de los directorios para las condiciones de "descanso" (rest), "derecha" (right) y "izquierda" (left).
  - Obtiene los datos de las pruebas para las condiciones "derecha" y "izquierda" usando la función Get\_Alpha\_C3\_C4.
  - Imprime en la consola las cabeceras "---Right---" y "---Left---" para claridad en la salida.
  - Calcula y almacena los promedios de potencia alfa para cada ensayo y condición usando Get\_Trial\_Avg.
  - Convierte las listas de promedios en arrays de NumPy para facilitar su manejo.

- Realiza una prueba t de Student independiente entre los valores de potencia alfa del canal C3 para las condiciones "derecha" y "izquierda" usando stats.ttest\_ind.
- Utiliza Matplotlib para graficar los valores promedio de potencia alfa del canal C3 para las condiciones "derecha" y "izquierda".

- **Graficación y salida:**

- Muestra el gráfico de los valores promedio de la potencia alfa del canal C3 para todas las pruebas en ambas condiciones.
- Finaliza el script imprimiendo "finished" para indicar que se ha completado la ejecución.

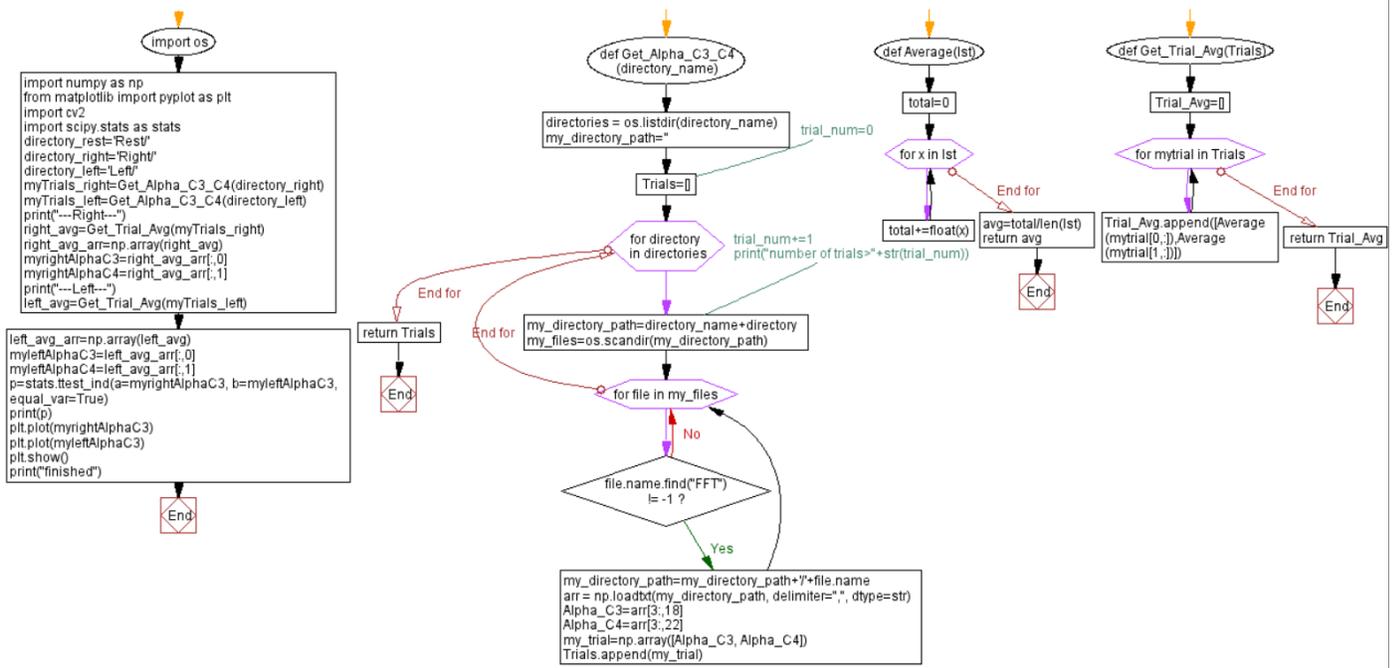


Figura 35. Diagrama de Flujo para el Código Iterative\_Get\_Data. Fuente: Autor.

o **Calibration (Algoritmo4):**

Este script de Python (Anexo 5) realiza un análisis de datos de EEG, específicamente la potencia de las ondas alfa en dos canales (C3 y C4), bajo diferentes condiciones (mano derecha y mano izquierda). Además, calcula líneas de umbral y guarda una de ellas en un archivo CSV, su diagrama de flujo se puede ver en la Figura 36.

- **Importación de módulos:**
  - os: para interactuar con el sistema operativo.
  - numpy: para cálculos numéricos y manejo de arrays.
  - pyplot de matplotlib: para la visualización de datos.
  - cv2: para operaciones de visión por computadora
  - stats de scipy: para cálculos estadísticos.
  - csv: para leer y escribir archivos en formato CSV.
- **Variables de configuración:**
  - samples\_per\_sec: número de muestras por segundo.
  - seconds: número de segundos que se consideran para el análisis.
  - datapoints: cálculo del número total de puntos de datos a analizar.
- **Función Get\_Alpha\_C3\_C4(directory\_name):**
  - Lista todos los directorios dentro del directory\_name proporcionado.
  - Inicializa una lista vacía Trials para almacenar datos de los ensayos.
  - Busca archivos con "FFT" en el nombre dentro de cada subdirectorio y carga sus datos.
  - Extrae la potencia alfa de los canales C3 y C4, limitando las filas a la cantidad de datapoints definida.
  - Añade los datos de potencia alfa para C3 y C4 a la lista Trials.
- **Función Average(lst):**
  - Calcula el promedio de una lista de números en formato de cadena.
- **Función Get\_Trial\_Avg(Trials):**
  - Calcula el promedio de potencia alfa para los canales C3 y C4 para cada ensayo en Trials.
- **Ejecución principal del script:**
  - Define directorios para las condiciones de descanso, movimiento a la derecha y movimiento a la izquierda.
  - Obtiene y calcula los promedios de potencia alfa para los ensayos de movimiento a la derecha e izquierda.
  - Imprime los promedios para cada condición.

- Realiza una prueba t de Student para comparar las potencias alfa de C3 entre las condiciones derecha e izquierda.
- Imprime los resultados de la prueba t.
- **Cálculo de umbrales y Graficación:**
  - Calcula un umbral superior e inferior basado en los promedios de potencia alfa para cada mano.
  - Calcula un umbral medio entre los dos umbrales anteriores.
  - Grafica las potencias alfa y las líneas de umbral.
- **Guardado del umbral medio en un archivo CSV:**
  - Abre (y crea si no existe) un archivo llamado 'decision\_line.csv'.
  - Escribe el valor del umbral medio en el archivo.
  - Cierra el archivo.
- **Muestra el gráfico y finaliza:**
  - Muestra el gráfico con las potencias alfa y las líneas de umbral.
  - Imprime "finished" para indicar que el script ha terminado.

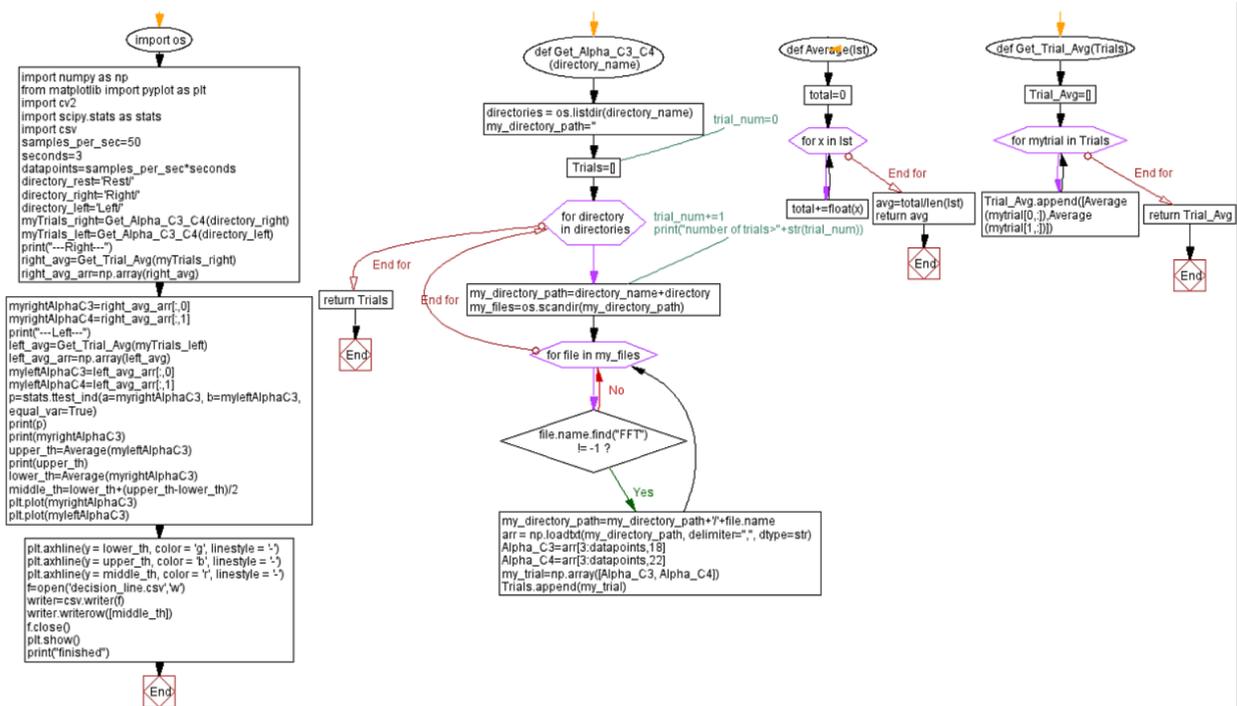


Figura 36. Diagrama de Flujo para el Código Calibration. Fuente: Autor.

- **VRehab\_2 (Algoritmo5):**

Este código (Anexo 6) sirve para interactuar con una secuencia de datos EEG en tiempo real, realizar una calibración y luego usar un modelo de regresión logística para determinar la intención de movimiento, su diagrama de flujo se puede ver en la Figura 37.

- **Importación de módulos:**

- pylsl: para interactuar con una secuencia de datos EEG (EEG stream) utilizando el protocolo LSL (Lab Streaming Layer).
- numpy y pandas: para cálculos numéricos y manejo de datos.
- pickle: para serializar y des serializar objetos en Python.
- serial: para comunicación serial con dispositivos externos, como un Arduino.
- time: para funciones relacionadas con el tiempo.
- goto: para permitir saltos en el flujo de control del programa (similar a GOTO en otros lenguajes).
- sklearn: para preprocesamiento de datos, división de conjuntos de datos, construcción de un modelo de regresión logística y cálculo de precisión de un modelo.

- **Configuración del Arduino:**

- Se establece una conexión serial con el Arduino en el puerto 'COM8' con una tasa de baudios de 38400 y un timeout de 0.1 segundos.

- **Configuración de la secuencia de datos EEG:**

- Se busca una secuencia LSL con el nombre "AURA\_Power" y se crea un StreamInlet.

- **Definición de funciones:**

- write\_read(x): envía un comando a través del puerto serie al Arduino y lee la respuesta.
- conteo(): cuenta regresivamente de 4 a 0 en intervalos de 1 segundo, utilizado para dar al usuario tiempo de preparación.

- **Función calibration():**

- Esta función utiliza un etiquetado proporcionado por with\_goto para controlar el flujo del programa.

- Se recopilan datos de EEG durante un período de descanso y un período de movimiento intencional, cada uno durante 30 segundos, y se les asignan etiquetas 0 y 1 respectivamente.
  - Luego se concatena y guarda esta información en un archivo CSV.
  - Se preprocesan los datos con StandardScaler y se dividen en conjuntos de entrenamiento y prueba.
  - Se entrena un modelo de regresión logística con los datos de entrenamiento.
  - Se evalúa la precisión del modelo con los datos de prueba y se imprime esta precisión.
- **Control del flujo del programa:**
- Después de entrenar y evaluar el modelo, el programa pregunta al usuario si desea continuar con el control o reiniciar el entrenamiento.
  - Si el usuario elige continuar, el programa entra en un bucle infinito donde monitorea la intención de movimiento y envía comandos al Arduino si detecta dicha intención.
  - Si el usuario elige reiniciar, el programa vuelve al inicio del entrenamiento.



Tras detallar el funcionamiento de cómo cada uno de los cinco algoritmos contribuye al funcionamiento general del sistema, se procede a ofrecer una ilustración práctica de estos conceptos. En la Figura 38, se muestra una captura de pantalla que permite observar cómo los datos se manifiestan visualmente en una terminal de Python tras el proceso de captura y preprocesamiento. Esta visualización es crucial, ya que proporciona una ventana al modo en que los datos son interpretados y manejados en tiempo real.

Posteriormente, una vez que los datos han sido debidamente procesados por el sistema de aprendizaje automático propuesto, se lleva a cabo el entrenamiento de la inteligencia artificial. Este entrenamiento es un paso fundamental que permite al modelo aprender de los datos y mejorar su capacidad para realizar predicciones o clasificaciones precisas. Tras completar esta etapa de entrenamiento, el sistema genera una métrica de rendimiento clave: el valor de exactitud, o 'Accuracy', que en este caso alcanza un 53.48%.

Además, este nivel de exactitud, dentro del contexto del ciclo de vida actual del proyecto, sugiere que se ha conseguido un balance adecuado en la modelación, ya que no se manifiestan indicios de 'underfitting', una condición donde un modelo es demasiado simple para capturar la complejidad de los datos y, por lo tanto, no aprende suficientemente de ellos ni de 'overfitting', que ocurre cuando un modelo se ajusta excesivamente a los datos de entrenamiento, perdiendo la capacidad de generalizar y actuar de manera precisa frente a nuevos datos no vistos previamente. La ausencia de estos problemas indica que el modelo tiene una base sólida sobre la cual se puede construir y mejorar, lo que es un signo positivo para las fases subsiguientes de investigación y desarrollo del proyecto.

```

[-50.0, -35.0, 35.0, 24.0, -74.0, -23.0, -43.16666793823242, -43.83333206176758]
[-50.0, -35.0, 35.0, 24.0, -46.0, -23.0, -43.16666793823242, -43.83333206176758]
[-50.0, -35.0, 35.0, 24.0, -46.0, 2.0, -1.5, -43.83333206176758]
[22.0, 23.0, 35.0, 24.0, -46.0, 2.0, -1.5, -12.333333015441895]
[22.0, 23.0, 44.0, 24.0, -46.0, 2.0, -1.5, -12.333333015441895]
[7.0, 13.0, 56.0, -2.0, -14.0, -25.0, -2.6666667461395264, -1.5]
[-5.0, -4.0, 40.0, -11.0, -20.0, -15.0, -19.16666603088379, -2.6666667461395264]
[16.0, -10.0, 18.0, 4.0, -20.0, -18.0, 2.0, -19.16666603088379]
[-20.0, 8.0, 12.0, 2.0, -6.0, -13.0, 5.5, 2.0]
[-24.0, 31.0, -6.0, -21.0, -3.0, 0.0, 10.333333015441895, 5.5]
[2.0, -1.0, 9.0, -1.0, -26.0, -1.0, 12.166666984558105, 10.333333015441895]
[13.0, 30.0, 5.0, -12.0, -22.0, -24.0, 3.1666667461395264, 12.166666984558105]
[27.0, 16.0, 13.0, -24.0, -26.0, -4.0, -12.333333015441895, 3.1666667461395264]
END OF TRAINING
AI TRAINING INIT
AI TRAINING END
AI ACCURACY (%): 53.47836480994501

```

Figura 38. Preprocesamiento y Entrenamiento del Modelo de Aprendizaje Automático. Fuente: Autor.

### 7.3.3 FASE 4 Desarrollo de Retroalimentación Háptica

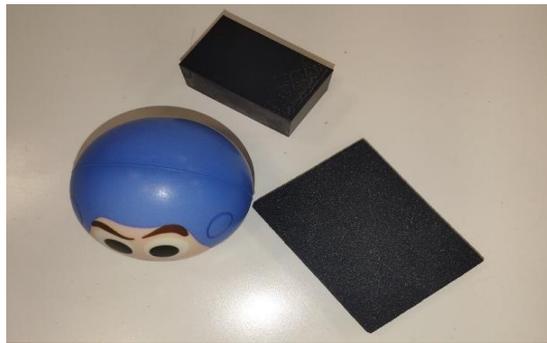
#### ▪ Selección de Objetos para Pruebas de Dureza

Para evaluar de manera efectiva la precisión y la utilidad del sistema de retroalimentación háptica, se ha llevado a cabo una selección cuidadosa de objetos que varían en su grado de dureza, tal como se ilustra en la Figura 39,. La elección incluye:

- **Pelota de espuma:** Este objeto es notablemente blando y comprimible, presentando el menor nivel de resistencia al ser apretado. Su estructura porosa y su flexibilidad hacen que sea un excelente candidato para probar la sensibilidad del sistema a cambios sutiles en la presión y para verificar que la retroalimentación háptica sea capaz de transmitir la sensación de suavidad y deformación.
- **Bloque de PLA (ácido poli láctico):** El PLA es un plástico biodegradable que es más rígido y resistente que la espuma. Un bloque de este material simula un objeto con un nivel intermedio de dureza. Es sólido, pero no tan duro como otros plásticos, lo cual permite al sistema demostrar su capacidad para discriminar entre grados moderados de fuerza aplicada y reflejar esta diferencia a través de la retroalimentación táctil.
- **Bloque de TPU (poliuretano termoplástico):** El TPU es un material que combina la alta elasticidad del caucho con la resistencia y durabilidad de los plásticos. Aunque es

flexible, presenta un nivel más alto de dureza en comparación con los objetos anteriores. Su inclusión en las pruebas es crucial para determinar si el sistema puede proporcionar una retroalimentación adecuada cuando se interactúa con materiales que ofrecen una resistencia considerable pero que aún tienen cierta capacidad de absorber impactos y de ser ligeramente deformables.

El conjunto de estos objetos permite realizar pruebas exhaustivas sobre la gama de sensaciones que el sistema de retroalimentación háptica debe ser capaz de discernir y transmitir al usuario.



*Figura 39. selección de objetos con diferentes durezas. Fuente: Autor.*

- **Codificación en Arduino para Adquisición de Datos y Control de Actuadores**

Se ha realizado la programación en Arduino para recolectar datos del sensor piezoeléctrico (Anexo 7) El funcionamiento del código en Arduino se describirá mediante el siguiente diagrama de flujo, véase Figura 40.

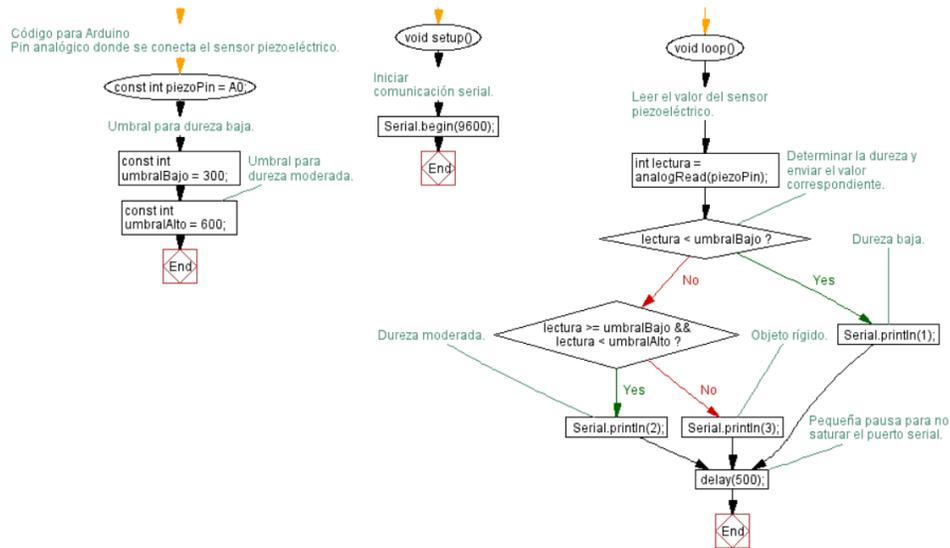


Figura 40. Diagrama de Flujo del Algoritmo en Arduino para la lectura del sensor piezoeléctrico. Fuente: Autor.

Ahora, el funcionamiento del código (Anexo 8) para el M5 Stack se describirá mediante el siguiente diagrama de flujo, véase Figura 41.

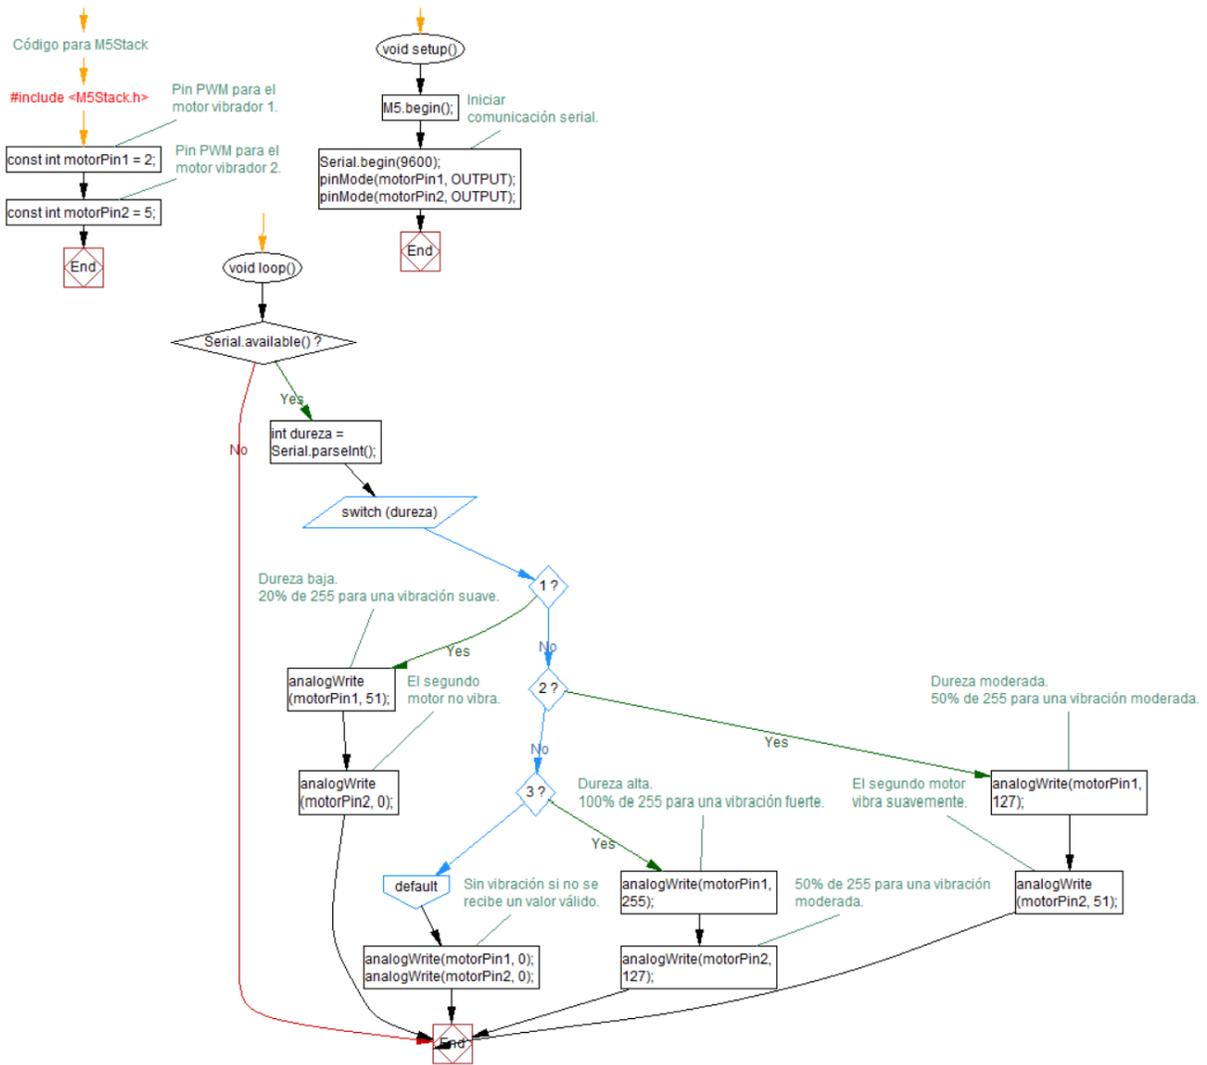


Figura 41. Diagrama de Flujo del Algoritmo para el M5 Stack que gestiona el pwm de los motores de vibración.  
Fuente: Autor.

▪ **Pruebas de Laboratorio de la Respuesta del Actuador Vibrador**

Para esta etapa se realizó la experimentación en un entorno controlado, para validar la respuesta del motor vibrador en correlación con los datos captados por el sensor piezoeléctrico.

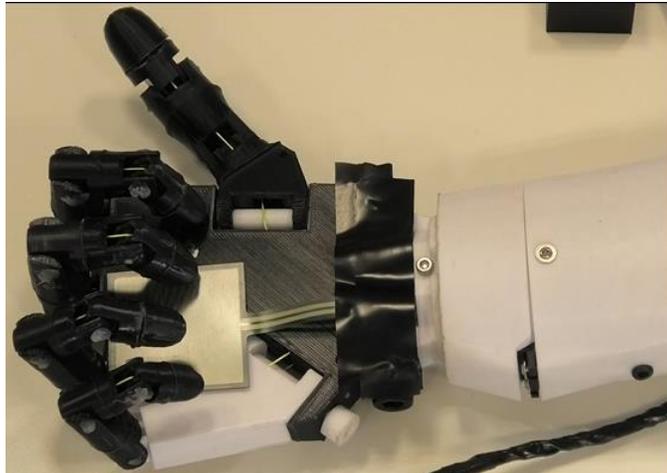


Figura 42. Integración de sensor piezoeléctrico RP-S40-ST de Alta Precisión a mano mecánica. Fuente: Autor.

Como se observa en la Figura 42 se coloca el sensor piezoeléctrico o galga extensiométrica RP-S40-ST, en la palma de la mano mecánica para que, al momento de realizar el agarre de los objetos, esta ejerza una presión y haga que su resistencia cambie por medio de la fuerza aplicada.

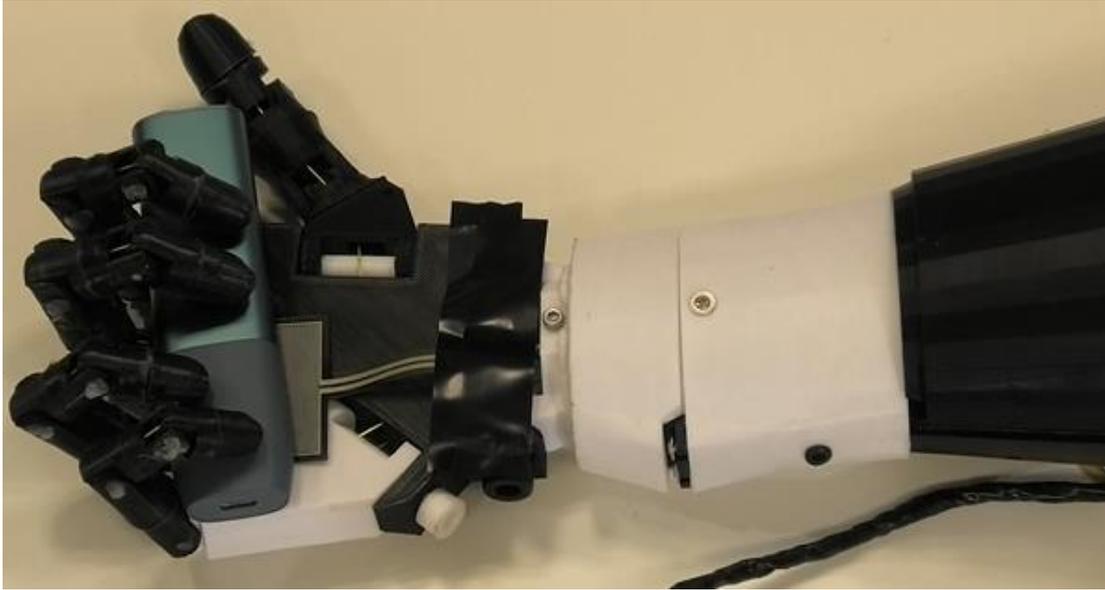


Figura 43. Micromotor de vibración 1030 DC utilizados en el sistema de retroalimentación. Fuente: Autor.

Al mismo tiempo, se hace una elección de los micromotores de vibración 1030 DC (Figura 43), para incorporarlos en el sistema de retroalimentación y controlar su intensidad por medio de pulsos PWM, de acuerdo con la señal emitida por sensor piezoeléctrico.

- ***Integración del Sensor Piezoeléctrico al Prototipo de Mano Robótica***

En esta etapa se realiza la incorporación y ajuste del sensor piezoeléctrico dentro de la mano robótica para la detección de contacto y presión.

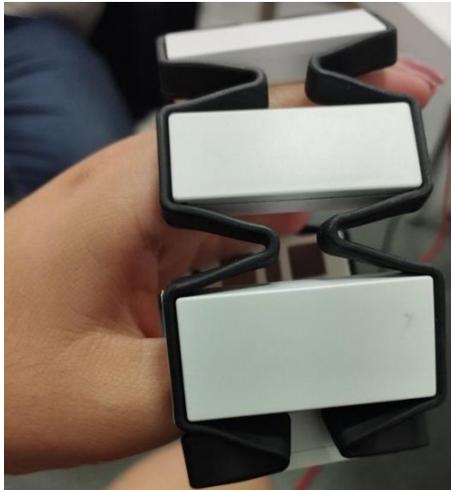


*Figura 44. Pruebas de sujeción de objeto y captación de señal a partir del sensor piezoeléctrico. Fuente: Autor.*

Como se puede observar en la Figura 44 se puede verificar inicialmente la sujeción de un objeto por parte de la mano robótica y a su vez la incorporación del sensor RP-S40-ST, esta integración permitirá hacer una clasificación de las tres intensidades correspondientes a los tres objetos seleccionados.

- ***Construcción del Prototipo de Brazaletes para Retroalimentación Háptica***

En esta etapa se realiza la fabricación del diseño presentado en la Figura 26, la cual corresponde al de muñeca que proporcionará feedback háptico al usuario y en cuyo interior estarían presentes los micromotores vibradores de la Figura 43.



*Figura 45. Construcción de sistema de realimentación a partir de ingeniería inversa del brazalete MYO, adaptándolo a los requerimientos del proyecto. Fuente: Autor.*

En la Figura 45 se presenta el resultado de la construcción física del brazalete modelado en CAD y como se mencionó anteriormente, incorporando los micromotores vibradores. Para lograr la construcción de este sistema se emplearon dos tipos de filamento de impresión 3D, uno rígido y otro flexible lo cual permite una correcta adaptación a los diferentes diámetros de antebrazo de los pacientes o usuarios.

#### **7.4 INTEGRACIÓN DEL SISTEMA**

Subiendo la pendiente derecha de la metodología V, se encaran las etapas esenciales de validación y verificación. Esta fase es el corazón de la confirmación de que el diseño propuesto se ha materializado en un sistema que no solo está completo, sino que también cumple con todas las expectativas y requisitos. Aquí, los componentes individuales previamente desarrollados, codificados y ensamblados son rigurosamente probados y ensamblados en el sistema mecatrónico completo. Esto incluye la ejecución de pruebas de integración sistemática, las cuales aseguran que el sistema de control robótico y la retroalimentación háptica operan en concierto, y las pruebas de validación y aceptación, que confirmarán que la solución es robusta y confiable. Esto constituye la Fase 5 de 5 fases o etapas del desarrollo de esta metodología.

#### 7.4.1 FASE 5 Integración y Pruebas del Sistema

- **Integración del Sistema AURA con la Mano Robótica y el Feedback Háptico**

A continuación se ofrece una representación visual de cómo se ha adaptado y sincronizado todo el sistema, incluyendo la combinación del sistema AURA, la mano robótica y el sistema de retroalimentación háptica.

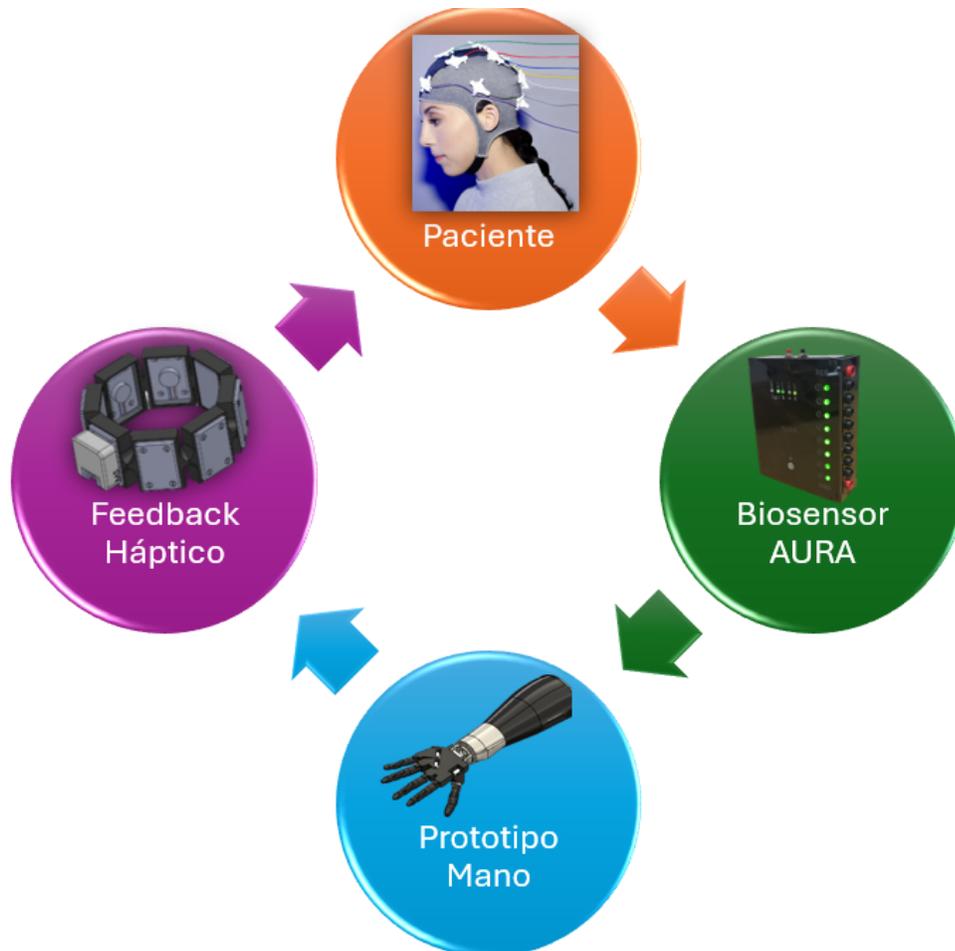


Figura 46. Integración del Sistema. Fuente: Autor.

Se ilustra de manera gráfica la integración del sistema que consta de cuatro etapas de proceso, como se puede observar en la Figura 46, las etapas conforman un ciclo de trabajo en el cual la salida de cada una de estas representa la entrada de la etapa siguiente, de esta manera se garantiza un adecuado flujo de trabajo, lo cual permite un

bucle cerrado de información, control y retroalimentación óptimo. A continuación, se describen cada una de las etapas de este proceso.

La primera etapa implica la preparación del paciente o usuario para emitir una señal de encefalografía por medio de los sensores EEG ubicados en el cuero cabelludo, en puntos estándar tal como se nombran en la Figura 5. Además, uno en el lóbulo de la oreja que actúa como referencia o “tierra”, añadiendo un gel conductor a todos los electrodos, esto con el fin de mejorar la adquisición de las señales cerebrales.

Una vez se prepara y equipa al paciente con todos los sensores, se procede a la segunda etapa, la captación de señales por medio del sensor de Aura. Se invita al usuario que entre en un estado de relajación con la mano cerrada y luego a concentrarse en la acción de abrir la mano tanto físicamente como solo pensando en ello, traduciendo y tratando la señal mediante etapas de amplificación, dado que las señales EEG son señales de voltaje muy pequeños y una etapa de filtrado para eliminar el ruido que haya afectado a la toma de datos. Las señales EEG son configuradas en el software AURA de acuerdo a el área que se quiera captar; en este caso el área central del cerebro responsable de la intención de movimiento.

Mediante un modelo de aprendizaje automático (machine learning) se determina si el usuario piensa en abrir o cerrar la mano. Esta decisión se envía al microcontrolador dando inicio a la tercera etapa.

En la tercera etapa se genera una variable de control que ajusta los servomotores de la mano robótica para que giren a la posición correspondiente ya sea para abrir o cerrar la mano. Además, por medio de un sensor de presión se emite una intensidad de fuerza variable que se capta cuando la mano se cierra y tiene un objeto en sujeción. Una vez la mano se cierra y agarra el objeto (o simplemente cierra la mano), envía esa señal de intensidad de presión al microcontrolador M5 dando paso a ejecutarse la cuarta etapa.

La cuarta etapa consiste en la interpretación de la señal analógica del sensor de presión que se clasifica en tres rangos de intensidad: Baja, Media y Alta. En función de la intensidad se controla la vibración de dos micromotores situados en un brazalete de retroalimentación, que incluye un microcontrolador M5 stack. La señal de salida de pulsos

(PWM) varía según la intensidad: para una presión baja, un micromotor vibra al 20% de su capacidad y el otro permanece inmóvil; para una presión media, uno vibra al 50% y el otro al 20%; si la intensidad es alta, se mantienen las vibraciones al 100% y al 50% respectivamente. En el modo 'Default', si no se detecta ninguna intensidad, los motores no vibran y el PWM es 0. Finalmente, la respuesta táctil recibida por el usuario a través del brazalete completa la cuarta etapa y permite reiniciar el proceso con una nueva captación de señales.

▪ ***Pruebas de Funcionamiento y Validación del Sistema Integrado***

Para identificar posibles problemas de integración, se realizan pruebas exhaustivas del sistema completo. Tras verificar el correcto funcionamiento, se procede a la fase de experimentación con un grupo de 20 usuarios, con el propósito de validar el prototipo.

Las pruebas se estructuran en tres etapas diferenciadas para cada usuario, con los siguientes objetivos:

1. **Calibración del Sistema:** Asegurar que la interfaz de control responde adecuadamente a las señales del usuario y que el sistema establece los umbrales correctos para una operación precisa.
2. **Operación y Control:** Evaluar la capacidad del usuario para manipular la mano robótica, incluyendo la apertura y cierre precisos, así como la manipulación de objetos.
3. **Retroalimentación Háptica:** Comprobar la efectividad del feedback táctil, permitiendo al usuario identificar diferencias en la textura y dureza de los objetos manipulados.

A través de estas pruebas, se busca recopilar datos que reflejen la precisión en el control y la calidad de la retroalimentación háptica, elementos clave para la funcionalidad y utilidad del sistema en aplicaciones reales.

A continuación, se explica detalladamente los tres objetivos denominados “tiempos”.

1. **Primer tiempo:** En la primera fase, se lleva a cabo una calibración del sistema utilizando las señales EEG del usuario controlando la apertura de la mano por 30

segundos como se observa en la Figura 47. Este proceso permite al modelo de aprendizaje automático determinar un umbral para clasificar los datos adquiridos y proporcionar señales de control para la apertura y cierre de la mano robótica. De esta forma, se logra identificar la intención de movimiento del usuario, lo que mejora la precisión en la toma de decisiones durante la fase de control. Con el control del usuario claramente establecido, se procede a la segunda etapa, centrada en el reconocimiento de tres durezas diferentes lo cual se explica a continuación.

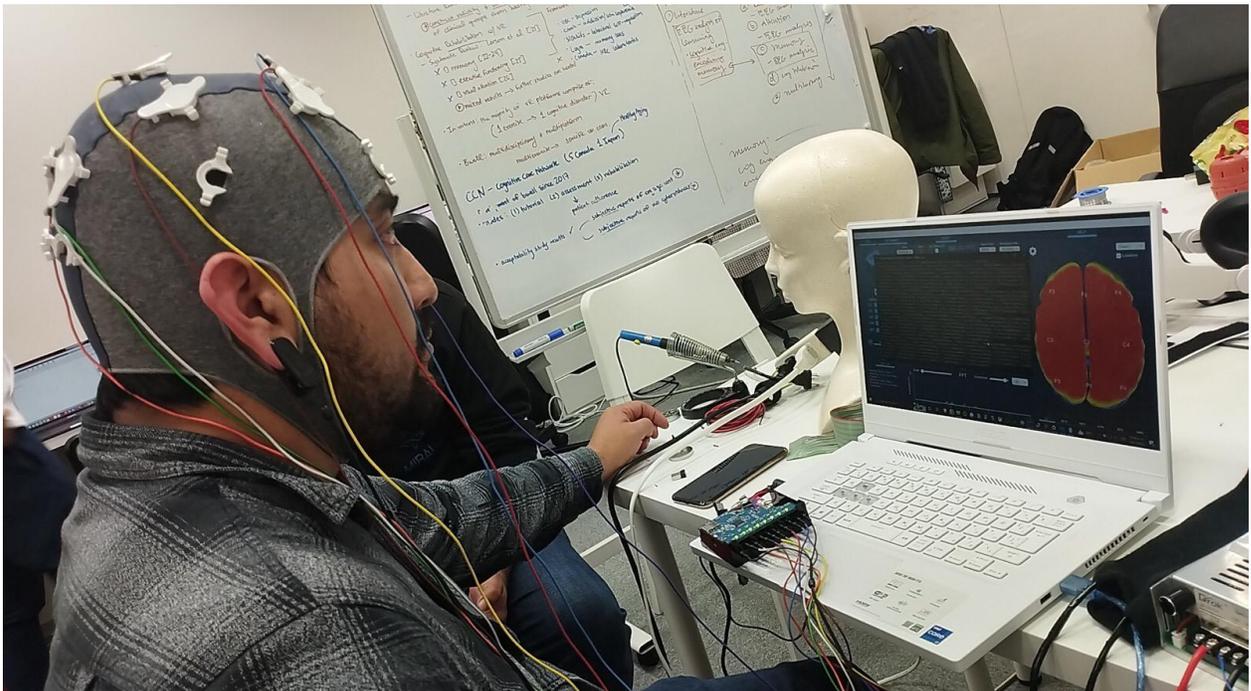


Figura 47. Pruebas del primer tiempo. Fuente: Autor.

2. **Segundo tiempo:** Durante la segunda etapa, el usuario manipula la mano robótica tres veces. Antes de que se cierre, se coloca uno de los objetos elegidos, pasando por tres niveles de dureza que van desde la más baja hasta la más alta como se puede observar en la Figura 48. De esta manera, el usuario puede distinguir la retroalimentación táctil que le proporciona el brazalete en respuesta a cada nivel de presión ejercida por la mano robótica. Una vez el usuario diferencie las tres intensidades de presión y las perciba por medio del brazalete, se pasa a un test dando paso a la etapa final.



*Figura 48. Pruebas del segundo tiempo. Fuente: Autor.*

3. **Tercer tiempo:** En la etapa final, se realiza una prueba con el usuario al que se le vendan los ojos ver Figura 49. Se le pide que cierre la mano robótica tres veces, pero esta vez con los objetos presentados en un orden diferente. Después de cada intento, se solicita al usuario que indique en qué momento sintió el objeto más suave, el de dureza intermedia y finalmente el de alta dureza.



*Figura 49. Momento de experimentación Tipo Test o tercer tiempo. Fuente: Autor.*

▪ **Análisis de Resultados Preliminares**

Antes de realizar cualquier ajuste al sistema, es crucial comprender su estado actual y rendimiento inicial. La recopilación de datos iniciales proporciona una base desde la cual se pueden identificar áreas de mejora y determinar la necesidad de ajustes. Los datos a continuación son fundamentales para permitir una evaluación objetiva de la funcionalidad del sistema y su efectividad en cumplir los objetivos propuestos.

*Tabla II. Primeros resultados de experimentación. Fuente: Autor.*

Usuario	1er tiempo: Calibración	2do tiempo: Reconocimiento de dureza		
		Suave	Medio	Alto
1	Exitoso	si	si	si
2	Exitoso	si	si	si
3	Exitoso	no	si	no
4	Exitoso	si	si	si
5	Exitoso	si	si	si
6	Exitoso	si	no	no
7	Exitoso	si	si	no
8	Exitoso	si	si	no
9	Exitoso	no	no	si
10	Exitoso	si	si	si
11	Exitoso	no	si	no
12	Exitoso	si	si	si
13	Exitoso	si	no	si
14	Exitoso	si	no	si
15	Exitoso	si	si	si
16	Exitoso	si	si	no
17	Exitoso	si	no	si
18	Exitoso	si	no	no
19	Exitoso	no	no	no

20	Exitoso	si	si	no
----	---------	----	----	----

La **¡Error! No se encuentra el origen de la referencia.**Tabla II proporciona datos cruciales que se han utilizado para comprender cómo las personas reconocen diferentes niveles de dureza. Se ha procesado esta información para obtener las frecuencias de respuestas "sí" y "no" cuando los participantes intentaron identificar si un material correspondía a un nivel de dureza suave, medio o alto. Los resultados se presentan en la Tabla III, que se presenta a continuación:

*Tabla III. Total "Si" y "No" pruebas preliminares. Fuente: Autor.*

Nivel de dureza	Suave	Medio	Alto
<b>Total, SI=</b>	20	13	11
<b>Total, NO=</b>	0	7	9

Para ilustrar con mayor claridad, en la categoría "suave", se le pidió a un total de 20 personas que determinaran si percibían esta dureza en una muestra. La totalidad de los participantes, es decir, el 100%, afirmó con confianza que el material era suave. Esto se traduce en una precisión total: cada persona que probó la muestra estuvo de acuerdo en que era suave.

Al pasar al nivel de dureza "medio", de las 20 personas evaluadas, 13 indicaron correctamente que el material tenía una dureza media, mientras que 7 no reconocieron este nivel de dureza. Esto nos da una precisión de reconocimiento del 65% para la dureza media, lo que sugiere que, aunque la mayoría pudo identificar correctamente este nivel, hubo un porcentaje significativo que no lo hizo.

Finalmente, en el nivel de dureza "alto", 11 de los 20 participantes identificaron adecuadamente la alta dureza del material, mientras que 9 no lo hicieron. Aquí, la precisión desciende al 55%, lo que indica que poco más de la mitad de los participantes

fueron capaces de identificar correctamente este grado de dureza, y casi la mitad no pudo.

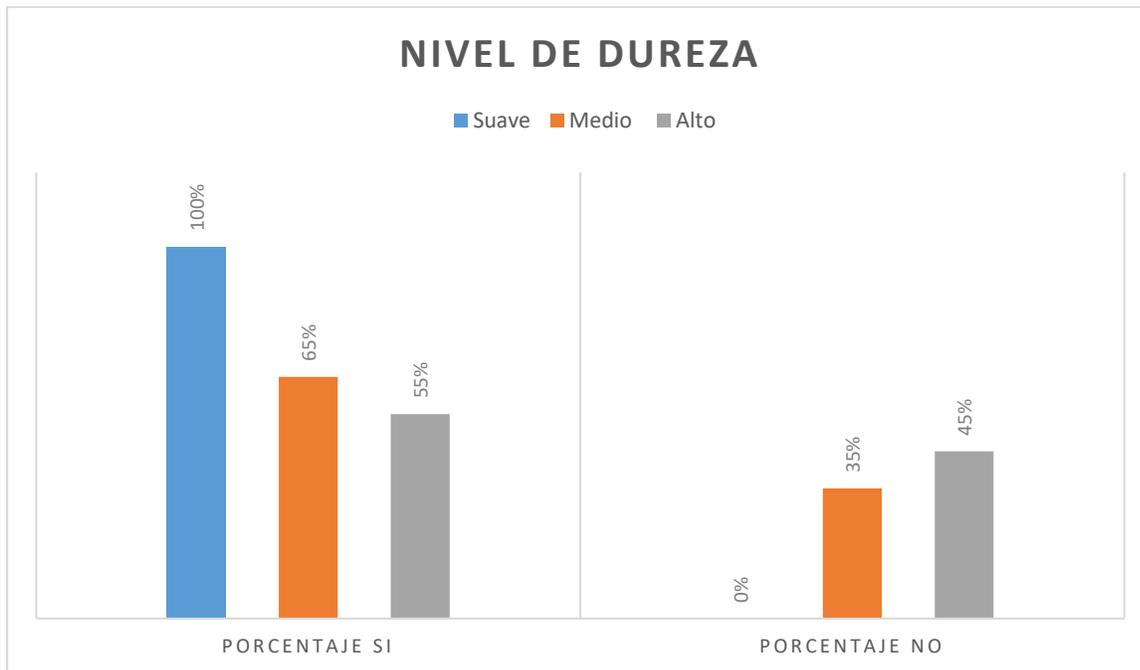


Gráfico 1. Porcentaje nivel de dureza reconocible pruebas preliminares. Fuente: Autor.

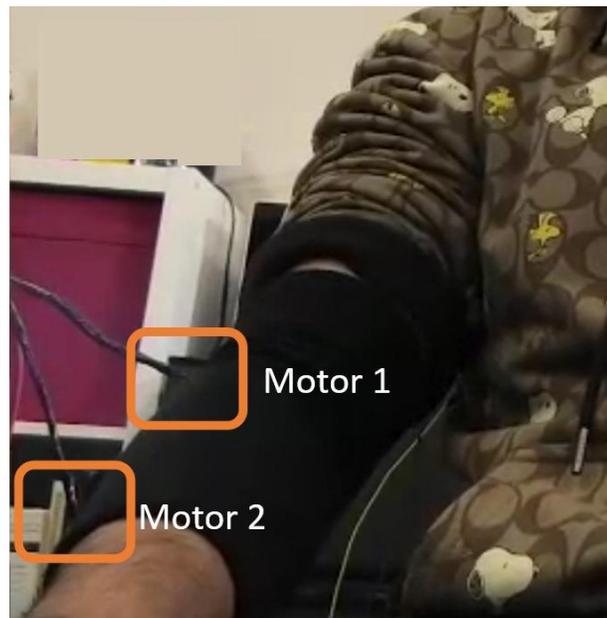
Adicionalmente, el Gráfico 1 pone en perspectiva estos resultados mostrando visualmente los porcentajes de aciertos en la identificación de cada nivel de dureza. Con esta representación gráfica, se observa una tendencia clara: la capacidad de los participantes para reconocer la dureza disminuye a medida que el nivel de dureza aumenta. El nivel "suave" fue identificado sin errores, el nivel "medio" presentó una precisión del 70%, y el reconocimiento del nivel "alto" fue el más desafiante, con una precisión ligeramente superior al 50%.

Estos resultados sugieren que podría existir una correlación entre el nivel de dureza y la dificultad para identificarlo correctamente, siendo los materiales más suaves los más fáciles de reconocer y los más duros los más complicados de identificar para los participantes en este estudio.

- **Realización de Ajustes Basados en los Hallazgos**

Tras la experimentación inicial, se realizaron ajustes claves en el sistema para optimizar su funcionalidad y rendimiento. Los resultados obtenidos de esta primera ronda de pruebas, como se detallan en la Tabla II, muestran que el proceso de calibración es satisfactorio en todas las fases para todos los participantes. No obstante, se reveló una dificultad significativa durante la etapa de reconocimiento de texturas: se registra un 45% de tasa de error en la detección de objetos de alta dureza y un 30% en aquellos de dureza media. Este desafío se presenta debido a que la activación simultánea de ambos micromotores a intensidades iguales o superiores al 50% produce una vibración homogénea en el brazalete, complicando la distinción de texturas.

Para abordar esta problemática, se ha añadido una cubierta de tela al brazalete. Esta modificación es evidente en la Figura 50 y tiene un doble propósito: en primer lugar, actúa como barrera para evitar la dispersión de la vibración a través de todo el brazalete; y en segundo lugar, mejora la focalización de la intensidad vibracional alrededor de los puntos donde se localizan los micromotores en el antebrazo. Este cambio permite una diferenciación más precisa de la intensidad de la vibración, facilitando así el reconocimiento de distintos niveles de dureza por parte del usuario.



*Figura 50. Pruebas del brazalete con una cubierta de tela para mayor percepción de vibración. Fuente: Autor.*

▪ **Análisis de Resultados Finales**

Después de realizar las modificaciones pertinentes al sistema, incluyendo la incorporación de la cubierta de tela en el brazalete, se procedió a repetir las pruebas en las tres etapas establecidas inicialmente. Estas pruebas se llevaron a cabo para verificar que los ajustes realizados habían mejorado la funcionalidad y el rendimiento del sistema, en línea con los objetivos planteados para el proyecto.

Repetición de las Pruebas:

Con el brazalete ahora envuelto en tela, se ejecutaron nuevamente las pruebas en los tres momentos críticos:

- Calibración y Control: Se evaluó la precisión con la que los usuarios podían operar la mano robótica utilizando el sistema de control perfeccionado.
- Reconocimiento de Texturas: Se midió la capacidad de los usuarios para distinguir entre diferentes texturas utilizando el sistema de retroalimentación háptica mejorado.
- ✓ Identificación de Durezas: Se analizó la efectividad de la retroalimentación táctil en la tarea de diferenciar objetos de distinta dureza.

*Tabla IV. Resultados después de ajustes. Fuente: Autor.*

Usuario	1er tiempo: Calibración	2do tiempo: Reconocimiento de dureza			3er tiempo: Test	
		Suave	medio	Alto	Aleatorio	#Intentos
1	Exitoso	si	si	si	Exitoso	1
2	Exitoso	si	si	si	Exitoso	2
3	Exitoso	si	si	si	Exitoso	1
4	Exitoso	si	si	si	Exitoso	1
5	Exitoso	si	si	si	Exitoso	2
6	Exitoso	si	si	si	Exitoso	1
7	Exitoso	si	si	si	Exitoso	1

<b>8</b>	Exitoso	si	si	si	Exitoso	1
<b>9</b>	Exitoso	si	si	si	Exitoso	1
<b>10</b>	Exitoso	si	si	si	Exitoso	1
<b>11</b>	Exitoso	si	si	si	Exitoso	1
<b>12</b>	Exitoso	si	si	si	Exitoso	1
<b>13</b>	Exitoso	si	si	si	Exitoso	1
<b>14</b>	Exitoso	si	si	si	Exitoso	1
<b>15</b>	Exitoso	si	si	si	Exitoso	2
<b>16</b>	Exitoso	si	si	si	Exitoso	1
<b>17</b>	Exitoso	si	si	si	Exitoso	1
<b>18</b>	Exitoso	si	si	si	Exitoso	1
<b>19</b>	Exitoso	si	si	si	Exitoso	1
<b>20</b>	Exitoso	si	si	si	Exitoso	1

En la Tabla IV se evidencia una mejora significativa en la fase de reconocimiento de durezas, alcanzando un rendimiento del 100%. Además, se introduce una tercera etapa de experimentación, en la que, al usuario, con los ojos vendados, se le proporciona retroalimentación táctil mediante el uso de tres objetos de durezas diferentes colocados de manera aleatoria. El usuario debe indicar en cuál de los tres intentos percibió la dureza más baja, la dureza media y la dureza más alta dando como resultado que el 75% de los usuarios prueba del sistema reconocieron satisfactoriamente las durezas frente a un 15% que lograron el objetivo al segundo intento.

Estos resultados indican que las mejoras implementadas han tenido un impacto positivo en la performance del sistema al momento de hacer la segunda experimentación. La cubierta de tela ha sido efectiva en aislar la vibración y en proporcionar una retroalimentación más precisa, lo que ha permitido a los usuarios una identificación más acertada de las diferentes durezas y texturas sin la necesidad de la vista. Con estos resultados, se confirma que la integración del sistema funciona correctamente.



*Figura 51. Validación de los ajustes realizados. Fuente: Autor.*



*Figura 52. Validación del sistema integrado. Fuente: Autor.*

Después de hacer ajustes metodológicos en nuestro procedimiento de prueba, los datos reflejaron cambios significativos en la capacidad de los usuarios para identificar la dureza de los objetos. La Tabla V proporciona una visión clara de la necesidad de realizar un segundo intento para algunos usuarios:

Tabla V. Intentos Realizados por los Usuarios. Fuente: Autor.

<b>Intentos</b>	<b>Usuarios</b>	<b>Porcentaje</b>
<b>Primer Intento:</b>	17	85%
<b>Segundo Intento</b>	3	15%
<b>Total</b>	20	100%

Inicialmente, el 85% de los usuarios (17 de los 20 participantes) identificaron correctamente la dureza de los objetos en su primer intento. Sin embargo, hubo un 15% (equivalente a 3 usuarios) que no lograron reconocer la dureza adecuadamente hasta que se les permitió un segundo intento. Esto subraya que, aunque la mayoría de los usuarios fueron capaces de identificar la dureza de inmediato, una porción menor necesitó una oportunidad adicional para hacerlo de manera correcta.

La Tabla VI presenta una comparación detallada de los resultados obtenidos antes y después de aplicar los ajustes al método experimental:

Tabla VI. Resultados antes y después de ajustes. Fuente: Autor.

	<b>Primer Experimento</b>			<b>Segundo Experimento</b>		
	<b>suave</b>	<b>medio</b>	<b>alto</b>	<b>suave</b>	<b>medio</b>	<b>alto</b>
<b>Si</b>	20	13	11	20	20	20
<b>No</b>	0	7	9	0	0	0
<b>porcentaje éxito</b>	100%	65%	55%	100%	100%	100%

En el primer experimento, la capacidad de los usuarios para reconocer la dureza se vio reflejada en los siguientes porcentajes de éxito: 100% para suave, 65% para medio y 55% para alto. Estos resultados indicaron que, aunque el nivel suave fue identificado sin

errores por todos los participantes, hubo una disminución en la precisión al identificar los niveles medio y alto.

Sin embargo, después de implementar ajustes en el proceso, los resultados del segundo experimento muestran una mejora excepcional, con un porcentaje de éxito del 100% en la identificación de la dureza en cada uno de los tres niveles evaluados. Lo que esto significa es que, tras los ajustes, cada participante pudo determinar con precisión si los objetos eran suaves, de dureza media o alta sin ningún error.

Esta transformación en los resultados evidencia la importancia y el impacto positivo de los ajustes realizados en el protocolo de prueba y en especial el ajuste realizado al sistema de retroalimentación háptico. Con estos cambios, se mejoró la claridad de las sensaciones lo que permitió a todos los usuarios identificar los objetos de manera correcta y confiable, independientemente de su nivel de dureza.

## 8 CONCLUSIONES

---

- ✓ La integración de recursos código abierto (open source) ha sido crucial en el proyecto, permitiendo una rápida creación de conocimiento y una optimización significativa en el desarrollo. Gracias a la accesibilidad y facilidad de programación de los diseños de la mano robótica, se ha podido concentrar esfuerzos en la mejora y personalización de la prótesis, lo cual ha reducido el tiempo de desarrollo e impulsado la innovación.
- ✓ El éxito en la construcción del prototipo físico de la mano robótica marca un punto decisivo, reflejando un diseño mecánico funcional y una programación que permite la correcta interpretación de las señales electroencefalográficas. Este logro subraya la efectividad de la codificación inicial y la viabilidad del diseño mecánico propuesto.
- ✓ Es relevante destacar que la precisión del 53.48% alcanzada, aunque pueda considerarse modesta frente a los estándares de sistemas altamente afinados y maduros, representa un resultado prometedor para un proyecto en su fase inicial de desarrollo y con un carácter distintivamente innovador. Este porcentaje subraya que el modelo está aprendiendo efectivamente y que hay un camino abierto hacia mejoras significativas y optimizaciones futuras. En paralelo, en el ámbito del procesamiento de señales y aprendizaje automático, se ha tenido éxito en la implementación y validación de algoritmos que garantizan la adquisición y calibración precisa de los datos electroencefalográficos. Esta exactitud es crucial para la interpretación correcta de las intenciones de movimiento del usuario por parte de la prótesis, lo cual es un componente esencial para la funcionalidad efectiva del sistema.
- ✓ La mejora en la retroalimentación háptica, como se evidencia en los resultados de dos experimentos, amplifica significativamente la funcionalidad de las prótesis, mejorando así la interacción humano-máquina. En el primer experimento, la efectividad del sistema fue del 100% con un ajuste suave, 65% con ajuste medio y 55% con ajuste alto, mientras que en el segundo experimento, la tasa de éxito fue del 100% en todos

los niveles de ajuste. Estos resultados preliminares sugieren que el sistema no solo proporciona un control intuitivo y una experiencia realista, sino que también es altamente efectivo en diferentes configuraciones de intensidad, lo que es un indicador positivo para su uso en rehabilitación y prótesis de miembros superiores. Estos hallazgos subrayan la importancia de la integración de sistemas sensoriales avanzados en el diseño de prótesis para mejorar la calidad de vida de los usuarios.

- ✓ El desarrollo de este prototipo de prótesis de mano mecatrónica, controlada por señales electroencefalográficas y enriquecida con retroalimentación sensorial háptica, constituye un avance notable en la creación de interfaces avanzadas entre humanos y máquinas. El prototipo es un claro testimonio del éxito en alcanzar el objetivo general y demuestra la factibilidad de proveer una interpretación precisa de las intenciones de movimiento del usuario, así como una respuesta sensorial detallada, lo cual tiene el potencial de mejorar considerablemente la calidad de vida de los usuarios de prótesis de mano.

## 9 TRABAJOS FUTUROS

---

### **Optimización Ergonómica y Funcional del Pulgar:**

- Realizar estudios biomecánicos para comprender mejor los movimientos y fuerzas del pulgar, y colaborar con ergonomistas y terapeutas ocupacionales.
- Experimentar con distintas configuraciones del pulgar para una manipulación más efectiva de objetos.

### **Desarrollo de Materiales Avanzados:**

- Investigar materiales biomiméticos para replicar la apariencia y sensación de la piel humana y mejorar la interacción del usuario con la prótesis.
- Usar compuestos ligeros y resistentes que aumenten la durabilidad sin sacrificar la funcionalidad.

### **Integración de Sensores y Actuadores Mejorados:**

- Integrar una matriz de microsensores en la prótesis para detectar estímulos como textura, presión y temperatura con precisión.
- Desarrollar actuadores miniaturizados para proporcionar una retroalimentación táctil diferenciada, mejorando la percepción sensorial del usuario.

### **Rediseño Compacto y Modular:**

- Crear un diseño modular y compacto que permita un transporte fácil sin comprometer la funcionalidad.

### **Integración de Tecnología Inalámbrica:**

- Incorporar conectividad inalámbrica y baterías de alta densidad energética para reducir el tamaño del sistema de alimentación.

### **Materiales Ligeros y Resistentes:**

- Seleccionar materiales de alta tecnología que ofrezcan una excelente resistencia sin añadir peso.

**Software y Feedback Inteligente:**

- Implementar un software que gestione el modo de bajo consumo y brinde retroalimentación para el cuidado de la prótesis.

## 10 REFERENCIAS

---

- Aflalo, T., Kellis, S., Klaes, C., Lee, B., Shi, Y., Pejsa, K., Shanfield, K., Hayes-Jackson, S., Aisen, M., Heck, C., Liu, C., & Andersen, R. A. (2015). Decoding motor imagery from the posterior parietal cortex of a tetraplegic human. *Science*, *348*(6237), 906-910. <https://doi.org/10.1126/science.aaa5417>
- Antfolk, C., D'Alonzo, M., Rosén, B., Lundborg, G., Sebelius, F., & Cipriani, C. (2013). Sensory feedback in upper limb prosthetics. *Expert Review of Medical Devices*, *10*(1), 45-54. <https://doi.org/10.1586/erd.12.68>
- Arias, M. C., & Martínez, V. C. (2023). Análisis de la reacción fisiológica cerebral del usuario de realidad virtual a través de la encefalografía (EEG). *Comunicación & Métodos*, *5*(2), Article 2. <https://doi.org/10.35951/v5i2.196>
- Aura Through Time. (s. f.). *Mirai Innovation Research Institute*. Recuperado 13 de diciembre de 2023, de <https://www.mirai-innovation-lab.com/aura-through-time/>
- Bai, X., Li, M., Qi, S., Ng, A. C. M., Ng, T., & Qian, W. (2023). A hybrid P300-SSVEP brain-computer interface speller with a frequency enhanced row and column paradigm. *Frontiers in Neuroscience*, *17*. <https://www.frontiersin.org/articles/10.3389/fnins.2023.1133933>
- Balam, V. P., Pławiak, P., & Jayaprakash, A. (2021). *A Brief Review on EEG Signal Pre-processing Techniques for Real-Time Brain-Computer Interface Applications*. <https://doi.org/10.36227/techrxiv.16691605>
- Belter, J. T., Segil, J. L., Dollar, A. M., & Weir, R. F. (2013). Mechanical design and performance specifications of anthropomorphic prosthetic hands: A review. *The Journal of Rehabilitation Research and Development*, *50*(5), 599. <https://doi.org/10.1682/JRRD.2011.10.0188>

- Bhattacharyya, S., Konar, A., & Tibarewala, D. N. (2014). Motor imagery, P300 and error-related EEG-based robot arm movement control for rehabilitation purpose. *Medical & Biological Engineering & Computing*, 52(12), 1007-1017. <https://doi.org/10.1007/s11517-014-1204-4>
- Biddiss, E. A., & Chau, T. T. (2007). Upper limb prosthesis use and abandonment: A survey of the last 25 years. *Prosthetics and Orthotics International*, 31(3), 236.  
<https://doi.org/10.1080/03093640600994581>
- Birbaumer, N., & Cohen, L. G. (2007). Brain-computer interfaces: Communication and restoration of movement in paralysis. *The Journal of Physiology*, 579(Pt 3), 621-636.  
<https://doi.org/10.1113/jphysiol.2006.125633>
- Birbaumer, N., Ghanayim, N., Hinterberger, T., Iversen, I., Kotchoubey, B., Kübler, A., Perelmouter, J., Taub, E., & Flor, H. (1999). A spelling device for the paralysed. *Nature*, 398(6725), 297-298.  
<https://doi.org/10.1038/18581>
- Bishop, C. M. (2023). *Pattern Recognition and Machine Learning*. MTM.
- Bishop, R. H. (Ed.). (2002). *The Mechatronics Handbook—2 Volume Set*. CRC Press.  
<https://doi.org/10.1201/9781420042450>
- Boulton, A. J., Vileikyte, L., Ragnarson-Tennvall, G., & Apelqvist, J. (2005). The global burden of diabetic foot disease. *The Lancet*, 366(9498), 1719-1724. [https://doi.org/10.1016/S0140-6736\(05\)67698-2](https://doi.org/10.1016/S0140-6736(05)67698-2)
- Branco, M. P., Freudenburg, Z. V., Aarnoutse, E. J., Bleichner, M. G., Vansteensel, M. J., & Ramsey, N. F. (2017). Decoding hand gestures from primary somatosensory cortex using high-density ECoG. *NeuroImage*, 147, 130-142. <https://doi.org/10.1016/j.neuroimage.2016.12.004>
- Brand, P. W., & Hollister, A. (1993). *Clinical Mechanics of the Hand*. Mosby Year Book.
- Brandl, S., & Blankertz, B. (2020). Motor Imagery Under Distraction—An Open Access BCI Dataset. *Frontiers in Neuroscience*, 14, 566147. <https://doi.org/10.3389/fnins.2020.566147>

- Buchholz, B., & Armstrong, T. J. (1992). A kinematic model of the human hand to evaluate its prehensile capabilities. *Journal of Biomechanics*, 25(2), 149-162. [https://doi.org/10.1016/0021-9290\(92\)90272-3](https://doi.org/10.1016/0021-9290(92)90272-3)
- Buzsáki, G., Anastassiou, C. A., & Koch, C. (2012). The origin of extracellular fields and currents—EEG, ECoG, LFP and spikes. *Nature Reviews Neuroscience*, 13(6), Article 6. <https://doi.org/10.1038/nrn3241>
- Buzsáki, G., & Draguhn, A. (2004). Neuronal oscillations in cortical networks. *Science (New York, N.Y.)*, 304(5679), 1926-1929. <https://doi.org/10.1126/science.1099745>
- Canny, E., Vansteensel, M. J., van der Salm, S. M. A., Müller-Putz, G. R., & Berezutskaya, J. (2023). Boosting brain–computer interfaces with functional electrical stimulation: Potential applications in people with locked-in syndrome. *Journal of NeuroEngineering and Rehabilitation*, 20(1), 157. <https://doi.org/10.1186/s12984-023-01272-y>
- Cerino, R., Pinto, D., Vergara, S., Pérez-Téllez, F., Cerino, R., Pinto, D., Vergara, S., & Pérez-Téllez, F. (2023). Estimulación visual basada en conceptos y su análisis mediante electroencefalografía. *Computación y Sistemas*, 27(1), 107-126. <https://doi.org/10.13053/cys-27-1-4417>
- Charkhkar, H., Shell, C. E., Marasco, P. D., Pinault, G. J., Tyler, D. J., & Triolo, R. J. (2018). High-density peripheral nerve cuffs restore natural sensation to individuals with lower-limb amputations. *Journal of Neural Engineering*, 15(5), 056002. <https://doi.org/10.1088/1741-2552/aac964>
- Cipriani, C., Segil, J. L., Birdwell, J. A., & Weir, R. F. ff. (2014). Dexterous Control of a Prosthetic Hand Using Fine-Wire Intramuscular Electrodes in Targeted Extrinsic Muscles. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4), 828-836. <https://doi.org/10.1109/TNSRE.2014.2301234>
- Colciencias, C. D. de C. T. e innovaciones-, Bid, B. I. de D.-, & Tecnología, C. M. de C. y. (2024). Plan estratégico departamental de ciencia, tecnología e innovación del Cauca. *Acemoglu, Daron. y*

- Robinson, James. (2012) *Por qué fracasan los países*. Bogotá: Editorial Planeta Colombiana S.A.  
<https://repositorio.minciencias.gov.co/handle/20.500.14143/537>
- Collinger, J. L., Wodlinger, B., Downey, J. E., Wang, W., Tyler-Kabara, E. C., Weber, D. J., McMorland, A. J. C., Velliste, M., Boninger, M. L., & Schwartz, A. B. (2013). High-performance neuroprosthetic control by an individual with tetraplegia. *Lancet (London, England)*, 381(9866), 557-564.  
[https://doi.org/10.1016/S0140-6736\(12\)61816-9](https://doi.org/10.1016/S0140-6736(12)61816-9)
- Cordella, F., Ciancio, A. L., Sacchetti, R., Davalli, A., Cutti, A. G., Guglielmelli, E., & Zollo, L. (2016). Literature Review on Needs of Upper Limb Prosthesis Users. *Frontiers in Neuroscience*, 10.  
<https://www.frontiersin.org/articles/10.3389/fnins.2016.00209>
- Cuellar, J. S., Smit, G., Breedveld, P., Zadpoor, A. A., & Plettenburg, D. (2019). Functional evaluation of a non-assembly 3D-printed hand prosthesis. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, 233(11), 1122-1131.  
<https://doi.org/10.1177/0954411919874523>
- Cutkosky, M. R., Howe, R. D., & Provancher, W. R. (2008). Force and Tactile Sensors. En B. Siciliano & O. Khatib (Eds.), *Springer Handbook of Robotics* (pp. 455-476). Springer.  
[https://doi.org/10.1007/978-3-540-30301-5\\_20](https://doi.org/10.1007/978-3-540-30301-5_20)
- D'Alonzo, M., & Cipriani, C. (2012). Vibrotactile Sensory Substitution Elicits Feeling of Ownership of an Alien Hand. *PLOS ONE*, 7(11), e50756. <https://doi.org/10.1371/journal.pone.0050756>
- Davies, B. (2000). A review of robotics in surgery. *Proceedings of the Institution of Mechanical Engineers. Part H, Journal of Engineering in Medicine*, 214(1), 129-140.  
<https://doi.org/10.1243/0954411001535309>
- Dobkin, B. H. (2007). Brain-computer interface technology as a tool to augment plasticity and outcomes for neurological rehabilitation. *The Journal of Physiology*, 579(Pt 3), 637-642.  
<https://doi.org/10.1113/jphysiol.2006.123067>

- Dollar, A. M., & Herr, H. (2008). Lower Extremity Exoskeletons and Active Orthoses: Challenges and State-of-the-Art. *IEEE Transactions on Robotics*, 24(1), 144-158.  
<https://doi.org/10.1109/TRO.2008.915453>
- Donchin, E., Spencer, K. M., & Wijesinghe, R. (2000). The mental prosthesis: Assessing the speed of a P300-based brain-computer interface. *IEEE Transactions on Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society*, 8(2), 174-179.  
<https://doi.org/10.1109/86.847808>
- Edelman, B. J., Baxter, B., & He, B. (2016). EEG Source Imaging Enhances the Decoding of Complex Right-Hand Motor Imagery Tasks. *IEEE Transactions on Bio-Medical Engineering*, 63(1), 4-14.  
<https://doi.org/10.1109/TBME.2015.2467312>
- Ein Shoka, A. A., Dessouky, M. M., El-Sayed, A., & Hemdan, E. E.-D. (2023). EEG seizure detection: Concepts, techniques, challenges, and future trends. *Multimedia Tools and Applications*, 82(27), 42021-42051. <https://doi.org/10.1007/s11042-023-15052-2>
- Electroencefalograma | ¿Qué es un electroencefalograma | PortalCLÍNICA*. (s. f.). Clínic Barcelona.  
Recuperado 25 de noviembre de 2023, de <https://www.clinicbarcelona.org/asistencia/pruebas-y-procedimientos/electroencefalograma>
- En, S., Educación, L., Sciotto, E. A., & Niripil, E. (2018). *ONDAS CEREBRALES, CONCIENCIA Y COGNICIÓN*.
- Fanjul, J. M. (2022, agosto 19). ¿Qué es el Análisis de Componentes Principales y cómo reducir el tamaño de una base de datos? *Blog de hiberus*. <https://www.hiberus.com/crecemos-contigo/analisis-de-componentes-principales/>
- Farina, D., Jiang, N., Rehbaum, H., Holobar, A., Graimann, B., Dietl, H., & Aszmann, O. C. (2014a). The Extraction of Neural Information from the Surface EMG for the Control of Upper-Limb Prostheses: Emerging Avenues and Challenges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4), 797-809. <https://doi.org/10.1109/TNSRE.2014.2305111>

Farina, D., Jiang, N., Rehbaum, H., Holobar, A., Graimann, B., Dietl, H., & Aszmann, O. C. (2014b). The Extraction of Neural Information from the Surface EMG for the Control of Upper-Limb Prostheses: Emerging Avenues and Challenges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4), 797-809. <https://doi.org/10.1109/TNSRE.2014.2305111>

Farina, D., Jiang, N., Rehbaum, H., Holobar, A., Graimann, B., Dietl, H., & Aszmann, O. C. (2014c). The extraction of neural information from the surface EMG for the control of upper-limb prostheses: Emerging avenues and challenges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society*, 22(4), 797-809. <https://doi.org/10.1109/TNSRE.2014.2305111>

FFT. (s. f.). Recuperado 11 de diciembre de 2023, de <https://www.nti-audio.com/es/servicio/conocimientos/transformacion-rapida-de-fourier-fft>

Filtro elimina banda. (2019). En *Wikipedia, la enciclopedia libre*. [https://es.wikipedia.org/w/index.php?title=Filtro\\_elimina\\_banda&oldid=118740013](https://es.wikipedia.org/w/index.php?title=Filtro_elimina_banda&oldid=118740013)

Filtro paso alto. (2022). En *Wikipedia, la enciclopedia libre*. [https://es.wikipedia.org/w/index.php?title=Filtro\\_paso\\_alto&oldid=144371533](https://es.wikipedia.org/w/index.php?title=Filtro_paso_alto&oldid=144371533)

Filtro paso bajo. (2022). En *Wikipedia, la enciclopedia libre*. [https://es.wikipedia.org/w/index.php?title=Filtro\\_paso\\_bajo&oldid=144370296](https://es.wikipedia.org/w/index.php?title=Filtro_paso_bajo&oldid=144370296)

Filtro paso banda. (2023). En *Wikipedia, la enciclopedia libre*. [https://es.wikipedia.org/w/index.php?title=Filtro\\_paso\\_banda&oldid=152886024](https://es.wikipedia.org/w/index.php?title=Filtro_paso_banda&oldid=152886024)

Fiuza Pérez, M. D., & Rodríguez Pérez, J. C. (2000). La regresión logística: Una herramienta versátil. *Nefrología*, 20(6), 495-500.

Fougner, A., Stavadahl, Ø., Kyberd, P. J., Losier, Y. G., & Parker, P. A. (2012). Control of Upper Limb Prostheses: Terminology and Proportional Myoelectric Control—A Review. *IEEE Transactions on*

*Neural Systems and Rehabilitation Engineering*, 20(5), 663-677.

<https://doi.org/10.1109/TNSRE.2012.2196711>

Gilja, V., Pandarinath, C., Blabe, C. H., Nuyujukian, P., Simeral, J. D., Sarma, A. A., Sorice, B. L., Perge, J. A., Jarosiewicz, B., Hochberg, L. R., Shenoy, K. V., & Henderson, J. M. (2015). Clinical translation of a high-performance neural prosthesis. *Nature Medicine*, 21(10), 1142-1145.

<https://doi.org/10.1038/nm.3953>

Gu, X., Cao, Z., Jolfaei, A., Xu, P., Wu, D., Jung, T.-P., & Lin, C.-T. (2020). EEG-Based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and Their Applications. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, PP. <https://doi.org/10.1109/TCBB.2021.3052811>

Guerrero-Mendez, C. D., Blanco-Diaz, C. F., Ruiz-Olaya, A. F., López-Delis, A., Jaramillo-Isaza, S., Andrade, R. M., Souza, A. F. D., Delisle-Rodriguez, D., Frizzera-Neto, A., & Bastos-Filho, T. F. (2023). EEG motor imagery classification using deep learning approaches in naïve BCI users. *Biomedical Physics & Engineering Express*, 9(4), 045029. <https://doi.org/10.1088/2057-1976/acde82>

Hargrove, L. J., Simon, A. M., Young, A. J., Lipschutz, R. D., Finucane, S. B., Smith, D. G., & Kuiken, T. A. (2013). Robotic leg control with EMG decoding in an amputee with nerve transfers. *The New England Journal of Medicine*, 369(13), 1237-1242. <https://doi.org/10.1056/NEJMoa1300126>

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer.

<https://doi.org/10.1007/978-0-387-84858-7>

Hebert, J. S., Olson, J. L., Morhart, M. J., Dawson, M. R., Marasco, P. D., Kuiken, T. A., & Chan, K. M. (2014). Novel targeted sensory reinnervation technique to restore functional hand sensation after transhumeral amputation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society*, 22(4), 765-773. <https://doi.org/10.1109/TNSRE.2013.2294907>

Hirsch, L. J., Fong, M. W. K., Leitinger, M., LaRoche, S. M., Beniczky, S., Abend, N. S., Lee, J. W., Wusthoff, C. J., Hahn, C. D., Westover, M. B., Gerard, E. E., Herman, S. T., Haider, H. A., Osman, G., Rodriguez-Ruiz, A., Maciel, C. B., Gilmore, E. J., Fernandez, A., Rosenthal, E. S., ... Gaspard, N. (2021). American Clinical Neurophysiology Society's Standardized Critical Care EEG Terminology: 2021 Version. *Journal of Clinical Neurophysiology: Official Publication of the American Electroencephalographic Society*, 38(1), 1-29. <https://doi.org/10.1097/WNP.0000000000000806>

Hochberg, L. R., Bacher, D., Jarosiewicz, B., Masse, N. Y., Simeral, J. D., Vogel, J., Haddadin, S., Liu, J., Cash, S. S., van der Smagt, P., & Donoghue, J. P. (2012). Reach and grasp by people with tetraplegia using a neurally controlled robotic arm. *Nature*, 485(7398), 372-375. <https://doi.org/10.1038/nature11076>

Hochberg, L. R., Serruya, M. D., Friehs, G. M., Mukand, J. A., Saleh, M., Caplan, A. H., Branner, A., Chen, D., Penn, R. D., & Donoghue, J. P. (2006). Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, 442(7099), 164-171. <https://doi.org/10.1038/nature04970>

Hochberg, L., Serruya, M., Friehs, G., Mukand, J., Saleh, M., Caplan, A., Branner, A., Chen, D., Penn, R., & Donoghue, J. (2006). Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, 442, 164-171. <https://doi.org/10.1038/nature04970>

Hoggan, E., Brewster, S. A., & Johnston, J. (2008). Investigating the effectiveness of tactile feedback for mobile touchscreens. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 1573-1582. <https://doi.org/10.1145/1357054.1357300>

*Informe mundial sobre la salud mental: Transformar la salud mental para todos.* (2023). Pan American Health Organization. <https://doi.org/10.37774/9789275327715>

InMoov body parts library : (s. f.). *InMoov*. Recuperado 24 de abril de 2024, de <https://inmoov.fr/inmoov-stl-parts-viewer/>

InMoov body parts library : (s. f.). *InMoov*. Recuperado 27 de abril de 2024, de

<https://inmoov.fr/inmoov-stl-parts-viewer/>

Jaseja, H. (2023). Electroencephalography in the diagnosis and management of treatment-resistant depression with comorbid epilepsy: A novel strategy. *General Psychiatry*, 36(2), e100868.

<https://doi.org/10.1136/gpsych-2022-100868>

Jeong, J. (2004). EEG dynamics in patients with Alzheimer's disease. *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, 115(7), 1490-1505.

<https://doi.org/10.1016/j.clinph.2004.01.001>

Klem, G. H., Lüders, H. O., Jasper, H. H., & Elger, C. (1999). The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology.

*Electroencephalography and clinical neurophysiology. Supplement.*

[https://doi.org/10.1016/0022-510x\(84\)90023-6](https://doi.org/10.1016/0022-510x(84)90023-6)

Klem, G. H., Lüders, H. O., Jasper, H. H., & Elger, C. (1999). *Guidelines of the International Federation of Clinical Physiology* (52.<sup>a</sup> ed.). Elsevier Science B.V.

Lebedev, M. A., & Nicolelis, M. A. L. (2006a). Brain-machine interfaces: Past, present and future. *Trends in Neurosciences*, 29(9), 536-546. <https://doi.org/10.1016/j.tins.2006.07.004>

Lebedev, M. A., & Nicolelis, M. A. L. (2006b). Brain-machine interfaces: Past, present and future. *Trends in Neurosciences*, 29(9), 536-546. <https://doi.org/10.1016/j.tins.2006.07.004>

Leuthardt, E. C., Schalk, G., Wolpaw, J. R., Ojemann, J. G., & Moran, D. W. (2004). A brain-computer interface using electrocorticographic signals in humans. *Journal of Neural Engineering*, 1(2), 63-71. <https://doi.org/10.1088/1741-2560/1/2/001>

López Callejo, P. (2019). *Análisis de artefactos oculares en electroencefalogramas mediante wavelets* [Info:eu-repo/semantics/bachelorThesis]. E.T.S.I. Industriales (UPM). <https://oa.upm.es/56803/>

- Lu, Z., Chen, X., Zhang, X., Tong, K.-Y., & Zhou, P. (2017). Real-Time Control of an Exoskeleton Hand Robot with Myoelectric Pattern Recognition. *International Journal of Neural Systems*, 27(05), 1750009. <https://doi.org/10.1142/S0129065717500095>
- Luck, S. J. (2014). *An Introduction to the Event-Related Potential Technique, second edition*. MIT Press.
- Lundström, R. (1984). Local vibrations—Mechanical impedance of the human hand's glabrous skin. *Journal of Biomechanics*, 17(2), 137-144. [https://doi.org/10.1016/0021-9290\(84\)90131-3](https://doi.org/10.1016/0021-9290(84)90131-3)
- Major Extremity Trauma Research Consortium (METRC). (2023). Development of a prosthetic fit and alignment assessment (ProFit) in persons with post-traumatic transtibial amputation. *Prosthetics and Orthotics International*, 47(6), 599-606. <https://doi.org/10.1097/PXR.0000000000000237>
- Medina, B., Sierra, J. E., & Ulloa, A. B. (s. f.). *Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI*.
- Meng, J., Zhang, S., Bekyo, A., Olsoe, J., Baxter, B., & He, B. (2016a). Noninvasive Electroencephalogram Based Control of a Robotic Arm for Reach and Grasp Tasks. *Scientific Reports*, 6(1), Article 1. <https://doi.org/10.1038/srep38565>
- Meng, J., Zhang, S., Bekyo, A., Olsoe, J., Baxter, B., & He, B. (2016b). Noninvasive Electroencephalogram Based Control of a Robotic Arm for Reach and Grasp Tasks. *Scientific Reports*, 6(1), Article 1. <https://doi.org/10.1038/srep38565>
- Micera, S., Carpaneto, J., & Raspopovic, S. (2010). Control of Hand Prostheses Using Peripheral Information. *IEEE Reviews in Biomedical Engineering*, 3, 48-68. <https://doi.org/10.1109/RBME.2010.2085429>
- Mirete, C. R. (s. f.). *Técnicas de aprendizaje profundo para clasificación de señales EEG de imaginación motora*.
- Morelos, D. O. R., Corral, C. M., Marrufo, I. S., Torres-Arguelles, V., & González, I. O. B. (2019). *Metodologías para diseño de prácticas didácticas en sistemas de control*. 12(11).

- Morgenroth, D. C., Gellhorn, A. C., & Suri, P. (2012). Osteoarthritis in the Disabled Population: A Mechanical Perspective. *PM&R*, 4(5S), S20.
- Müller-Putz, G. R., Scherer, R., Pfurtscheller, G., & Rupp, R. (2006). *Brain-computer interfaces for control of neuroprostheses: From synchronous to asynchronous mode of operation / Brain-Computer Interfaces zur Steuerung von Neuroprothesen: von der synchronen zur asynchronen Funktionsweise*. 51(2), 57-63. <https://doi.org/10.1515/BMT.2006.011>
- Muñoz-Ruata, J. (1999). Ritmos cerebrales y cognición en deficientes mentales. *Educación, desarrollo y diversidad*, 1, 43-62.
- Nicolas-Alonso, L. F., & Gomez-Gil, J. (2012). Brain Computer Interfaces, a Review. *Sensors*, 12(2), Article 2. <https://doi.org/10.3390/s120201211>
- Niedermeyer, E., & Silva, F. H. L. da. (2005). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins.
- Ondas cerebrales y su significado. (2019, mayo 13). *clinicaalevia.com*.  
<https://www.clinicaalevia.com/ondas-cerebrales-y-su-significado/>
- Pawan, & Dhiman, R. (2023). Machine learning techniques for electroencephalogram based brain-computer interface: A systematic literature review. *Measurement: Sensors*, 28, 100823. <https://doi.org/10.1016/j.measen.2023.100823>
- Penaloza, C. I., Alimardani, M., & Nishio, S. (2018). Android Feedback-Based Training Modulates Sensorimotor Rhythms During Motor Imagery. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(3), 666-674. <https://doi.org/10.1109/TNSRE.2018.2792481>
- Penaloza, C. I., Mae, Y., Cuellar, F. F., Kojima, M., & Arai, T. (2014). Brain Machine Interface System Automation Considering User Preferences and Error Perception Feedback. *IEEE Transactions on Automation Science and Engineering*, 11(4), 1275-1281. <https://doi.org/10.1109/TASE.2014.2339354>

- Penaloza, C. I., & Nishio, S. (2018). BMI control of a third arm for multitasking. *Science Robotics*, 3(20), eaat1228. <https://doi.org/10.1126/scirobotics.aat1228>
- Periódico UNAL*. (s. f.). Recuperado 6 de febrero de 2024, de <https://www.periodico.unal.edu.co>
- Perry, J. C., Rosen, J., & Burns, S. (2007). Upper-Limb Powered Exoskeleton Design. *IEEE/ASME Transactions on Mechatronics*, 12(4), 408-417. <https://doi.org/10.1109/TMECH.2007.901934>
- Pfurtscheller, G., Müller-Putz, G. R., Pfurtscheller, J., & Rupp, R. (2005). EEG-Based Asynchronous BCI Controls Functional Electrical Stimulation in a Tetraplegic Patient. *EURASIP Journal on Advances in Signal Processing*, 2005(19), Article 19. <https://doi.org/10.1155/ASP.2005.3152>
- Pfurtscheller, G., Neuper, C., Guger, C., Harkam, W., Ramoser, H., Schlögl, A., Obermaier, B., & Pregenzer, M. (2000). Current trends in Graz Brain-Computer Interface (BCI) research. *IEEE Transactions on Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society*, 8(2), 216-219. <https://doi.org/10.1109/86.847821>
- Pons, J. L. (2008). *Wearable Robots: Biomechatronic Exoskeletons*. John Wiley & Sons.
- Proal, E., Alvarez-Segura, M., de la Iglesia-Vayá, M., Martí-Bonmatí, L., & Castellanos, F. X. (2011). Actividad funcional cerebral en estado de reposo: REDES EN CONEXIÓN. *Revista de neurología*, 52(0 1), S3-10.
- Quintero-Rincon, A., Liberczuk, S., & Risk, M. (2012). Preprocesamiento de EEG con Filtros Hampel. En *Argencon IEEE 2012* (Vol. 89).
- Ran, D., Zhang, Y., Yuan, Y., & Bian, K. (2020). CFP: A Cross-layer Recommender System with Fine-grained Preloading for Short Video Streaming at Network Edge. *2020 IEEE 13th International Conference on Cloud Computing (CLOUD)*, 380-388. <https://doi.org/10.1109/CLOUD49709.2020.00059>
- Rodríguez González, Z. I., & Soriano Padilla, F. (2015). Complejo de deformidades amnióticas, adhesiones, mutilación: Interminable debate. *Boletín Médico del Hospital Infantil de México*, 72(3), 159-168. <https://doi.org/10.1016/j.bmhmx.2015.06.006>

- Saal, H. P., & Bensmaia, S. J. (2015). Biomimetic approaches to bionic touch through a peripheral nerve interface. *Neuropsychologia*, 79(Pt B), 344-353.  
<https://doi.org/10.1016/j.neuropsychologia.2015.06.010>
- Sáez, T. D. (s. f.). *Relación entre procesos mentales y sentido háptico: Emociones y recuerdos mediante el análisis empírico de texturas*.
- Safari, R. (2020). Lower limb prosthetic interfaces: Clinical and technological advancement and potential future direction. *Prosthetics and Orthotics International*, 44(6), 384-401.  
<https://doi.org/10.1177/0309364620969226>
- Salisbury, K., Conti, F., & Barbagli, F. (2004). Haptic Rendering: Introductory Concepts. *IEEE Computer Graphics and Applications*, 24(2), 24-32. <https://doi.org/10.1109/MCG.2004.1274058>
- Santos, P. R. de los. (s. f.). *Tipos de aprendizaje en Machine Learning: Supervisado y no supervisado*. Telefónica Tech. Recuperado 11 de diciembre de 2023, de <https://telefonicatech.com/blog/que-algoritmo-elegir-en-ml-aprendizaje>
- Scheme, E., & Englehart, K. (2011). Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use. *The Journal of Rehabilitation Research and Development*, 48(6), 643. <https://doi.org/10.1682/JRRD.2010.09.0177>
- Schwartz, A. B., Cui, X. T., Weber, D. J., & Moran, D. W. (2006). Brain-controlled interfaces: Movement restoration with neural prosthetics. *Neuron*, 52(1), 205-220.  
<https://doi.org/10.1016/j.neuron.2006.09.019>
- Sensing, J. W., & Dosen, S. (2020). A Review of Sensory Feedback in Upper-Limb Prostheses From the Perspective of Human Motor Control. *Frontiers in Neuroscience*, 14, 345.  
<https://doi.org/10.3389/fnins.2020.00345>

- Serrancoí, G., Kinney, A. L., Fregly, B. J., & Font-Llagunes, J. M. (2016). Neuromusculoskeletal Model Calibration Significantly Affects Predicted Knee Contact Forces for Walking. *Journal of Biomechanical Engineering*, 138(8), 0810011-08100111. <https://doi.org/10.1115/1.4033673>
- Srinivasan, M. A., & Basdogan, C. (1997). Haptics in virtual environments: Taxonomy, research status, and challenges. *Computers & Graphics*, 21(4), 393-404. [https://doi.org/10.1016/S0097-8493\(97\)00030-7](https://doi.org/10.1016/S0097-8493(97)00030-7)
- Staff, T. P. B. (2019). Expression of Concern: Brain–Computer Interface–Based Communication in the Completely Locked-In State. *PLOS Biology*, 17(10), e3000527. <https://doi.org/10.1371/journal.pbio.3000527>
- Stam, C. J. (2005). Nonlinear dynamical analysis of EEG and MEG: Review of an emerging field. *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, 116(10), 2266-2301. <https://doi.org/10.1016/j.clinph.2005.06.011>
- SYNCED. (2017, febrero 24). David Silver, Google DeepMind: Deep Reinforcement Learning | Synced. <https://syncedreview.com/2017/02/24/david-silver-google-deepmind-deep-reinforcement-learning/>
- Tagliamonte, N. L., & Accoto, D. (2014). Passivity constraints for the impedance control of series elastic actuators. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 228(3), 138-153. <https://doi.org/10.1177/0959651813511615>
- Torres-García, A. A., Reyes-García, C. A., Villaseñor-Pineda, L., & Ramírez-Cortés, J. M. (2013a). Análisis de señales electroencefalográficas para la clasificación de habla imaginada. *Revista mexicana de ingeniería biomédica*, 34(1), 23-39.
- Torres-García, A. A., Reyes-García, C. A., Villaseñor-Pineda, L., & Ramírez-Cortés, J. M. (2013b). Análisis de señales electroencefalográficas para la clasificación de habla imaginada. *Revista mexicana de ingeniería biomédica*, 34(1), 23-39.

*Transformadas Wavelet | Multimedia*. (s. f.). Recuperado 11 de diciembre de 2023, de

<http://multimedia.ufp.pt/codecs/compressao-com-perdas/transformadas-wavelet/>

Tubiana, R., & Valentin, P. (1964). THE ANATOMY OF THE EXTENSOR APPARATUS OF THE FINGERS. *The Surgical Clinics of North America*, 44, 897-906.

Universidad Autónoma Metropolitana, Trejo-Alcantara, G., Castañeda-Villa, N., & Universidad Autónoma Metropolitana. (2017). Effect of EEG pre-processing on Independent Component Analysis: Reduction of cochlear implant artifact in Auditory Evoked Potentials. *Revista Mexicana de Ingeniería Biomédica*, 38(1), 382-389. <https://doi.org/10.17488/RMIB.38.1.34>

Universitat Politècnica De València, E. (2014). Universitat Politècnica de València. *Ingeniería del agua*, 18(1), ix. <https://doi.org/10.4995/ia.2014.3293>

Valdés Rodríguez, O. (1997). *Sistema de Mapeo de Actividad Eléctrica Cerebral*.

Valencia, C. F., Suárez, J. A., Cogollos, Á., Uribe, R. A., & Flores, G. C. (2015). Heridos en combate, experiencia del Grupo de Trauma del Hospital Militar Central de Bogotá. *Revista Colombiana de Cirugía*, 30(1), Article 1. <https://doi.org/10.30944/20117582.315>

Vansteensel, M. J., Pels, E. G. M., Bleichner, M. G., Branco, M. P., Denison, T., Freudenburg, Z. V., Gosselaar, P., Leinders, S., Ottens, T. H., Van Den Boom, M. A., Van Rijen, P. C., Aarnoutse, E. J., & Ramsey, N. F. (2016). Fully Implanted Brain-Computer Interface in a Locked-In Patient with ALS. *The New England Journal of Medicine*, 375(21), 2060-2066. <https://doi.org/10.1056/NEJMoa1608085>

Vidal, J. J. (1973a). Toward Direct Brain-Computer Communication. *Annual Review of Biophysics and Bioengineering*, 2(1), 157-180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>

Vidal, J. J. (1973b). Toward Direct Brain-Computer Communication. *Annual Review of Biophysics and Bioengineering*, 2(1), 157-180. <https://doi.org/10.1146/annurev.bb.02.060173.001105>

- Wells, E. D., Shehata, A. W., Dawson, M. R., Carey, J. P., & Hebert, J. S. (2022). Preliminary Evaluation of the Effect of Mechanotactile Feedback Location on Myoelectric Prosthesis Performance Using a Sensorized Prosthetic Hand. *Sensors*, 22(10), Article 10. <https://doi.org/10.3390/s22103892>
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., & Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, 113(6), 767-791. [https://doi.org/10.1016/s1388-2457\(02\)00057-3](https://doi.org/10.1016/s1388-2457(02)00057-3)
- Wolpaw, J. R., McFarland, D. J., Neat, G. W., & Forneris, C. A. (1991). An EEG-based brain-computer interface for cursor control. *Electroencephalography and Clinical Neurophysiology*, 78(3), 252-259. [https://doi.org/10.1016/0013-4694\(91\)90040-B](https://doi.org/10.1016/0013-4694(91)90040-B)
- World Health Organization (WHO)*. (s. f.). Recuperado 6 de febrero de 2024, de <https://www.who.int/es>
- Yadav, H., & Maini, S. (2023). Electroencephalogram based brain-computer interface: Applications, challenges, and opportunities. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-023-15653-x>
- Zamarrón Sobrinos, C. (2019). *Análisis y Clasificación de las Señales de la Actividad Neuronal Rítmica (EEG) para la Detección de la Epilepsia basado en Wavelets*. <https://repositorio.comillas.edu/xmlui/handle/11531/29310>
- Zhang, X., Purba, V., Hong, M., & Dhople, S. (2020a). A Sum-of-Squares Optimization Method for Learning and Controlling Photovoltaic Systems. *2020 American Control Conference (ACC)*, 2376-2381. <https://doi.org/10.23919/ACC45564.2020.9147944>
- Zhang, X., Purba, V., Hong, M., & Dhople, S. (2020b). A Sum-of-Squares Optimization Method for Learning and Controlling Photovoltaic Systems. *2020 American Control Conference (ACC)*, 2376-2381. <https://doi.org/10.23919/ACC45564.2020.9147944>

- Zheng, H., & Shen, X. (2015). Design and Control of a Pneumatically Actuated Transtibial Prosthesis. *Journal of bionic engineering*, 12(2), 217-226. [https://doi.org/10.1016/S1672-6529\(14\)60114-1](https://doi.org/10.1016/S1672-6529(14)60114-1)
- Ziegler-Graham, K., MacKenzie, E. J., Ephraim, P. L., Trivison, T. G., & Brookmeyer, R. (2008a). Estimating the Prevalence of Limb Loss in the United States: 2005 to 2050. *Archives of Physical Medicine and Rehabilitation*, 89(3), 422-429. <https://doi.org/10.1016/j.apmr.2007.11.005>
- Ziegler-Graham, K., MacKenzie, E. J., Ephraim, P. L., Trivison, T. G., & Brookmeyer, R. (2008b). Estimating the Prevalence of Limb Loss in the United States: 2005 to 2050. *Archives of Physical Medicine and Rehabilitation*, 89(3), 422-429. <https://doi.org/10.1016/j.apmr.2007.11.005>
- Zuniga, J., Katsavelis, D., Peck, J., Stollberg, J., Petrykowski, M., Carson, A., & Fernandez, C. (2015). Cyborg beast: A low-cost 3d-printed prosthetic hand for children with upper-limb differences. *BMC Research Notes*, 8(1), 10. <https://doi.org/10.1186/s13104-015-0971-9>
- Zuniga, J. M., Peck, J., Srivastava, R., Katsavelis, D., & Carson, A. (2016). An open source 3D-printed transitional hand prosthesis for children. *Journal of Prosthetics and Orthotics*, 28(3), 103-108. <https://doi.org/10.1097/JPO.0000000000000097>

# 11 ANEXOS

---

## 11.1 ANEXO 1 CÓDIGO CONTROL MOTORES PRÓTESIS

```
#include <Servo.h>

Servo servo1;
Servo servo2;
Servo servo3;
Servo servo4;
Servo servo5;

volatile int angle = 90; // Ángulo inicial

void setup() {
  Serial.begin(9600);

  servo1.attach(3);
  servo2.attach(5);
  servo3.attach(6);
  servo4.attach(9);
  servo5.attach(10);

  // Inicializa los servos en el ángulo inicial
  servo1.write(angle);
```

```

servo2.write(angle);
servo3.write(angle);
servo4.write(angle);
servo5.write(angle);
}

void loop() {
  if (Serial.available() > 0) {
    char receivedChar = Serial.read();
    if (receivedChar == '0') {
      angle = 0;
    } else if (receivedChar == '1') {
      angle = 180;
    } else if (receivedChar == 's') {
      angle = 90;
    }
  }
}

// Actualiza los servos en paralelo
updateServos();
}

void updateServos() {
  static int previousAngle = angle;
  if (previousAngle != angle) {
    servo1.write(angle);
    servo2.write(angle);
    servo3.write(angle);
    servo4.write(angle);
    servo5.write(angle);
    previousAngle = angle;
  }
}

```

## 11.2 ANEXO 2 CÓDIGO AURA.PY.

```

import datetime
from pylsl import StreamInlet, resolve_stream
import numpy as np
# first resolve a marker stream on the lab network
print("looking for a marker stream...")
streams = resolve_stream('name', 'AURA_Power')
#ALFA BETA GAMMA THETA x 8
# create a new inlet to read from the stream
import time
#from pyardrone import ARDrone
#print("passa")

```

```
inlet = StreamInlet(streams[0])
inlet.open_stream()
```

```
def Time_UP(bo,old=0):
    btime =datetime.datetime.now()-datetime.timedelta(seconds=10)#(days=1)
    if old<btime:
        old = datetime.datetime.now()
        bo=False
    else:
        pass
    return bo,old
```

```
#print("here")
idx =19
```

```
First =True
Abierto =[]
Abierto_AVG =0
```

```
x = input(" Dale enter")
old_day = datetime.datetime.now()
while First:
    # get a new sample (you can also omit the timestamp part if you're not
    # interested in it)
    #print("atorado")
    sample,timestamp = inlet.pull_sample()
    print("got {0}".format(sample[idx]))
    Abierto.append(sample[idx])
```

```
    First,old_day =Time_UP(bo=First,old=old_day)
Abierto_AVG = np.mean(np.asarray(Abierto))
```

```
print("end First -- avg : {0}".format(Abierto_AVG))
```

```
x = input(" Dale enter")
Second =True
Cerrado =[]
Cerrado_AVG2 =0
Cerrado2 =[]
Cerrado_AVG2 =0
old_day_2 = datetime.datetime.now()
while Second:
    # get a new sample (you can also omit the timestamp part if you're not
    # interested in it)
    sample,timestamp = inlet.pull_sample()
    print("got {0}".format(sample[idx]))
    Cerrado.append(sample[idx])
```

```

Second,old_day =Time_UP(bo=Second,old=old_day_2)

print("end Second -- avg : {0}".format(Cerrado_AVG))
Threshold = (Abierto_AVG + Cerrado_AVG ) /2

print(" Threshold : {0}".format(Threshold))

print("End experiment")
print(" FIRST AVG {0}".format(Abierto_AVG))
print(" SECOND AVG {0}".format(Cerrado_AVG))
np.save("LIMITES.npy",[Threshold])

```

### 11.3 ANEXO 3 LSL\_WRITE.PY

```

# Code made to generate BCI Compatible Syntectic Data
# Data Format Standards Obtained from http://docs.openbci.com/Hardware/03-Cyton\_Data\_Format

```

```

import os
#import serial
import time
import argparse
from time import sleep
from random import gauss
from math import sqrt, pi, sin
import struct
from pylsl import StreamInfo, StreamOutlet

freq = 250 # Hz
EOT = b'$$$' # End Of Transmission characters
BCIsettings = b'060110' # Default Channel Settings
header = b'\xA0' # OpenBCI header
footer = b'\xC0' # OpenBCI footer
numChannels = 40
uV = [0] * numChannels

# LSL Setup
info = StreamInfo('AURA_Power', 'EEG', numChannels, freq, 'float32', 'myuid01')
# append some meta-data
channels = info.desc().append_child("channels")
# for c in ["C1", "C2", "C3", "C4", "C5", "C6", "C7", "C8"]:
for i in range(numChannels):
    c = f'C{i+1}'
    channels.append_child("channel") \
        .append_child_value("label", c) \
        .append_child_value("unit", "microvolts") \
        .append_child_value("type", "EEG")
# next make an outlet
outlet = StreamOutlet(info)

```

```

# Synthetic Algorithm adapted from OpenBCI Processing Code
def synthesizeData(freq):
    sine_freq_Hz = 10
    sine_phase_rad = [0] * numChannels
    uVbytes = []
    for chan in range(numChannels):
        val_uV = gauss(0, 1) * sqrt(freq/2)
        if chan == 0:
            val_uV *= 10 # scale one channel higher

        elif chan == 1: # add sine wave at 10 Hz at 10 uVrms
            sine_phase_rad[chan] += 2*pi*sine_freq_Hz/freq
            if(sine_phase_rad[chan] > 2*pi):
                sine_phase_rad[chan] -= 2*pi
            val_uV += 10 * sqrt(2)*sin(sine_phase_rad[chan])

        elif chan == 2: # 50 Hz interference at 50 uVrms
            sine_phase_rad[chan] += 2*pi * 50 / freq # 60Hz
            if (sine_phase_rad[chan] > 2*pi):
                sine_phase_rad[chan] -= 2*pi
            val_uV += 50 * sqrt(2)*sin(sine_phase_rad[chan]) # 20 uVrms

        elif chan == 3: # 60 Hz interference at 50 uVrms
            sine_phase_rad[chan] += 2*pi * 60 / freq # 50 Hz
            if (sine_phase_rad[chan] > 2*pi):
                sine_phase_rad[chan] -= 2*pi
            val_uV += 50 * sqrt(2)*sin(sine_phase_rad[chan]) # 20 uVrms

        else:
            val_uV = 0

    val_uV *= 100
    # convert to counts, the 0.5 is to ensure rounding
    val_uV = round(0.5 + val_uV)
    byte = struct.pack(">i", val_uV)[1:]
    uVbytes.append(byte)

return uVbytes

def main(args):
    while True:
        now = time.time()
        chn8data = synthesizeData(freq)

        # Write to LSL
        for i in range(numChannels):
            uV[i] = int.from_bytes(chn8data[i], byteorder='big', signed=True)
        outlet.push_sample(uV)

    if args.log:
        print(uV)

```

```

# Time keeping for making it a true 250Hz transmission rate
while (time.time() - now) < (1/freq): # sleep(1/freq)
    continue

if __name__ == "__main__":
    parser = argparse.ArgumentParser(description='Generate EEG signals')
    parser.add_argument('-l', '--log', nargs='?',
                        const=True, default=False,
                        help="Activate logs.")

    args = parser.parse_args()
    main(args)

```

## 11.4 ANEXO 4 ITERATIVE\_GET\_DATA.PY

```

import os
import numpy as np
from matplotlib import pyplot as plt
import cv2
import scipy.stats as stats

def Get_Alpha_C3_C4(directory_name):
    directories = os.listdir(directory_name)
    my_directory_path=""
    #trial_num=0
    Trials=[]
    for directory in directories:
        #trial_num+=1
        #print("number of trials>"+str(trial_num))
        my_directory_path=directory_name+directory
        my_files=os.scandir(my_directory_path)
        for file in my_files:
            if file.name.find("FFT") != -1:
                my_directory_path=my_directory_path+'/'+file.name
                arr = np.loadtxt(my_directory_path, delimiter=",", dtype=str)

                Alpha_C3=arr[3:,18]
                Alpha_C4=arr[3:,22]
                my_trial=np.array([Alpha_C3, Alpha_C4])
                Trials.append(my_trial)

    return Trials

def Average(lst):
    total=0
    for x in lst:
        total+=float(x)

```

```

        avg=total/len(lst)
        return avg

def Get_Trial_Avg(Trials):
    Trial_Avg=[]
    for mytrial in Trials:
        Trial_Avg.append([Average(mytrial[0,:]),Average(mytrial[1,:])])
    return Trial_Avg

directory_rest='Rest/'
directory_right='Right/'
directory_left='Left/'
myTrials_right=Get_Alpha_C3_C4(directory_right)
myTrials_left=Get_Alpha_C3_C4(directory_left)

print("---Right---")
right_avg=Get_Trial_Avg(myTrials_right)
right_avg_arr=np.array(right_avg)
myrightAlphaC3=right_avg_arr[:,0]
myrightAlphaC4=right_avg_arr[:,1]

print("---Left---")
left_avg=Get_Trial_Avg(myTrials_left)
left_avg_arr=np.array(left_avg)
myleftAlphaC3=left_avg_arr[:,0]
myleftAlphaC4=left_avg_arr[:,1]

p=stats.ttest_ind(a=myrightAlphaC3, b=myleftAlphaC3, equal_var=True)
print(p)

plt.plot(myrightAlphaC3)
plt.plot(myleftAlphaC3)
plt.show()

print("finished")

```

## 11.5 ANEXO 5 CALIBRATION.PY

```

import os
import numpy as np
from matplotlib import pyplot as plt
import cv2
import scipy.stats as stats
import csv

samples_per_sec=50
seconds=3
datapoints=samples_per_sec*seconds

```

```

def Get_Alpha_C3_C4(directory_name):
    directories = os.listdir(directory_name)
    my_directory_path=""
    #trial_num=0
    Trials=[]
    for directory in directories:
        #trial_num+=1
        #print("number of trials">+str(trial_num))
        my_directory_path=directory_name+directory
        my_files=os.scandir(my_directory_path)
        for file in my_files:
            if file.name.find("FFT") != -1:
                my_directory_path=my_directory_path+'/'+file.name
                arr = np.loadtxt(my_directory_path, delimiter=",", dtype=str)

                Alpha_C3=arr[3:datapoints,18]
                Alpha_C4=arr[3:datapoints,22]
                my_trial=np.array([Alpha_C3, Alpha_C4])
                Trials.append(my_trial)

    return Trials

def Average(lst):
    total=0
    for x in lst:
        total+=float(x)
    avg=total/len(lst)
    return avg

def Get_Trial_Avg(Trials):
    Trial_Avg=[]
    for mytrial in Trials:
        Trial_Avg.append([Average(mytrial[0,:]),Average(mytrial[1,:])])
    return Trial_Avg

directory_rest='Rest/'
directory_right='Right/'
directory_left='Left/'
myTrials_right=Get_Alpha_C3_C4(directory_right)
myTrials_left=Get_Alpha_C3_C4(directory_left)

print("---Right---")
right_avg=Get_Trial_Avg(myTrials_right)
right_avg_arr=np.array(right_avg)
myrightAlphaC3=right_avg_arr[:,0]
myrightAlphaC4=right_avg_arr[:,1]

print("---Left---")
left_avg=Get_Trial_Avg(myTrials_left)
left_avg_arr=np.array(left_avg)

```

```

myleftAlphaC3=left_avg_arr[:,0]
myleftAlphaC4=left_avg_arr[:,1]

p=stats.ttest_ind(a=myrightAlphaC3, b=myleftAlphaC3, equal_var=True)
print(p)

print(myrightAlphaC3)
upper_th=Average(myleftAlphaC3)
print(upper_th)
lower_th=Average(myrightAlphaC3)

middle_th=lower_th+(upper_th-lower_th)/2

plt.plot(myrightAlphaC3)
plt.plot(myleftAlphaC3)
plt.axhline(y = lower_th, color = 'g', linestyle = '-')
plt.axhline(y = upper_th, color = 'b', linestyle = '-')
plt.axhline(y = middle_th, color = 'r', linestyle = '-')

f=open('decision_line.csv','w')
writer=csv.writer(f)
writer.writerow([middle_th])
f.close()

plt.show()
print("finished")

```

## 11.6 ANEXO 6 VREHAB\_2.PY

```

from pylsl import StreamInlet, resolve_stream
import numpy as np
import pandas as pd
import pickle
import serial
import time
from goto import with_goto
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score

arduino = serial.Serial(port='COM8', baudrate=38400, timeout=.1)

print("looking for an EEG stream...")
brain_stream = resolve_stream("name", "AURA_Power")

brain_inlet = StreamInlet(brain_stream[0])
brain_inlet.open_stream()

```

```
global sample
```

```
def write_read(x):  
    arduino.write(bytes(x, 'utf-8'))  
    time.sleep(0.05)  
    data = arduino.readline()  
    return data
```

```
def conteo():  
    print("4")  
    time.sleep(1)  
    print("3")  
    time.sleep(1)  
    print("2")  
    time.sleep(1)  
    print("1")  
    time.sleep(1)  
    print("0")  
    time.sleep(1)
```

```
@with_goto
```

```
def calibration():
```

```
    label .train
```

```
    rest_df = pd.DataFrame()  
    move_df = pd.DataFrame()
```

```
    print("RELAX TRAINING IN 5 SECONDS")
```

```
    conteo()
```

```
    ##### training rest
```

```
    timeout = True
```

```
    start = time.time()
```

```
    while timeout:
```

```
        end = time.time()
```

```
        end2 = end - start
```

```
        if(end2 > 30):
```

```
            timeout = False
```

```
        sample, timestamp = brain_inlet.pull_sample()
```

```
        print(sample)
```

```
        rest_df = pd.concat([rest_df, pd.DataFrame(sample).T])
```

```
    rest_df.reset_index()
```

```
    rest_df["Event"] = 0
```

```
    print(rest_df.shape)
```

```
    print("Entrenamiento de intencion de movimiento en 5 segundos")
```

```
    conteo()
```

```

##### training move
timeout = True

start = time.time()

while timeout:
    end = time.time()
    end2 = end - start
    if(end2 > 30):
        timeout = False

    sample, timestamp = brain_inlet.pull_sample()
    print(sample)
    move_df = pd.concat([move_df, pd.DataFrame(sample).T])

move_df.reset_index()
move_df["Event"] = 1

print("END OF TRAINING")

print("AI TRAINING INIT")
selected_data = pd.concat([rest_df,move_df])
selected_data.to_csv('full_data_personas_nuevas.csv')

X = selected_data.iloc[1:, :-1].values
y = selected_data.iloc[1:, -1].values

sc_x = StandardScaler()
X = sc_x.fit_transform(X)

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.1)

lr_model_3 = LogisticRegression()
lr_model_3.fit(X_train,y_train)
print("AI TRAINING END")
lr_y_pred_3 = lr_model_3.predict(X_test)

print("AI ACCURACY (%): ", accuracy_score(y_test,lr_y_pred_3)*100)

print("Desea continuar con el control (y) o reiniciar el entrenamiento (n)? (y / n):")
respuesta = input()

if respuesta == "y":

    label .innew
    #write_read("1")
    counter_1 = 0
    #counter_moves = 0

    while True:
        sample, timestamp = brain_inlet.pull_sample()

```

```

""if counter_moves == 6:
    write_read("0")
    counter_moves = 0
""
if counter_1 == 700:
    write_read("1")
    # write_read("1")
    # write_read("1")
    # write_read("1")
    # write_read("1")
    # write_read("1")
    # write_read("0")
    counter_1 = 0
    print("Tiempo de relajacion: 5 segundos.")
    conteo()
    break
    # counter_moves = counter_moves + 1

intention = lr_model_3.predict(sc_x.transform(pd.DataFrame(sample).values.T))
if intention == 1:
    counter_1 = counter_1 + 1
else:
    if counter_1 > 0:
        counter_1 = counter_1 - 1
    else:
        counter_1 = 0

print(counter_1)
#print(loaded_model.predict(sc.transform(pd.DataFrame(sample).values.T)))

time.sleep(5)
print("Inicia nuevamente el monitoreo")
goto .ininew

else:
    goto .train

calibration()

```

## 11.7 ANEXO 7 CÓDIGO SENSOR PIEZOELÉCTRICO DE PRESIÓN

```

// Código para Arduino
const int piezoPin = A0; // Pin analógico donde se conecta el sensor piezoeléctrico.
const int umbralBajo = 300; // Umbral para dureza baja.
const int umbralAlto = 600; // Umbral para dureza moderada.

void setup() {
    Serial.begin(9600); // Iniciar comunicación serial.

```

```
}  
  
void loop() {  
  int lectura = analogRead(piezoPin); // Leer el valor del sensor piezoeléctrico.  
  
  // Determinar la dureza y enviar el valor correspondiente.  
  if (lectura < umbralBajo) {  
    Serial.println(1); // Dureza baja.  
  } else if (lectura >= umbralBajo && lectura < umbralAlto) {  
    Serial.println(2); // Dureza moderada.  
  } else {  
    Serial.println(3); // Objeto rígido.  
  }  
  
  delay(500); // Pequeña pausa para no saturar el puerto serial.  
}
```

## 11.8 ANEXO 8 CÓDIGO M5 STACK

```
// Código para M5Stack
#include <M5Stack.h>

const int motorPin1 = 2; // Pin PWM para el motor vibrador 1.
const int motorPin2 = 5; // Pin PWM para el motor vibrador 2.

void setup() {
  M5.begin();
  Serial.begin(9600); // Iniciar comunicación serial.
  pinMode(motorPin1, OUTPUT);
  pinMode(motorPin2, OUTPUT);
}

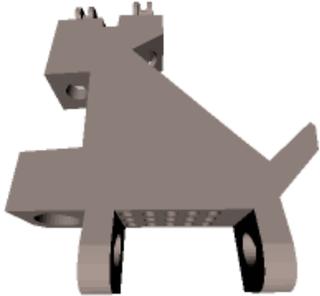
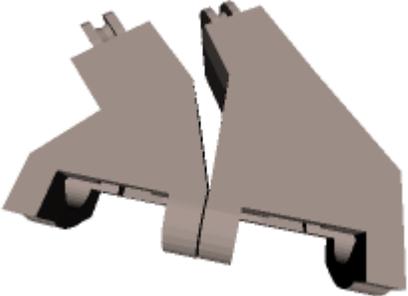
void loop() {
  if (Serial.available()) {
    int dureza = Serial.parseInt();

    switch(dureza) {
      case 1: // Dureza baja.
        analogWrite(motorPin1, 51); // 20% de 255 para una vibración suave.
        analogWrite(motorPin2, 0); // El segundo motor no vibra.
        break;
      case 2: // Dureza moderada.
        analogWrite(motorPin1, 127); // 50% de 255 para una vibración moderada.
        analogWrite(motorPin2, 51); // El segundo motor vibra suavemente.
        break;
      case 3: // Dureza alta.
        analogWrite(motorPin1, 255); // 100% de 255 para una vibración fuerte.
        analogWrite(motorPin2, 127); // 50% de 255 para una vibración moderada.
        break;
      default:
        analogWrite(motorPin1, 0); // Sin vibración si no se recibe un valor válido.
        analogWrite(motorPin2, 0);
        break;
    }
  }
}
```

## 11.9 ANEXO 9 PARTES DE DISEÑO DE MANO DEL MODELO DE MANO VERSIÓN 1 DEL ROBOT INMOOV PARA ENSAMBLAJE

Tabla VII. PARTES DE DISEÑO DE MANO DEL MODELO DE MANO VERSIÓN 1 DEL ROBOT INMOOV PARA ENSAMBLAJE

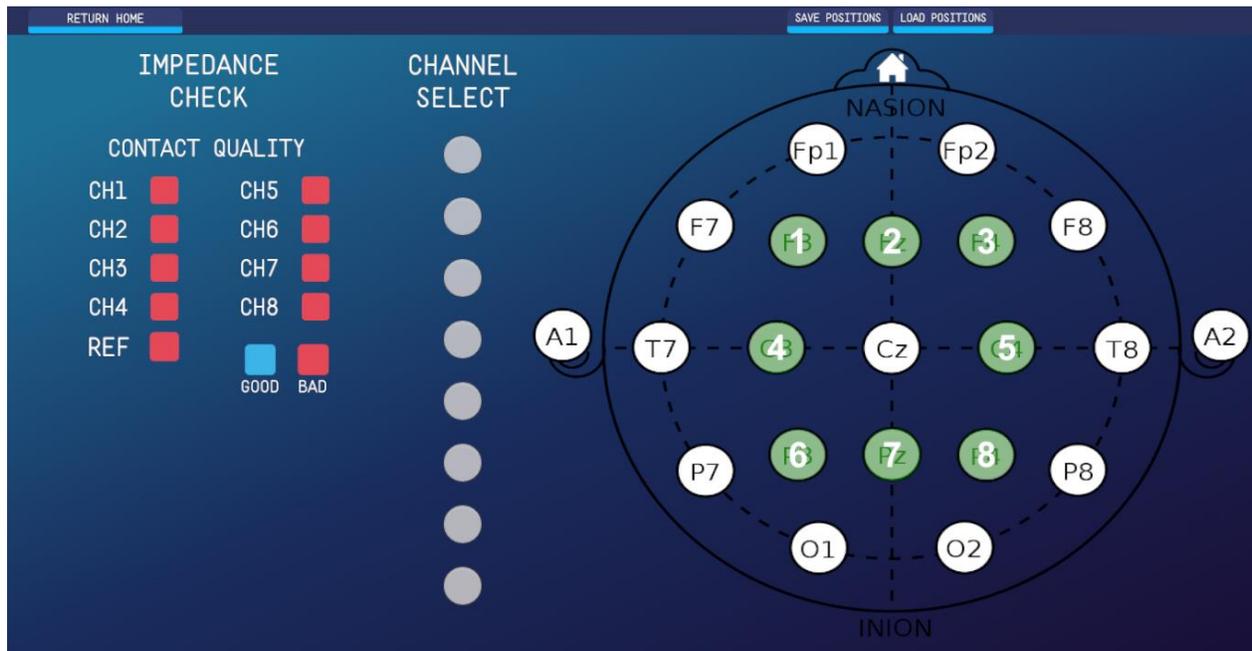
Número de pieza	Nombre de la pieza	imagen
1	Dedo meñique	
2	Dedo anular	
3	Dedo corazón o dedo del medio	
4	Dedo Índice	

5	Pulgar	
6	Palma 1	
7	Palma 2	
8	Tornillos	
9	Muñeca	

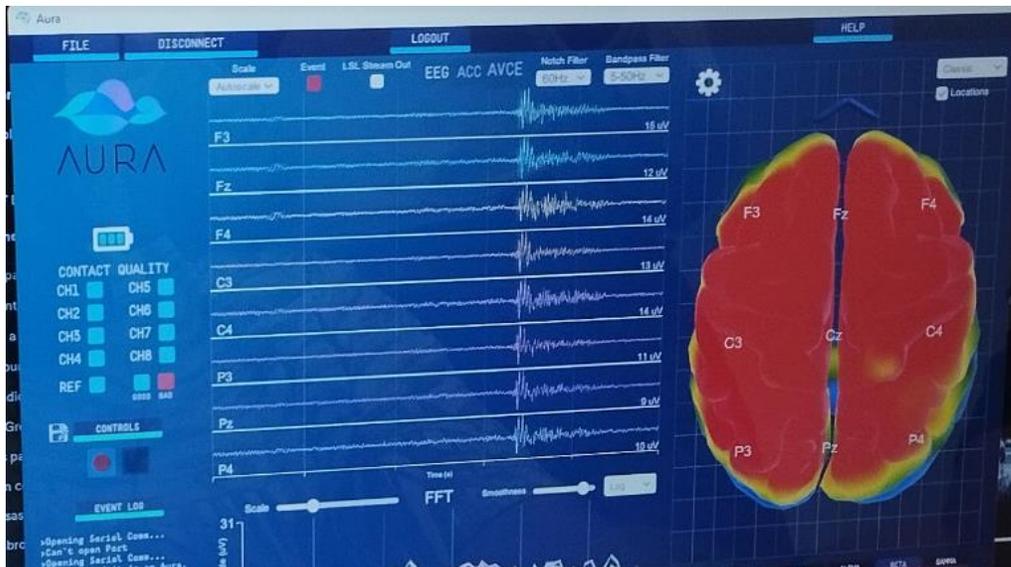
<b>10</b>	Antebrazo 1	
<b>11</b>	Antebrazo 2	
<b>12</b>	Antebrazo 3	
<b>13</b>	Antebrazo 4	



## 11.11 POSICIÓN DE ELECTRÓDOS SOFTWARE AURA



## 11.12 INTERFAZ AURA



Área de estudio: Área **CENTRAL** del cerebro en color **ROJO**