



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Instrumentación y

Control Automático

Etapa de control de un filtro para un sistema BCI

TESIS

Que como parte de los requisitos para obtener el grado de
Maestro en Ciencias en Instrumentación y Control Automático

Presenta:

Ángel Emmanuel Moreno Flores

Dirigido por:

Dr. Juvenal Rodríguez Reséndiz

Dra. Diana Carolina Toledo Pérez

Centro Universitario

Querétaro, QRO

México.

Mayo 2024

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:



Atribución — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.



NoComercial — Usted no puede hacer uso del material con [propósitos comerciales](#).



SinDerivadas — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Instrumentación y
Control Automático

Etapas de control de un filtro para un sistema BCI
TESIS

Que como parte de los requisitos para obtener el grado de
Maestro en Ciencias en Instrumentación y Control Automático

Presenta:

Ángel Emmanuel Moreno Flores

Dirigido por:

Dr. Juvenal Rodríguez Reséndiz

Dra. Diana Carolina Toledo Pérez

SINODALES

Dr. Juvenal Rodríguez Reséndiz

Presidente

Dra. Diana Carolina Toledo Pérez

Secretario

Dra. Georgina del Carmen Mota Valtierra

Vocal

Dr. Roberto Valentín Carrillo Serrano

Suplente

Dra. Luz María Sánchez Réyez

Suplente

Centro Universitario
Querétaro, QRO
México.
Mayo 2024

© 2024 - Ángel Emmanuel Moreno Flores

All rights reserved.

This thesis is dedicated to my family. Esta tesis está dedicada a mi familia.

Agradecimientos

A mi familia por su apoyo y amor incondicional, son la base de mi educación y valores, quienes me han apoyado y guiado en todas mis decisiones.

A mi novia por siempre apoyarme y estar en todo momento para mí.

A mi mejor amigo por su amistad incondicional y por siempre estar para mí.

A mis amigos que los valoro por su amistad y ayuda en todo momento y situación.

A los miembros del sínodo por sus consejos y enseñanzas, sin su ayuda, esto no hubiera sido posible.

Al profesorado y personal administrativo de la Universidad Autónoma de Querétaro.

A CONAHCYT y a la Universidad Autónoma de Querétaro por el apoyo otorgado para realizar estos estudios.

Abstract

A brain-computer interface (BCI) system is a mechanism that allows the extraction and reading of brain signals known as electroencephalographic (EEG), which are mostly used to detect mental illnesses and perform different treatments, which is why For this reason, an adaptive filter was designed that can be used after obtaining EEG signals from different BCI devices. However, because many BCI systems are used in the company of other devices to obtain parameters from other parts of the body, for example the eyes or the heart, it was important to maintain an adaptive control stage so that the filter adapts to the different results obtained with different noise levels. This work shows the design of a low-pass filter, which was implemented to the results obtained from different tests with BCI systems, with the purpose of reducing noise in the acquisition of EEG signals. by at least 40 %.

Resumen

Un sistema de interfaz cerebro-computadora (BCI) es un mecanismo que permite la extracción y lectura de las señales cerebrales conocidas como electroencefalográficas (EEG), las cuales son usadas en su mayoría de veces para detectar enfermedades mentales y realizar diferentes tratamientos, es por este motivo que se diseñó un filtro adaptativo que sea capaz de utilizarse tras obtener la señales EEG de diferentes dispositivos BCI. Sin embargo, debido a que muchos sistemas BCI son utilizados en compañía de otros dispositivos para obtener parámetros de otras partes del cuerpo, por ejemplo los ojos o el corazón. Fue importante mantener una etapa de control adaptativo para que el filtro se adecue a los diferentes resultados obtenidos con diferentes niveles de ruido. Debido a esto, en el presente trabajo se muestra el diseño de un filtro pasa-bajas, el cual se implementó a los resultados obtenidos de diferentes pruebas con los sistemas BCI, con el propósito de reducir el ruido en la adquisición de las señales EEG en un 40 %.

Índice general

Agradecimientos	I
Abstract	III
Resumen	V
Contents	VII
List of Figures	IX
List of Tables	XI
1. Introducción	1
1.1. Justificación	1
1.2. Hipótesis	3
1.3. Problemática	4
1.4. Objetivo	5
1.4.1. Objetivos específicos	5
2. Marco teórico	7
2.0.1. Sistemas BCI	7
2.0.2. Señales EEG	7
2.0.3. Filtros para señales EEG	8
2.0.4. Tipos de filtros	9
2.0.5. Ecuación matemática	27
2.0.6. Parámetro SNR	30
3. Antecedentes	31
3.0.1. Principales referencias en la literatura	33
3.0.2. Trabajos previos en la UAQ	36
3.0.3. Tabla de patentes	37
4. Metodología	39
4.0.1. Revisión del filtro pasa bajas para EEG	40
4.0.2. Identificación del sistema BCI	40
4.0.3. Parametrización y configuración del filtro seleccionado	42

4.0.4. Simulación del filtro	42
4.0.5. Implementación del filtro	43
4.0.6. Bases de datos utilizadas	46
5. Consideraciones éticas	47
6. Resultados obtenidos	49
7. Conclusión	67
References	75

Índice de figuras

1.1. Investigaciones relacionadas con señales EEG en el periodo 2012-2024.	2
1.2. Diagrama para la selección de trabajos e investigaciones utilizadas.	3
1.3. Zonas relacionadas con el error (ERN).	4
1.4. Diagrama de los objetivos particulares y entregables.	5
2.1. Ejemplo del comportamiento de las señales EEG.	8
3.1. Gráfica comparativa de las señales EEG en la literatura [1].	38
4.1. Diagrama de la metodología.	39
4.2. Diagrama de la implementación del filtro diseñado.	41
4.3. Gráficas de los resultados teóricos del filtro.	43
6.1. Gráfica de la señal EEG de la prueba 1.	50
6.2. Gráfica del espectro en frecuencia de la señal EEG de la prueba 1.	51
6.3. Gráfica de la señal EEG de la prueba 2.	52
6.4. Gráfica del espectro en frecuencia de la señal EEG de la prueba 2.	53
6.5. Gráfica de la señal EEG de la prueba 3.	54
6.6. Gráfica del espectro en frecuencia de la señal EEG de la prueba 3.	54
6.7. Gráfica de la señal EEG de la prueba 4 sin aplicar el filtrar.	55
6.8. Gráfica del espectro en frecuencia de la señal EEG de la prueba 4.	56
6.9. Gráfica de la señal EEG de la prueba 5 sin aplicar el filtrar.	57
6.10. Gráfica del espectro en frecuencia de la señal EEG de la prueba 5.	57
6.11. Gráfica de la señal EEG de la prueba 6 sin aplicar el filtrar.	58
6.12. Gráfica del espectro en frecuencia de la señal EEG de la prueba 6.	59
6.13. Gráfica de la señal EEG de la prueba 7 sin aplicar el filtrar.	60
6.14. Gráfica del espectro en frecuencia de la señal EEG de la prueba 7.	60
6.15. Gráfica de la señal EEG de la prueba 8 sin aplicar el filtrar.	61
6.16. Gráfica de la señal EEG de la prueba 9 con el filtro aplicado.	62
6.17. Gráfica de la señal EEG de la prueba 10 sin aplicar el filtrar.	63

Índice de cuadros

3.1. Cuadro de referencias de las investigaciones y publicaciones más importantes.	34
3.1. Continuación al cuadro de referencias de las investigaciones y publicaciones más importantes	35
3.2. Cuadro de las referencias de artículos e investigaciones utilizados para los antecedentes a nivel local.	36
3.3. Cuadro de patentes que utilizan señales EEG	37
6.1. Resultados obtenidos en las pruebas	64
6.2. Promedio del porcentaje del error obtenido en las pruebas	64
6.3. Margen de error de las pruebas.	65

Introducción

Esta tesis está enfocada en la mejora de la calidad de las señales electroencefalográficas (EEG), obtenidas de un sistema *brain computer interface* (BCI), creado con un kit especializado para este tipo de investigaciones y trabajos. Es importante saber que se tiene que trabajar con sistemas BCI, ya que en México, la salud mental toma relevancia legislativa, como lo menciona el diputado Jhonatan Colmenares Rentería en [2], desde el punto de vista de propuestas de modificación de ley o creación de las leyes, en la medida que se relaciona con otros temas de interés público. En este sentido, la salud mental incluye, desde trastornos discapacitantes como la esquizofrenia, depresión, obsesión-compulsión y alcoholismo, que son enfermedades neuropsiquiátricas y están entre las 10 enfermedades más discapacitantes, hasta fenómenos sociales como la corrupción, la cual, como conducta antisocial, es también materia de la salud mental. Para contribuir con esto, esta tesis se enfocó en el diseño de una etapa de control para caracterizar un filtro, con la finalidad de que el sistema BCI utilizado tenga una mejor calidad en las señales EEG extraídas. Para medir los resultados se tomó en cuenta la reducción del ruido al implementar el filtro.

Se anexa un glosario de las palabras clave utilizadas previo a la sección de introducción.

1.1. Justificación

Cuando se habla de señales EEG, existen diferentes formas de mejorar su extracción y análisis, esto se debe a que no existe un dispositivo físico o digital, que evite totalmente el ruido ocasionado por diferentes factores, ya sean externos o internos. Es por eso que las investigaciones y trabajos relacionados con las señales EEG son un tema de suma importancia. Esto se puede visualizar en la Gráfica 1.1, donde se muestra un crecimiento exponencial del número de investigaciones realizadas en las plataformas Scopus, Google académico, ResearchGate y Web of Science. Ahora bien, los trabajos relacionados con las señales EEG son de gran ayuda para diferentes áreas de la salud, como lo es la prevención de enfermedades mentales, lo cual es un problema muy importante en México, ya que, el diputado Jhonatan Colmenares Rentería [2] dice lo siguiente: “En México, el 17% de las personas presenta al menos un trastorno mental y una de cada cuatro lo padecerán al menos una vez en su vida. De las personas con algún trastorno mental, solo una de cada cinco recibe tratamiento. El mismo estudio citado sugiere que el costo de los problemas de salud mental se estima entre el 2.5% y el 4.5% del producto interno bruto. De la misma manera, del presupuesto de salud en México, solo se destina alrededor del 2% al tratamiento de la salud mental de las y los

mexicanos. Cuando la OMS recomienda que se invierta entre el 5% y el 10%. Además, de ese 2%, el 80% se emplea en la operación de los hospitales psiquiátricos, mientras que muy poco se destina a la detección, prevención y rehabilitación”. Este problema se puede combatir al tener más sistemas BCI de costos económicos y dirigidos, tanto a la prevención como tratamientos de enfermedades mentales.

No obstante, para poder hacer frente a varios factores de ruido, se han implementado diferentes métodos, tales como el uso de filtros que reducen el rango del error al obtener la señales EEG. Sin embargo, muchas veces es necesario utilizar múltiples filtros que actúen en diferentes etapas de un proceso, lo cual da como resultado una señal que sea fácil de analizar para realizar un trabajo en específico. En esta tesis, se implementó el uso de un filtro externo al sistema BCI para reducir el rango de error en el análisis de las señales EEG.




Figura 1.1: Investigaciones relacionadas con señales EEG en el periodo 2012-2024.

En la Figura 1.2 se muestra la metodología utilizada para el anexo de investigaciones y trabajos a esta tesis.

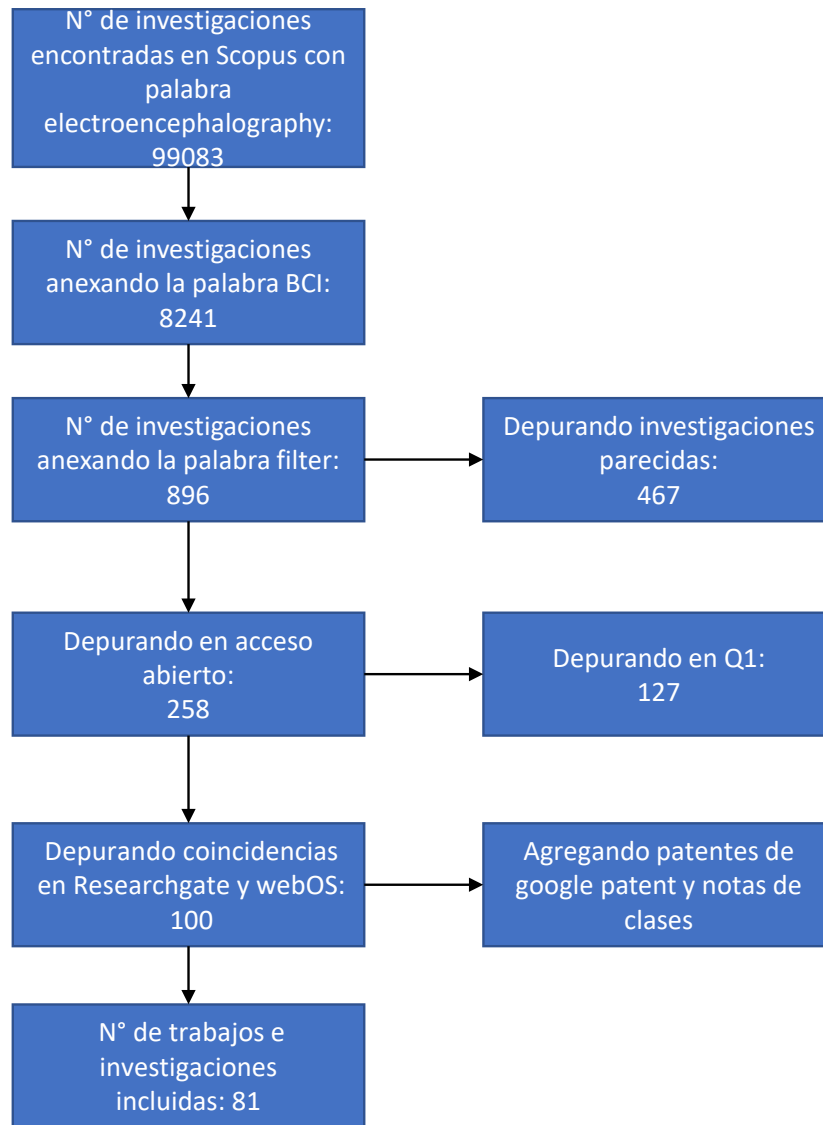


Figura 1.2: Diagrama para la selección de trabajos e investigaciones utilizadas.

1.2. Hipótesis

La hipótesis de esta tesis sostiene que la implementación de un filtro pasa bajas diseñado para la extracción de señales EEG en un sistema BCI producirá una disminución en el ruido de la señal adquirida, logrando al menos una reducción del 40% en la amplitud del ruido registrado cuando se compara con las señales EEG sin filtrar en condiciones de prueba controladas.

1.3. Problemática

Los análisis y trabajos relacionados con el problema del ruido en las señales EEG se remontan desde muchos años atrás, esto se puede ver reflejado en diversas investigaciones como la de [3], la cual habla concretamente del error e incluso presenta las zonas craneales en donde se pueden realizar mejores análisis y en donde se puede presentar más el error. En esta investigación también se muestran diferentes métodos para trabajar con el error, pero entre ellos, los más importantes vienen en la Figura 1.3, donde se muestran las zonas con mayor presencia de error de la zona craneal. No obstante, existen investigadores que trabajan desde 1996 en los diferentes tipos de error, ejemplo de esto se puede encontrar en [4], donde se muestra una investigación de como actúa el cerebro ante diferentes pruebas especializadas para generar frustración en diferentes tiempos de reacción. Este trabajo sirvió como base para que el investigador Rabbitt hiciera los trabajos vistos en [5] y [6].

No obstante, cuando se habla del análisis y la extracción de señales EEG por medio de sistemas BCI, existe un problema que siempre estará presente, el ruido. Como se ha visto en los antecedentes [7]- [8], el ruido se encuentra presente en todas las investigaciones, pero la forma de solucionar este problema es variado, algunos utilizando filtros de diferentes tipos y otros usando amplificadores. Gran cantidad de dispositivos que se encuentran en el mercado para la obtención de señales electroencefalográficas, cuentan con filtros internos, el problema de esto es que tienen un límite de rango, que muchas veces no es óptimo para diferentes trabajos o investigaciones, es por eso que al implementarse un filtro digital adicional, se puede reducir los niveles de ruido, pero para que esto pueda ser adaptado a los sistemas BCI, es crucial trabajar en la etapa de control de los filtros para su correcta adaptación.




Figura 1.3: Zonas relacionadas con el error (ERN).

1.4. Objetivo

Diseñar un filtro digital pasa bajas para la extracción de señales EEG que pueda implementarse externamente en un sistema BCI, que proporcione una disminución en el ruido de la señal adquirida en un 40 %.

1.4.1. Objetivos específicos

Los objetivos particulares con sus respectivos entregables se muestran en la Figura 1.4

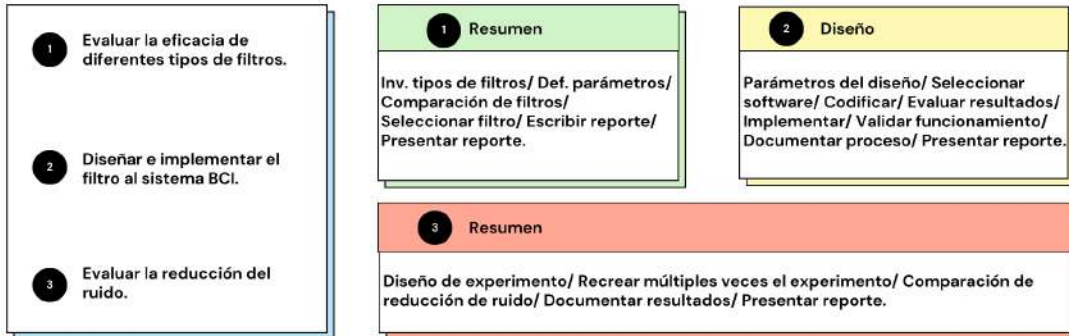


Figura 1.4: Diagrama de los objetivos particulares y entregables.

Marco teórico

En esta sección se encuentra la explicación de los temas más importantes para entender las bases de esta tesis, tales como las señales utilizadas, los sistemas utilizados, tipos de filtro, parámetro del ruido, etc.

2.0.1. Sistemas BCI

Un sistema BCI es un dispositivo con el cual se puede analizar el cerebro humano. Generalmente, este tipo de dispositivos son usados para la extracción y el análisis de las señales electroencefalográficas, las cuales se utilizan para diversos trabajos, como la detección de enfermedades mentales, el análisis del cerebro humano ante ciertas circunstancias, etc. La importancia de estos sistemas recae en su gran cantidad de usos y la gran variedad que hay de estos, el problema es que todos cuentan con la presencia del ruido, que no es más que el rango de error que tienen los sistemas al analizar las señales, pero para solucionar este problema, se lleva a cabo la implementación de filtros, tanto digitales como físicos, ya que estos son utilizados para reducir los niveles de ruido, lo cual permite que las señales obtenidas sean más fáciles de analizar [9]- [10].

2.0.2. Señales EEG

Las señales electroencefalográficas son los impulsos eléctricos con los cuales las neuronas se comunican entre sí, es por esto que dichos impulsos se encuentran todo el tiempo activos, incluso al momento en que una persona duerme. El análisis de estas señales se hace con intervalos de tiempo específicos, ya sea cuando una persona realiza una acción, sufre algún padecimiento o se encuentra en un estado de reposo, todo depende del objetivo primario de la investigación por el cual se genera el análisis de las señales EEG. Estos análisis se realizan en intervalos de tiempo para evitar la mayor presencia posible de ruido en las señales, ya que incluso un parpadeo introduce ruido y altera la señal EEG adquirida [11].

La obtención de las señales EEG permite conocer diferentes ondas cerebrales tales como: ondas delta, theta, alfa y beta, las cuales se pueden ver en la Figura 2.1 donde se muestra un ejemplo de como se comportan las ondas en diferentes estados mentales.

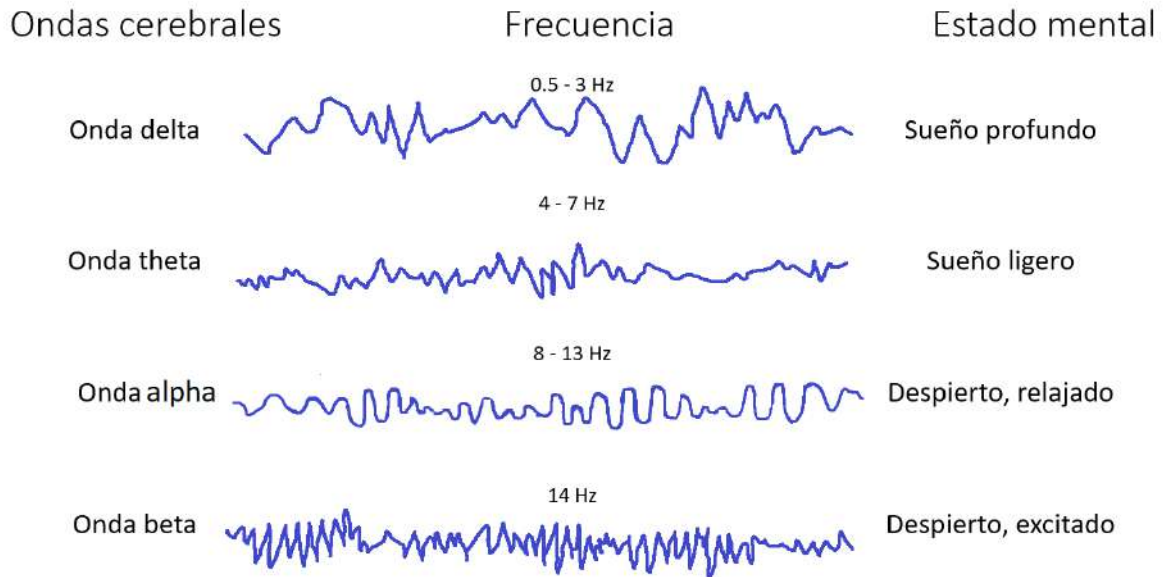


Figura 2.1: Ejemplo del comportamiento de las señales EEG.

2.0.3. Filtros para señales EEG

Un filtro es un sistema que se encarga de controlar y modificar el espectro de frecuencia de una señal de entrada, para obtener en la salida una función determinada para algún sistema más complejo o dispositivo. También, se puede ver a los filtros como un sistema conformado por dos puertos, uno de entrada y uno de salida, el cual funciona en dominio del tiempo. Los filtros se encargan de reducir o eliminar la mayor cantidad de ruido, permitiendo así que la señal EEG sea lo más limpia posible.

Los filtros se clasifican en dos tipos: activos y pasivos. Un filtro activo es considerado como tal cuando su diseño incluye amplificadores operacionales, lo cual permite la eliminación de inductancias. Además reduce el tamaño y costo de fabricación del circuito [12].

Un filtro pasivo es considerado como tal cuando sus componentes del circuito son únicamente capacitores, inductores y resistencias; la ventaja que tiene este filtro es una baja sensibilidad [12].

2.0.4. Tipos de filtros

Existen diferentes tipos de filtros derivados de los activos y pasivos, entre ellos, los más importantes son los siguientes:

- Filtro pasa-baja: permite trabajar únicamente con señales de baja frecuencia.
- Filtro pasa-altas: permite trabajar únicamente con señales de alta frecuencia.
- Filtro pasa-bandas: permite trabajar con señales de frecuencia específicas, pueden ser entre intervalos altos o bajos.

En esta tesis se hizo énfasis en los filtros pasa-baja, ya que son los más utilizados para trabajar con señales EEG por las bajas frecuencias en las que trabajan [13–16].

Las características de los filtros pasa-baja son:

- f_p Frecuencia final de la banda de paso.
- f_s Frecuencia de inicio de la banda atenuada o frecuencia de rechazo.
- R_p Rizado máximo.
- R_s Atenuación mínima

El filtro pasa-bajas permite únicamente el paso de señales de baja frecuencia, a través de su banda de paso, para poder lograrlo, evita que las frecuencias altas determinadas por f_p pasen a la salida de la banda. Los filtros pasa bajas trabajan de la siguiente manera:

- Banda de paso de $f = 0$ hasta $f = f_p$
- Banda de rechazo de $f = f_s$ hasta $f = \infty$

Existen diferentes tipos de filtros pasa-baja [17], pero al hablar de las señales EEG se pueden encontrar una gran cantidad de filtros, es por este mismo motivo que se realizó una investigación de los filtros más utilizados, lo cual dio como resultado la siguiente lista:

Filtro Pasa bajas Butterworth

Es un tipo de filtro que tiene una respuesta de amplitud plana en la banda de paso. [18]

- Ventajas

Eliminación de ruido de alta frecuencia: Los filtros pasa bajas Butterworth pueden eliminar eficazmente las frecuencias de alta frecuencia no deseadas, como el ruido eléctrico y las interferencias, que pueden contaminar las señales EEG. Esto mejora la calidad de la señal y facilita su análisis.

Diseño controlable: Puedes diseñar un filtro Butterworth para tener una frecuencia de corte específica y un orden de filtrado deseado, lo que te brinda control sobre qué frecuencias permites y cuáles atenúas. Esto es útil para adaptar el filtro a las características de la señal EEG particular que estás analizando.

- Desventajas

Atenuación de componentes de alta frecuencia: Aunque los filtros pasa bajas son efectivos para eliminar el ruido de alta frecuencia, también atenúan las componentes de frecuencia más alta de la señal EEG. Esto puede ser problemático si estás interesado en analizar patrones de frecuencia más altos en la señal, como las ondas beta y gamma, que son importantes en ciertas aplicaciones de investigación.

Requerimientos de diseño cuidadoso: Debes diseñar cuidadosamente el filtro Butterworth para asegurarte de que la frecuencia de corte y el orden del filtro sean apropiados para tus necesidades. Un diseño inadecuado puede resultar en una distorsión no deseada de la señal.

Posibilidad de artefactos de fase: Los filtros Butterworth pueden introducir artefactos de fase, lo que significa que las diferentes componentes de la señal pueden tener diferentes retardos temporales después de pasar por el filtro. Esto puede ser problemático en aplicaciones donde se requiere una alta precisión en la sincronización temporal de las señales EEG.

Filtro Pasa bajas Chebyshev

Tiene una respuesta de amplitud más nítida que el filtro Butterworth, pero con ondulaciones en la banda de paso [18].

- **Ventajas**

Mayor selectividad: Uno de los principales beneficios de los filtros pasa bajas Chebyshev es su mayor selectividad en comparación con los filtros Butterworth. Los filtros Chebyshev pueden proporcionar una atenuación más rápida de las frecuencias no deseadas en la banda de rechazo, lo que es útil cuando se necesita un alto nivel de supresión de frecuencias no deseadas, como el ruido eléctrico.

Control de la frecuencia de corte y la atenuación: Los filtros Chebyshev permiten un control preciso de la frecuencia de corte y la cantidad de atenuación en la banda de rechazo. Esto es beneficioso cuando se requiere un ajuste fino de los parámetros de filtrado para adaptarse a las características específicas de la señal EEG que se está analizando.

Eficiencia en el dominio de la frecuencia: Los filtros Chebyshev son eficientes en términos de recursos computacionales y de hardware, lo que los hace adecuados para aplicaciones en tiempo real, como la monitorización continua de señales EEG.

- **Desventajas**

Distorsión de fase: Los filtros Chebyshev pueden introducir distorsiones de fase en la señal de salida, especialmente en las frecuencias cercanas a la frecuencia de corte. Esto puede ser problemático en aplicaciones donde la precisión de la sincronización temporal es crítica, como en el análisis de eventos EEG específicos.

Dificultad en el diseño: El diseño de un filtro Chebyshev puede ser más complicado en comparación con un filtro Butterworth debido a la necesidad de ajustar parámetros como la cantidad de rizado permitido en la banda de paso y la atenuación en la banda de rechazo. Esto requiere un conocimiento más profundo de la teoría de filtros.

No es ideal para todas las aplicaciones: Aunque los filtros Chebyshev son excelentes para suprimir frecuencias no deseadas, no son ideales para todas las aplicaciones de EEG. Pueden ser excesivamente selectivos en algunos casos, lo que resulta en una pérdida de información en ciertas frecuencias de interés.

Filtro Pasa bajas Bessel

Ofrece una respuesta de fase lineal en la banda de paso, lo que lo hace adecuado para aplicaciones de audio y comunicaciones [19].

- Ventajas

Respuesta de fase lineal: La principal ventaja de los filtros pasa bajas Bessel es que proporcionan una respuesta de fase lineal en la banda de paso. Esto significa que todas las componentes de frecuencia de la señal de entrada se retrasan de manera uniforme en el tiempo, lo que preserva la sincronización temporal de las señales EEG. Esta característica es especialmente importante en aplicaciones donde la precisión temporal es crítica, como el análisis de eventos EEG.

Atenuación suave fuera de la banda de paso: Los filtros Bessel ofrecen una atenuación suave de las frecuencias fuera de la banda de paso. Esto es beneficioso para preservar las componentes de baja frecuencia de la señal y minimizar la distorsión de estas componentes, lo que puede ser importante en el análisis de señales EEG.

Mínima distorsión en el dominio del tiempo: Debido a su respuesta de fase lineal, los filtros Bessel introducen una distorsión mínima en el dominio del tiempo. Esto es crucial para preservar la forma de onda original de la señal EEG y garantizar que los eventos se registren con precisión en el tiempo.

- Desventajas

Menor selectividad: Los filtros Bessel no son tan selectivos como los filtros Chebyshev en términos de supresión de frecuencias no deseadas en la banda de rechazo. Esto puede ser una desventaja en situaciones donde se necesita una alta selectividad para eliminar ruido no deseado.

Necesita más etapas para alcanzar una alta atenuación: Para lograr una alta atenuación de frecuencias no deseadas, a menudo se requiere el uso de múltiples etapas de filtros Bessel en cascada, lo que puede aumentar la complejidad del diseño.

No es adecuado para todas las aplicaciones: Los filtros Bessel son más adecuados para aplicaciones en las que la preservación de la fase y la sincronización temporal son críticas, pero pueden no ser la mejor elección si se necesita una alta supresión de frecuencias no deseadas.

Filtro Pasa bajas Cauer (Elíptico)

Tiene una respuesta de amplitud más aguda que los filtros Chebyshev, pero puede tener ondulaciones tanto en la banda de paso como en la de paro [20].

- Ventajas

Alta selectividad: Los filtros elípticos son conocidos por ofrecer una alta selectividad tanto en la banda de paso como en la banda de rechazo. Esto significa que pueden suprimir eficazmente las frecuencias no deseadas tanto por encima como por debajo de la banda de interés, lo que puede ser útil para eliminar el ruido eléctrico y otras interferencias.

Transición abrupta entre la banda de paso y la banda de rechazo: Los filtros elípticos tienen una transición muy pronunciada entre la banda de paso y la banda de rechazo. Esto permite una separación clara entre las frecuencias de interés y las frecuencias no deseadas, lo que puede ser beneficioso en aplicaciones donde se necesita una alta supresión de ruido.

Eficiencia en el uso del ancho de banda: Los filtros elípticos pueden proporcionar una alta atenuación de las frecuencias no deseadas sin desperdiciar ancho de banda en la banda de paso. Esto es útil cuando se necesita maximizar la eficiencia espectral en aplicaciones de EEG.

- Desventajas

Distorsión de fase: Los filtros elípticos pueden introducir distorsiones de fase en la señal de salida, especialmente en las frecuencias cercanas a la frecuencia de corte. Esto puede ser problemático en aplicaciones donde la sincronización temporal precisa de las señales EEG es crítica.

Dificultad de diseño: El diseño de un filtro elíptico puede ser más complicado en comparación con otros tipos de filtros, como los Butterworth. Requiere ajustar múltiples parámetros, como la cantidad de rizado en la banda de paso y la atenuación en la banda de rechazo, lo que puede requerir conocimientos más avanzados en teoría de filtros.

Mayor orden del filtro: Para lograr una alta selectividad, los filtros elípticos suelen requerir un orden de filtro más alto en comparación con otros tipos de filtros, lo que puede aumentar la complejidad y los requisitos de procesamiento.

Filtro Pasa bajas FIR (Respuesta al Impulso Finita)

Los filtros FIR son implementados utilizando una respuesta al impulso finita y pueden diseñarse para tener características pasa bajas [21].

- Ventajas

Linealidad: Los filtros FIR son inherentemente lineales, lo que significa que no introducirán distorsiones no lineales en la señal de EEG. Esto es importante en aplicaciones donde la linealidad es esencial.

Flexibilidad de diseño: Se pueden diseñar filtros FIR con una amplia variedad de características de respuesta de frecuencia según las necesidades requeridas. Esto permite adaptar el filtro a las características específicas de la señal EEG que se desea preservar o suprimir.

Fácil implementación: Los filtros FIR se pueden implementar de manera eficiente y sencilla en hardware digital y software. Esto es beneficioso para aplicaciones en tiempo real y procesamiento de señales en tiempo real.

Respuesta de fase ajustable: Se puede diseñar filtros FIR con una respuesta de fase ajustable, lo que permite controlar la fase de la señal en función a las necesidades requeridas. Esto puede ser útil en aplicaciones donde se requiere una sincronización precisa de eventos en el tiempo.

- Desventajas

Mayor orden del filtro: Para lograr características de filtrado específicas, los filtros FIR a menudo requieren un orden (tamaño del filtro) mayor en comparación con algunos filtros IIR (Infinite Impulse Response) como los Butterworth. Un mayor orden del filtro puede aumentar los requisitos computacionales y de memoria.

Transición más lenta entre la banda de paso y la banda de rechazo: Los filtros FIR pueden tener una transición más lenta entre la banda de paso y la banda de rechazo en comparación con los filtros elípticos o Chebyshev. Esto significa que pueden no ser tan eficientes en la supresión de frecuencias no deseadas en aplicaciones donde se necesita una alta selectividad.

Mayor latencia: Debido a su naturaleza de respuesta al impulso finita, los filtros FIR pueden introducir una cierta cantidad de latencia en la señal de salida, especialmente en filtros de orden elevado. Esto puede ser problemático en aplicaciones donde se requiere una respuesta en tiempo real.

Filtro Pasa bajas de Media Móvil

Utilizado en el procesamiento de señales y series temporales para suavizar la señal y eliminar el ruido [22].

- Ventajas

Sencillez de implementación: Los filtros de media móvil son fáciles de implementar y comprender. Utilizan una técnica simple de promediado de muestras, lo que los hace adecuados para aplicaciones en las que la simplicidad es prioritaria.

Baja latencia: Debido a su simplicidad y procesamiento directo de muestras, los filtros de media móvil tienden a tener una latencia muy baja, lo que los hace apropiados para aplicaciones que requieren una respuesta en tiempo real.

Reducción de ruido de alta frecuencia: Los filtros de media móvil pueden ser efectivos para suavizar o reducir el ruido de alta frecuencia en las señales EEG, lo que puede mejorar la calidad de la señal para ciertas aplicaciones.

- Desventajas

Transición suave: Los filtros de media móvil tienen una transición de frecuencia relativamente suave entre la banda de paso y la banda de rechazo. Esto significa que no son ideales para aplicaciones que requieren una supresión precisa y rápida de frecuencias no deseadas.

Pérdida de información de alta frecuencia: Dado que los filtros de media móvil suavizan la señal, pueden eliminar información de alta frecuencia que puede ser relevante para ciertas aplicaciones de EEG, como la detección de eventos cerebrales de alta frecuencia.

Requisitos de orden: Para lograr una supresión de frecuencia no deseada más efectiva, los filtros de media móvil pueden requerir un orden (número de puntos de muestra) más alto, lo que puede aumentar los requisitos computacionales.

No son ideales para todas las aplicaciones: Los filtros de media móvil son adecuados para aplicaciones de suavizado y eliminación de ruido de alta frecuencia, pero pueden no ser la mejor opción para aplicaciones que requieren una respuesta de frecuencia precisa y una supresión selectiva de frecuencias no deseadas.

Filtro Pasa bajas Exponencial

A menudo se utiliza en el procesamiento de imágenes para suavizar la imagen y reducir el ruido [23].

- Ventajas

Respuesta de frecuencia ajustable: Los filtros pasa bajas exponenciales permiten ajustar la constante de tiempo de decaimiento (τ) para adaptarse a las necesidades específicas del filtrado. Esto permite controlar cómo se suaviza la señal y cuánto énfasis se pone en las muestras más recientes en comparación con las anteriores.

Baja latencia: Los filtros exponenciales de media móvil tienen una latencia muy baja debido a su procesamiento en tiempo real y a la ponderación de las muestras más recientes. Esto los hace adecuados para aplicaciones que requieren una respuesta rápida.

Adecuados para seguimiento de tendencias: Los filtros exponenciales son efectivos para seguir tendencias en las señales EEG y eliminar componentes de alta frecuencia no deseados, lo que puede ser útil en aplicaciones donde se necesita un filtrado suave y adaptativo.

- Desventajas

No son ideales para supresión selectiva de frecuencias: Los filtros exponenciales no son eficaces para la supresión selectiva de frecuencias no deseadas en la señal EEG. No son adecuados si se requiere una alta selectividad de frecuencia.

Pérdida de información de alta frecuencia: Debido a su naturaleza de suavizado, los filtros exponenciales pueden eliminar información de alta frecuencia de la señal EEG, lo que puede ser problemático en aplicaciones que dependen de esta información.

Dependencia de la constante de tiempo: La elección de la constante de tiempo (τ) es crítica en los filtros exponenciales, y elegir el valor incorrecto puede dar como resultado una pérdida de información o una supresión inadecuada de las componentes de la señal.

Mayor complejidad de implementación: La implementación de filtros exponenciales puede ser más compleja que la de filtros FIR simples, ya que implica el cálculo de una constante de tiempo y la actualización de la salida en tiempo real.

Filtro Paso Banda (Band-Pass Filter)

Ayuda a aislar las bandas de frecuencia específicas asociadas con eventos cerebrales de interés, como las ondas alfa (8-13 Hz) o beta (13-30 Hz) [18, 24, 25].

- Ventajas

Selección de banda de frecuencia: Los filtros paso banda permiten seleccionar una banda específica de frecuencias de interés en las señales EEG. Esto es útil cuando se desea enfocar un rango de frecuencia particular, como las ondas alfa (8-13 Hz) o las ondas beta (13-30 Hz).

Supresión de ruido fuera de la banda de interés: Los filtros paso banda atenúan eficazmente las frecuencias fuera de la banda de interés, lo que ayuda a reducir el ruido de frecuencias no deseadas y las interferencias de señales eléctricas ambientales.

Mayor selectividad: Los filtros paso banda ofrecen una mayor selectividad en comparación con los filtros pasa bajas o pasa altos, lo que permite un mejor aislamiento de la actividad cerebral en la banda de frecuencia de interés.

Aplicaciones específicas: Los filtros paso banda son esenciales para muchas aplicaciones en EEG, como la detección de eventos cerebrales específicos, el análisis de potencia en bandas de frecuencia particulares y la identificación de patrones característicos de diferentes estados mentales.

- Desventajas

Mayor complejidad de diseño: El diseño de un filtro paso banda puede ser más complicado que el de filtros pasa bajas o pasa altos, ya que requiere especificar con precisión la banda de frecuencia de interés y los límites de atenuación fuera de la banda.

Posible distorsión de fase: Algunos filtros paso banda pueden introducir distorsiones de fase en la señal de salida, lo que puede ser problemático en aplicaciones que requieren una sincronización temporal precisa de los eventos EEG.

Requisitos de orden: La efectividad de un filtro paso banda puede depender del orden del filtro, que a menudo debe ser mayor para lograr una alta selectividad en la banda de frecuencia de interés.

Limitaciones en la adaptabilidad: Una vez que se ha diseñado un filtro paso banda para una banda de frecuencia específica, no es fácilmente adaptable a otras bandas de frecuencia sin rediseñar el filtro.

Filtro Notch (Filtro de Rechazo de Frecuencia)

Se utiliza para eliminar interferencias de frecuencia específicas, como la línea de alimentación de 50 Hz o 60 Hz [26–28].

- Ventajas

Supresión precisa de frecuencias específicas: Los filtros Notch son altamente efectivos para suprimir o eliminar una frecuencia específica en la señal EEG. Esto es especialmente útil cuando se desea eliminar una interferencia de frecuencia conocida, como una línea de corriente eléctrica de 50 Hz o 60 Hz.

Preservación de otras frecuencias: A diferencia de algunos otros filtros que pueden afectar a toda la señal, los filtros Notch se centran en una frecuencia particular y no afectan significativamente a otras frecuencias de la señal EEG. Esto permite mantener intactas las componentes de frecuencia de interés.

Reducción del ruido eléctrico: Los filtros Notch son eficaces para reducir el ruido eléctrico y las interferencias de frecuencia de la línea de corriente, que a menudo contaminan las señales EEG recogidas en entornos eléctricos.

- Desventajas

Selección de frecuencia crítica: Los filtros Notch deben configurarse con precisión en la frecuencia exacta de la interferencia que se desea eliminar. Si la frecuencia de la interferencia cambia o si hay múltiples fuentes de interferencia, el filtro Notch puede no ser tan efectivo.

Posible distorsión de fase: Los filtros Notch pueden introducir distorsión de fase en la señal de salida, lo que puede ser problemático si se necesita una sincronización temporal precisa en las aplicaciones EEG.

Requisitos de diseño y ajuste: Configurar correctamente un filtro Notch requiere conocimientos específicos para elegir la frecuencia de rechazo adecuada y garantizar que se alcance la supresión deseada sin afectar negativamente las frecuencias circundantes.

Interferencias cercanas: Si se tiene múltiples frecuencias cercanas que deben eliminarse, la implementación de varios filtros Notch puede ser complicada y puede introducir problemas adicionales.

Filtro Espacial (Spatial Filter)

Ayuda a mejorar la selectividad de las señales EEG al enfocarse en regiones de interés específicas en el cerebro [29–33].

- Ventajas

Separación de fuentes: Los filtros espaciales permiten separar las señales de diferentes fuentes cerebrales o regiones del cerebro. Esto es valioso en aplicaciones donde se desea aislar la actividad de una región específica para su análisis.

Reducción de ruido y artefactos: Los filtros espaciales pueden ayudar a reducir la contaminación de señales no deseadas o artefactos de otras áreas del cerebro o fuentes externas. Esto mejora la calidad de la señal EEG.

Enfoque en regiones de interés: Si se está interesado en analizar una región cerebral específica, como el córtex motor o el lóbulo frontal, los filtros espaciales permiten enfocarse selectivamente en esa área, lo que puede ser útil en investigaciones y diagnósticos específicos.

Adaptabilidad: Los filtros espaciales se pueden adaptar para enfocarse en diferentes regiones o cambiar el enfoque según sea necesario, lo que brinda flexibilidad en el análisis de EEG.

- Desventajas

Requiere información adicional: La implementación efectiva de filtros espaciales generalmente requiere información adicional, como la ubicación de electrodos en el cuero cabelludo o una matriz de mezcla de fuentes. Esto puede agregar complejidad al proceso de análisis.

Necesidad de conocimiento especializado: El diseño y la implementación de filtros espaciales pueden requerir un conocimiento especializado en EEG y procesamiento de señales. Esto puede limitar su uso en entornos donde no se dispone de experiencia en este campo. Potencial de sobre ajuste: Si no se configuran y utilizan correctamente, los filtros espaciales pueden sobre ajustarse o introducir sesgos en el análisis de señales EEG.

No es adecuado para todas las aplicaciones: Los filtros espaciales son más adecuados para aplicaciones específicas que requieren el aislamiento de fuentes o regiones específicas.

Filtro Adaptativo (Adaptive Filter)

Utilizado para eliminar artefactos y ruido en tiempo real, ajustándose automáticamente a las condiciones cambiantes de la señal EEG [34–38].

- Ventajas

Adaptabilidad: Los filtros adaptativos se ajustan automáticamente a las variaciones en la señal EEG o a las condiciones del entorno. Esto los hace efectivos en aplicaciones donde las características de la señal cambian con el tiempo.

Reducción de ruido: Los filtros adaptativos pueden reducir eficazmente el ruido y las interferencias en las señales EEG, lo que mejora la calidad de la señal y facilita el análisis.

Supresión de artefactos: Los filtros adaptativos son útiles para suprimir artefactos de señales EEG, como los generados por movimientos oculares y musculares, lo que permite obtener registros más limpios.

Amplia gama de aplicaciones: Los filtros adaptativos se utilizan en una variedad de aplicaciones, como la mejora de la resolución espacial en EEG de alta densidad, la eliminación de artefactos y la adaptación a cambios en las condiciones de registro.

- Desventajas

Requiere configuración y entrenamiento: Los filtros adaptativos a menudo requieren una configuración y entrenamiento adecuados para funcionar de manera efectiva. Esto puede implicar ajustar parámetros y recopilar datos de referencia.

Mayor complejidad computacional: Los filtros adaptativos suelen ser más computacionalmente intensivos en comparación con otros filtros, lo que puede requerir hardware más potente para su implementación en tiempo real.

Potencial de sobre ajuste: Si no se configuran adecuadamente, los filtros adaptativos pueden sobre ajustarse a la señal y eliminar información importante.

Requiere experiencia técnica: La implementación y configuración efectivas de filtros adaptativos a menudo requieren experiencia técnica en procesamiento de señales y EEG.

Filtro de Supresión de Artefactos (Artifact Suppression Filter)

Diseñado específicamente para reducir artefactos de movimiento o parpadeo en las señales EEG [39].

- Ventajas

Mejora la calidad de las señales EEG: Los filtros de supresión de artefactos pueden mejorar significativamente la calidad de las señales EEG al eliminar o reducir artefactos no deseados, lo que facilita el análisis de las señales cerebrales.

Reducción de interferencia: Estos filtros son efectivos para reducir la interferencia de señales no cerebrales, como el ruido muscular y los movimientos oculares, que son comunes en las grabaciones EEG.

Preservación de la información cerebral: Los filtros de supresión de artefactos están diseñados para minimizar el impacto en las señales cerebrales de interés, lo que permite analizar la actividad cerebral genuina.

Mejora de la reproducibilidad: Al eliminar artefactos, los filtros de supresión de artefactos ayudan a mejorar la reproducibilidad de los resultados en investigaciones y análisis clínicos.

- Desventajas

Configuración y adaptación: Los filtros de supresión de artefactos suelen requerir una configuración y adaptación específicas para el tipo de artefacto que se desea eliminar. Esto puede ser un proceso complejo y puede requerir un conocimiento detallado de las características del artefacto.

Potencial de pérdida de información: Si los filtros de supresión de artefactos se configuran de manera incorrecta o demasiado agresiva, pueden eliminar información de las señales EEG que es relevante para el análisis.

Necesidad de datos de referencia: En muchos casos, se necesita disponer de datos de referencia o señales de artefactos independientes para configurar y entrenar adecuadamente los filtros de supresión de artefactos.

Posible introducción de artefactos residuales: A pesar de los esfuerzos por suprimir artefactos, en algunas ocasiones pueden quedar artefactos residuales en las señales EEG, especialmente si los artefactos son muy similares en características a las señales cerebrales.

Filtros Espacio-Tiempo (Space-Time Filters)

Utilizados en técnicas avanzadas de procesamiento de señales EEG, como la descomposición en componentes independientes (ICA) y el análisis de fuentes espaciales [40–43].

- Ventajas

Mejora la separación de fuentes: Los filtros espacio-tiempo pueden separar con mayor precisión las fuentes de señales EEG, lo que permite analizar las actividades cerebrales de manera más selectiva.

Reducción de la interferencia espacial: Estos filtros son efectivos para reducir la interferencia espacial, como la actividad muscular y los artefactos de fuentes cercanas, lo que mejora la calidad de las señales EEG.

Adaptación a variaciones temporales: Los filtros espacio-tiempo pueden adaptarse a las variaciones temporales en la actividad cerebral y las fuentes de interferencia, lo que los hace útiles en situaciones donde las condiciones cambian con el tiempo.

Mejora de la resolución espacial: Estos filtros pueden mejorar la resolución espacial de las grabaciones EEG, permitiendo una mejor identificación de las fuentes cerebrales y sus ubicaciones.

- Desventajas

Mayor complejidad de diseño: Los filtros espacio-tiempo son más complejos de diseñar e implementar en comparación con técnicas de filtrado más simples.

Requieren un conocimiento especializado en procesamiento de señales y EEG.

Mayor procesamiento computacional: La implementación de filtros espacio-tiempo puede ser más computacionalmente intensiva, lo que puede requerir hardware más potente para su uso en tiempo real.

Necesidad de datos de referencia: A menudo, se requieren datos de referencia o modelos específicos para entrenar y ajustar correctamente los filtros espacio-tiempo.

Sensibilidad a variaciones de ruido: Si los filtros espacio-tiempo no se configuran adecuadamente o si las condiciones de grabación cambian significativamente, pueden ser sensibles a variaciones de ruido y artefactos.

A continuación se muestran los filtros que cuentan con amplificadores operacionales:

Filtro Paso Bajo Activo

Se utiliza para eliminar componentes de alta frecuencia y ruido de las señales EEG.

Filtro Paso Alto Activo

Ayuda a eliminar las componentes de baja frecuencia, como las derivadas de la actividad cardíaca y los artefactos de movimiento.

Filtro Pasa Banda Activo

Utilizado para resaltar o aislar bandas de frecuencia específicas en las señales EEG, como las bandas alfa (8-13 Hz) o beta (13-30 Hz).

Filtro Notch Activo

Elimina interferencias de frecuencia específicas, como la línea de alimentación de 50 Hz o 60 Hz.

Filtro Sallen-Key Activo de Segundo Orden

Puede utilizarse para diseñar filtros de mayor orden que satisfagan requisitos específicos de atenuación y respuesta de fase.

Filtro de Supresión de Artefactos

Diseñado específicamente para eliminar artefactos de movimiento, parpadeo u otros artefactos no deseados en las señales EEG.

A continuación se muestra las ventajas y desventajas generales de todos los filtros con amplificadores operacionales [12, 18, 44–47].

■ Ventajas

Flexibilidad de diseño: Los filtros con amplificadores operacionales permiten un alto grado de flexibilidad en el diseño. Permite ajustar y personalizar fácilmente la frecuencia de corte, la ganancia y la respuesta de frecuencia según las necesidades específicas.

Amplificación integrada: Al combinar un filtro con un amplificador operacional, estos circuitos pueden amplificar la señal de interés al mismo tiempo que aplican el filtrado. Esto es útil cuando se necesita tanto filtrar como amplificar una señal.

Reducción de ruido: Los amplificadores operacionales suelen tener una relación señal-ruido (SNR) alta, lo que ayuda a mantener la calidad de la señal incluso después de la amplificación.

Impedancia de entrada alta: Los amplificadores operacionales a menudo tienen una impedancia de entrada alta, lo que significa que no cargan significativamente la fuente de señal, evitando así la pérdida de amplitud.

■ Desventajas

Requieren alimentación: Los amplificadores operacionales y, por lo tanto, los filtros que los utilizan, requieren una fuente de alimentación. Esto puede ser una desventaja en aplicaciones donde la eficiencia energética o la portabilidad son críticas.

Costo potencialmente más alto: Los amplificadores operacionales de alta calidad pueden ser costosos, lo que puede aumentar el costo de implementación de estos filtros en comparación con soluciones más simples.

Mayor complejidad de diseño: Los circuitos con amplificadores operacionales pueden ser más complicados de diseñar e implementar en comparación con filtros pasivos, especialmente si se necesitan configuraciones más avanzadas.

Sensibilidad a la alimentación y componentes: Los amplificadores operacionales y los filtros que los utilizan pueden ser sensibles a fluctuaciones en la fuente de alimentación y a variaciones en los valores de los componentes, lo que puede requerir una calibración y supervisión adecuadas.

Ruido inherente: Aunque los amplificadores operacionales pueden tener una relación señal-ruido alta, también pueden introducir ruido inherente en la señal si no se diseñan o se utilizan adecuadamente.

Filtros digitales

Existen una infinidad de filtros aplicados digitalmente, comúnmente se utilizan programas matemáticos para reducir el ruido en los sistemas BCI [47–51], pero los más utilizados son:

EEGLAB

EEGLAB es una popular caja de herramientas de MATLAB que se utiliza para el análisis de señales EEG, incluyendo filtrado, eliminación de artefactos, análisis espectral y descomposición en componentes independientes (ICA) [52].

- Ventajas

Interfaz amigable: EEGLAB ofrece una interfaz gráfica de usuario (GUI) intuitiva que facilita la manipulación y visualización de datos EEG, incluyendo las operaciones de filtrado.

Amplia gama de filtros: EEGLAB proporciona una variedad de opciones de filtrado, que incluyen filtros pasa bajo, pasa alto, pasa banda y rechazo de frecuencia (notch), lo que permite a los usuarios elegir el filtro adecuado para sus necesidades de procesamiento.

Personalización: Los usuarios pueden personalizar los parámetros de filtrado según sus requisitos específicos, lo que brinda un alto grado de flexibilidad en el proceso de filtrado.

Integración con MATLAB: EEGLAB se integra bien con MATLAB, lo que permite a los usuarios aprovechar las capacidades de programación y análisis personalizado que ofrece MATLAB.

Comunidad activa: EEGLAB cuenta con una comunidad activa de usuarios y desarrolladores que brindan soporte técnico y contribuyen con extensiones y plugins que mejoran sus capacidades.

- Desventajas

Curva de aprendizaje: Aunque EEGLAB es ampliamente utilizado, su aprendizaje puede requerir tiempo, especialmente para usuarios nuevos en el procesamiento de señales EEG y en la interfaz de MATLAB.

Necesita MATLAB: Para usar EEGLAB, es necesario tener acceso a MATLAB, que es un software comercial. Esto puede ser un costo adicional para algunos usuarios.

Requisitos de hardware: El procesamiento de señales EEG en EEGLAB puede ser computacionalmente intensivo, lo que puede requerir hardware adecuado, especialmente para conjuntos de datos grandes o análisis complejos.

Sensibilidad a parámetros: La configuración incorrecta de los parámetros de filtrado en EEGLAB puede llevar a resultados no deseados o distorsiones en las señales EEG. Se requiere experiencia para utilizarlo de manera efectiva.

Compatibilidad de datos: No todos los tipos de datos EEG pueden ser adecuadamente procesados en EEGLAB, y puede requerir adaptaciones o ajustes específicos dependiendo de la naturaleza de los datos.

FieldTrip

FieldTrip es una caja de herramientas de MATLAB/Octave diseñada específicamente para el análisis de señales EEG y MEG (magnetoencefalografía). Ofrece una amplia gama de funciones para el procesamiento y el análisis de datos EEG [53].

- Ventajas

Flexibilidad: FieldTrip es altamente flexible y se puede personalizar para adaptarse a una amplia variedad de análisis de señales EEG. Permite a los usuarios implementar análisis específicos y flujos de trabajo personalizados.

Amplia funcionalidad: FieldTrip ofrece una amplia gama de herramientas para el análisis de señales EEG, incluyendo filtrado, análisis de conectividad, análisis de componentes independientes (ICA), estadísticas y visualización.

Integración de datos multimodales: FieldTrip es adecuado para el análisis de datos multimodales, lo que significa que puede manejar simultáneamente datos EEG, MEG y otros tipos de datos de neuroimagen, lo que es útil en investigaciones que combinan múltiples modalidades.

Comunidad activa: FieldTrip tiene una comunidad activa de usuarios y desarrolladores que proporcionan soporte técnico, comparten scripts y contribuyen con actualizaciones y mejoras.

Documentación extensa: FieldTrip cuenta con una documentación extensa y tutoriales que ayudan a los usuarios a aprender a utilizar eficazmente la herramienta y comprender los conceptos detrás del análisis de señales EEG.

- Desventajas

Curva de aprendizaje: FieldTrip, al igual que MATLAB en general, puede tener una curva de aprendizaje pronunciada para usuarios que no están familiarizados con la programación en MATLAB o el análisis de señales EEG.

Requisitos de hardware: El análisis de señales EEG en FieldTrip puede ser computacionalmente intensivo, lo que puede requerir hardware potente, especialmente para conjuntos de datos grandes o análisis complejos.

Necesidad de MATLAB: FieldTrip se ejecuta en MATLAB, que es un software comercial, por lo que los usuarios deben tener acceso a MATLAB para utilizar la biblioteca.

Dependencia de scripting: FieldTrip es una biblioteca de programación que requiere que los usuarios escriban scripts para llevar a cabo análisis personalizados, lo que puede ser un desafío para aquellos que prefieren interfaces gráficas de usuario.

Compatibilidad de datos: Aunque FieldTrip es versátil, la compatibilidad de datos puede variar según la fuente de adquisición y el formato de datos. Algunos tipos de datos pueden requerir preprocesamiento adicional.

BrainVision Analyzer

BrainVision Analyzer es un software comercial utilizado para el análisis de datos EEG y otros tipos de datos neurofisiológicos. Ofrece una variedad de herramientas para filtrado, análisis de componentes independientes y análisis estadístico [54].

- Ventajas

Interfaz gráfica de usuario amigable: BrainVision Analyzer proporciona una interfaz gráfica de usuario (GUI) intuitiva que facilita la carga, visualización y análisis de datos de EEG sin necesidad de escribir código.

Flujos de trabajo predefinidos: El software incluye flujos de trabajo predefinidos para tareas comunes de procesamiento de EEG, lo que facilita la realización de análisis estándar y evita la necesidad de configurar todo desde cero.

Amplias capacidades de análisis: BrainVision Analyzer ofrece una amplia gama de herramientas de análisis, incluyendo filtrado, promedios, análisis de componentes independientes (ICA), análisis de eventos y conectividad, entre otros.

Visualización avanzada: Permite una visualización avanzada de los datos EEG, incluyendo mapas topográficos y gráficos de ondas cerebrales, lo que facilita la interpretación de los resultados.

Exportación de resultados: Puede exportar fácilmente resultados y figuras para su posterior análisis o presentación en otros programas.

- Desventajas

Costo: BrainVision Analyzer es un software comercial, lo que significa que puede tener un costo significativo en comparación con herramientas de código abierto o de uso gratuito.

Limitaciones en la personalización: Aunque es fácil de usar para análisis estándar, BrainVision Analyzer puede tener limitaciones en la personalización de flujos de trabajo y análisis altamente específicos. Los usuarios avanzados pueden encontrar restricciones en la adaptabilidad del software.

Curva de aprendizaje inicial: Aunque tiene una interfaz de usuario amigable, los nuevos usuarios pueden requerir tiempo para familiarizarse con todas las características y funcionalidades del software.

No es una herramienta de código abierto: A diferencia de algunas otras herramientas de análisis de EEG, BrainVision Analyzer no es de código abierto, lo que significa que no se pueden acceder ni modificar directamente sus componentes internos.

Neuroscan

Neuroscan es otro software comercial utilizado para el análisis de EEG y otros datos de neurofisiología. Proporciona una variedad de herramientas de filtrado y análisis de datos EEG [55].

■ Ventajas

Amplias capacidades de análisis: NeuroScan ofrece una amplia gama de herramientas de análisis para el procesamiento de señales EEG, incluyendo filtrado, promedios, análisis de eventos, análisis de componentes independientes y conectividad funcional, entre otros.

Visualización avanzada: El software proporciona herramientas de visualización avanzada, como mapas topográficos y gráficos de ondas cerebrales, que facilitan la interpretación de los resultados.

Adaptabilidad: NeuroScan permite a los usuarios personalizar y configurar flujos de trabajo de análisis de datos EEG de acuerdo con sus necesidades específicas.

Exportación de resultados: Puedes exportar fácilmente resultados y figuras para su posterior análisis o presentación en otros programas. Comunidad de usuarios activa: Al igual que otras herramientas, NeuroScan cuenta con una comunidad de usuarios activa que puede proporcionar soporte técnico y compartir recursos.

■ Desventajas

Costo: NeuroScan es un software comercial y puede tener un costo significativo, lo que puede ser un factor limitante para algunos usuarios.

Curva de aprendizaje inicial: Aunque es una herramienta poderosa, los nuevos usuarios pueden requerir tiempo para familiarizarse con todas las características y funcionalidades del software.

Compatibilidad de hardware: NeuroScan a menudo se utiliza en combinación con sistemas de adquisición de EEG específicos de la misma empresa, lo que puede limitar las opciones de hardware disponibles.

No es una herramienta de código abierto: Al igual que BrainVision Analyzer, NeuroScan no es una herramienta de código abierto, por lo que no se pueden acceder ni modificar directamente sus componentes internos.

MATLAB con Toolboxes

Además de EEGLAB y FieldTrip, MATLAB con sus diversas toolboxes (como Signal Processing Toolbox) es ampliamente utilizado para el procesamiento de señales EEG. Los usuarios pueden personalizar sus propios scripts y funciones de filtrado según sus necesidades [56].

- Ventajas

Alta flexibilidad: MATLAB es un entorno de programación altamente flexible que permite a los usuarios personalizar y adaptar los análisis de acuerdo con sus necesidades específicas.

Amplias capacidades: Los toolboxes específicos para EEG en MATLAB suelen ofrecer una amplia gama de capacidades de análisis, incluyendo filtrado, análisis de eventos, análisis de componentes independientes (ICA), conectividad funcional y más.

Integración de herramientas: Puede combinar y utilizar diferentes toolboxes y funciones de MATLAB para crear flujos de trabajo de análisis personalizados que se adapten a los objetivos de investigación.

Acceso a funciones avanzadas de programación: MATLAB proporciona un conjunto completo de herramientas de programación que permiten la automatización de tareas y el desarrollo de algoritmos personalizados.

Soporte para hardware personalizado: Puedes trabajar con una variedad de sistemas de adquisición de EEG y otros dispositivos de neuroimagen, lo que te brinda flexibilidad en la elección del hardware.

- Desventajas

Curva de aprendizaje inicial: MATLAB es un entorno de programación poderoso, pero también puede tener una curva de aprendizaje pronunciada para aquellos que no están familiarizados con la programación o el procesamiento de señales.

Requiere conocimientos de programación: Para aprovechar al máximo las capacidades de MATLAB y sus toolboxes, es necesario tener conocimientos de programación y estar familiarizado con las funciones y comandos específicos.

Costo: MATLAB y sus toolboxes son productos comerciales y pueden tener un costo significativo. Sin embargo, algunas instituciones académicas pueden ofrecer licencias académicas a precios reducidos.

Dependencia de la calidad de los algoritmos: La calidad de los resultados en el análisis EEG en MATLAB depende en gran medida de la calidad de los algoritmos y métodos implementados, lo que requiere una comprensión sólida de la teoría y práctica del procesamiento de señales EEG.

Python con MNE-Python

MNE-Python es una biblioteca de Python utilizada para el análisis de datos de neuroimagen, incluyendo señales EEG. Proporciona herramientas para el filtrado, la visualización y el análisis estadístico de datos EEG [57].

- Ventajas

Código abierto y gratuito: Python y MNE-Python son de código abierto y gratuitos, lo que significa que están disponibles para su uso sin costo y tienen una comunidad activa de usuarios y desarrolladores.

Amplias capacidades de análisis: MNE-Python ofrece una amplia gama de herramientas y funciones para el procesamiento de señales EEG, incluyendo filtrado, promedios, análisis de eventos, análisis de componentes independientes (ICA), conectividad funcional y más.

Integración con otras bibliotecas: Python es conocido por su capacidad de integración con otras bibliotecas y herramientas, lo que te permite combinar MNE-Python con otros paquetes de análisis, visualización o aprendizaje automático según sea necesario.

Documentación extensa: MNE-Python tiene una documentación detallada y tutoriales que facilitan el aprendizaje y la utilización efectiva de la herramienta.

Comunidad activa: Existe una comunidad activa de usuarios y desarrolladores que proporciona soporte técnico, comparte scripts y contribuye con actualizaciones y mejoras.

- Desventajas

Curva de aprendizaje: Aunque Python es conocido por su facilidad de aprendizaje, puede haber una curva de aprendizaje para aquellos que no están familiarizados con la programación en Python o el procesamiento de señales EEG.

Necesidad de programación: Al igual que con MATLAB, para aprovechar al máximo las capacidades de MNE-Python, se requiere conocimiento de programación y familiaridad con los comandos y funciones específicos de Python.

Compatibilidad de hardware: Debes asegurarte de que tu hardware de adquisición de EEG sea compatible con las bibliotecas de Python y MNE-Python, ya que esto puede variar según el equipo y el sistema de adquisición.

Recursos computacionales: El procesamiento de señales EEG en Python puede ser computacionalmente intensivo, por lo que puede requerir recursos de hardware adecuados para conjuntos de datos grandes o análisis complejos.

OpenViBE

OpenViBE es un software de código abierto diseñado para el desarrollo de aplicaciones BCI. Ofrece herramientas para la adquisición, preprocesamiento y análisis de señales EEG [58].

- Ventajas

Código abierto: OpenViBE es una plataforma de código abierto, lo que significa que es de acceso gratuito y está disponible para su modificación y adaptación según las necesidades de los usuarios.

Interfaz gráfica de usuario (GUI): OpenViBE proporciona una guía intuitiva que facilita la creación y configuración de flujos de trabajo de procesamiento de señales sin necesidad de programación.

Amplias capacidades de procesamiento: La plataforma ofrece una variedad de herramientas y algoritmos para el preprocesamiento, filtrado, segmentación y análisis de señales EEG.

Soporte para dispositivos de adquisición: OpenViBE es compatible con una variedad de dispositivos de adquisición de señales EEG, lo que permite una fácil integración con diferentes sistemas de adquisición.

Comunidad activa: OpenViBE cuenta con una comunidad de usuarios activa que proporciona soporte técnico, contribuye con extensiones y comparte recursos.

- Desventajas

Curva de aprendizaje: Aunque la guía de OpenViBE es amigable, todavía puede haber una curva de aprendizaje para aquellos que no están familiarizados con el procesamiento de señales EEG o las herramientas de neuroimagen.

Personalización limitada: Aunque OpenViBE ofrece una variedad de herramientas, la personalización avanzada puede ser limitada en comparación con soluciones de programación más flexibles como Python o MATLAB.

Recursos de hardware: El rendimiento de OpenViBE puede depender de los recursos de hardware disponibles, especialmente cuando se trabaja con grandes conjuntos de datos EEG o flujos de trabajo complejos.

Menos funciones de análisis avanzado: En comparación con algunas otras herramientas, OpenViBE puede tener menos capacidades avanzadas de análisis de conectividad o aprendizaje automático incorporadas.

BCILAB

BCILAB es una extensión de EEGLAB que se centra en el desarrollo de aplicaciones BCI y el procesamiento de señales EEG en tiempo real [59].

■ Ventajas

Integración con MATLAB: BCILAB se integra con MATLAB, lo que permite aprovechar las capacidades de programación y análisis personalizado que ofrece MATLAB.

Enfoque en BCI: BCILAB se centra en aplicaciones de interfaz cerebro-computadora (BCI), lo que lo hace especialmente adecuado para investigadores y desarrolladores que trabajan en este campo específico.

Amplias capacidades de análisis: BCILAB proporciona herramientas para el preprocesamiento, filtrado, extracción de características y clasificación de señales EEG, todo dentro del entorno de MATLAB.

Desarrollo de BCI personalizado: BCILAB permite el desarrollo de sistemas BCI personalizados, lo que es útil para aquellos que desean crear su propio sistema BCI desde cero.

Comunidad activa: BCILAB cuenta con una comunidad activa de usuarios y desarrolladores que proporcionan soporte técnico y comparten recursos.

■ Desventajas

Curva de aprendizaje: Al igual que con MATLAB en general, BCILAB puede tener una curva de aprendizaje para aquellos que no están familiarizados con la programación en MATLAB o el procesamiento de señales EEG.

Requiere conocimientos de programación: Para aprovechar al máximo las capacidades de BCILAB, es necesario tener conocimientos de programación y estar familiarizado con los comandos y funciones específicos de MATLAB.

Limitaciones en la personalización: Aunque BCILAB es personalizable, la personalización avanzada puede requerir conocimientos técnicos y experiencia en MATLAB.

Compatibilidad de hardware: Debe asegurarse que el hardware de adquisición de EEG sea compatible con BCILAB y MATLAB, ya que esto puede variar según el equipo y el sistema de adquisición.

LabChart

LabChart es una plataforma comercial utilizada para la adquisición y el análisis de datos de señales fisiológicas, incluyendo EEG. Ofrece herramientas de filtrado y análisis de datos [60].

- Ventajas

Interfaz amigable: LabChart ofrece una interfaz gráfica de usuario (GUI) amigable que facilita la adquisición y visualización de señales EEG en tiempo real.

Amplia compatibilidad de hardware: LabChart es compatible con una amplia variedad de sistemas de adquisición de señales EEG y otros dispositivos de medición fisiológica, lo que permite la integración de diferentes tipos de sensores.

Herramientas de análisis básicas: El software proporciona herramientas de análisis básicas que permiten realizar análisis sencillos de señales EEG, como cálculos de amplitud y frecuencia.

Registro de eventos: LabChart permite registrar eventos y marcar segmentos de datos relevantes durante la adquisición, lo que es útil para la anotación de eventos en señales EEG.

Compatibilidad con datos multimodales: Puede integrar señales EEG con otros tipos de datos fisiológicos y realizar análisis multimodales en LabChart.

- Desventajas

Limitaciones en el procesamiento avanzado: LabChart está más orientado hacia la adquisición de datos y el análisis básico. Puede carecer de herramientas avanzadas de procesamiento y análisis de señales EEG en comparación con software especializado.

Personalización limitada: La personalización de flujos de trabajo y análisis avanzados puede ser limitada en LabChart en comparación con herramientas más flexibles como MATLAB o Python.

Curva de aprendizaje: Aunque LabChart es fácil de usar para tareas básicas, puede haber una curva de aprendizaje para realizar análisis más avanzados o personalizados.

Costo: LabChart es un software comercial, lo que puede aumentar el costo de implementación en comparación con herramientas de código abierto o de uso gratuito.

Machine learning

Entre estos softwares, los métodos de filtrado más comunes son SVM, árbol de decisiones y random forest [61–68].

- Ventajas

Capacidad para modelar relaciones complejas: El machine learning puede aprender y modelar relaciones complejas en los datos EEG que pueden ser difíciles de capturar con métodos de filtrado lineal convencionales.

Adaptabilidad: Los modelos de machine learning pueden adaptarse a las características cambiantes de las señales EEG a lo largo del tiempo, lo que los hace efectivos para el filtrado en tiempo real.

Personalización: Los modelos de machine learning se pueden entrenar y personalizar para adaptarse a las necesidades específicas de cada usuario o aplicación, lo que permite un filtrado altamente individualizado.

Identificación de patrones sutiles: El machine learning puede identificar patrones sutiles en los datos EEG que pueden ser indicativos de eventos o fenómenos de interés, como cambios en la actividad cerebral anormal.

Automatización: Una vez entrenados, los modelos de machine learning pueden automatizar el proceso de filtrado sin la necesidad de intervención humana constante.

- Desventajas

Requiere conjuntos de datos grandes: Los modelos de machine learning suelen requerir conjuntos de datos grandes y etiquetados para un entrenamiento eficaz, lo que puede ser un desafío en el caso de datos EEG debido a la recopilación de datos costosa y la necesidad de expertos para etiquetarlos.

Curva de aprendizaje: La implementación efectiva de machine learning para el filtrado EEG puede requerir un conocimiento significativo de programación, estadísticas y machine learning, lo que puede representar una curva de aprendizaje para los investigadores y clínicos.

Sensibilidad a la calidad de los datos: Los modelos de machine learning pueden ser sensibles a la calidad de los datos EEG, incluyendo artefactos y ruido. La limpieza de los datos puede ser necesaria antes del entrenamiento.

Interpretación de modelos: Los modelos de machine learning suelen ser cajas negras, lo que significa que pueden ser difíciles de interpretar y explicar, lo que puede ser un problema en aplicaciones clínicas o en la investigación donde se requiere una comprensión detallada de los resultados.

Riesgo de sobreajuste: Los modelos de machine learning pueden sufrir de sobreajuste (overfitting) si se entrenan con demasiados datos o si no se seleccionan cuidadosamente los hiperparámetros, lo que puede llevar a resultados inexactos.

2.0.5. Ecuación matemática

A continuación se muestran las ecuaciones matemáticas básicas para el diseño teórico de un filtro básico de segundo orden, el cual servirá como referencia para entender como funcionan los filtros.

Para esta ecuación matemática, también llamada función de transferencia del sistema, de un pasa-bajas de segundo orden, es importante tener en cuenta los siguientes parámetros:

- k - Ganancia
- ζ - Factor de amortiguamiento
- ω_n - Frecuencia natural
- $C(S)$ - Salida del sistema
- $R(S)$ - Entrada del sistema
- Q - Factor de calidad
- C_1 - Capacitor 1
- C_2 - Capacitor 2
- R - Resistencia

Una vez definidos estos parámetros, es posible trabajar con la función de transferencia de un filtro pasa-baja, que está dada por la ecuación (2.1) [69]

$$\frac{C(S)}{R(S)} = \frac{k\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2}. \quad (2.1)$$

El factor de calidad se expresa con la siguiente ecuación:

$$Q = \frac{1}{2} \sqrt{\frac{C_1}{C_2}}. \quad (2.2)$$

A partir de estas ecuaciones, se realizan los cálculos para conocer las características del filtro y a partir de ellas, determinar si son adecuados o no para lo que se requiere [69].

Ahora, para poder encontrar un caso en que el sistema de segundo orden sea subamortiguado, se debe cumplir que $0 < \zeta < 1$. Para poder llegar a esta condición, se deben identificar los polos de la siguiente manera:

$$s^2 + 2\zeta w_n s + w_n^2 = 0, \quad (2.3)$$

se utiliza la ecuación general para encontrar las raíces de un polinomio de segundo grado:

$$s_{1,2} = \frac{-2\zeta w_n \pm \sqrt{4\zeta^2 w_n^2 - 4w_n^2}}{2}. \quad (2.4)$$

En el caso de que se desee tener un sistema subamortiguado, se aumenta el valor de k , lo cual da como resultado las siguientes ecuaciones:

$$\zeta = \sqrt{\frac{C}{\pi^2 + C}}, \quad (2.5)$$

para encontrar Co :

$$Co = \left[\ln \left(\frac{m_p(\%)}{100} \right) \right]^2, \quad (2.6)$$

donde Co es el coeficiente de amortiguamiento y $m_p(\%)$ es el porcentaje de sobrepaso. Ahora, para encontrar la frecuencia de oscilación transitoria ω_d se utiliza la siguiente ecuación:

$$\omega_d = \frac{1}{t_r} \left[\pi - \arctan \left(\frac{\sqrt{1 - \zeta^2}}{\zeta} \right) \right]. \quad (2.7)$$

Al simplificar la ec. (2.7) se tiene la siguiente ecuación:

$$\omega_n = \frac{\omega_d}{\sqrt{1 - \zeta^2}}, \quad (2.8)$$

de esta manera se puede conocer el valor exacto de la frecuencia de natural no amortiguada [70, 71].

Ahora, para poder conocer la eficacia de un filtro, se puede usar la ecuación de la desviación estándar (σ) de una señal antes y después del filtrado, el cual refleja el cambio en la variabilidad de la señal, permitiendo con este saber la eficacia de un filtro.

La desviación estándar se calcula con la siguiente ecuación:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (2.9)$$

donde N es el número total de muestras, x_i es cada muestra de la señal, y μ es el valor medio de la señal.

No obstante, para el diseño del filtro tipo Butterworth adaptativo, se utilizó la siguiente función de transferencia:

$$H(s) = \frac{1}{\sqrt{1 + \left(\frac{s}{\omega_c}\right)^{2n}}} \quad (2.10)$$

donde $H(s)$ es la función de transferencia, s es la variable compleja de Laplace, ω_c es la frecuencia de corte angular y n es el orden del filtro. La frecuencia de corte angular se relaciona con la frecuencia de corte (f_c) mediante $\omega_c = 2\pi f_c$. Este diseño garantiza una respuesta en frecuencia máximamente plana en la banda de paso y una transición suave hacia la banda de rechazo.

Los cálculos específicos que se hicieron para el diseño del filtro fueron:

Frecuencia Normalizada La frecuencia normalizada se calcula para adaptar la frecuencia de corte deseada a las características específicas del sistema digital:

$$\text{Frecuencia normalizada} = \frac{\text{Frecuencia de corte}}{\text{Frecuencia de Nyquist}} \quad (2.11)$$

donde la frecuencia de Nyquist es la mitad de la frecuencia de muestreo del sistema.

Diseño de los Coeficientes del Filtro: Los coeficientes del filtro b (numerador) y a (denominador) se calculan utilizando la función `butter` de `scipy.signal`, basándose en la orden del filtro y la frecuencia normalizada.

Aplicación del Filtro La señal filtrada se obtiene aplicando el filtro a la señal EEG a través de la ecuación:

$$y[n] = \sum_{k=0}^M b[k]x[n-k] - \sum_{l=1}^N a[l]y[n-l] \quad (2.12)$$

donde $x[n]$ es la señal de entrada y $y[n]$ es la señal de salida (filtrada) [72].

2.0.6. Parámetro SNR

Para corroborar de manera efectiva la disminución del ruido en las señales electroencefalográficas sometidas a estudio, se implementó la evaluación del parámetro de relación señal a ruido (SNR) en las señales post-procesamiento. La elección de este parámetro es crucial, dado que en la amplia gama de investigaciones enfocadas en el reconocimiento de patrones cerebrales, la primacía recae en disponer de un conjunto de características donde las señales se distingan claramente en un espacio ordenado y discriminable. Esta distinción es esencial para facilitar la identificación y clasificación de patrones específicos dentro de las señales EEG, un paso fundamental en el desarrollo de interfaces cerebro-computadora eficientes y en la investigación neurocientífica en general.

La calidad superior de las señales EEG, garantizada mediante la aplicación de un método de caracterización riguroso como es el análisis de la SNR, permite no solo una separación más precisa de los patrones de interés sino también una interpretación más fiable de los datos. El parámetro SNR actúa como un indicador cuantitativo de la mejora en la calidad de la señal, reflejando la proporción entre la potencia de la señal de interés y la potencia del ruido que la contamina. Al aumentar la SNR, se evidencia una reducción efectiva del ruido, lo que implica que la señal resultante posee una mayor pureza y claridad, facilitando así el proceso de extracción y análisis de características relevantes.

Este enfoque metódico para la mejora y evaluación de la calidad de las señales EEG mediante el parámetro SNR es fundamental en la búsqueda de sistemas BCI más precisos y en el avance de la neurociencia. Al optimizar la calidad de las señales, se abre el camino hacia una mayor comprensión de los procesos cerebrales y hacia el desarrollo de tecnologías capaces de interpretar y responder a las complejidades del cerebro humano con una eficacia sin precedentes [73].

La fórmula para calcular el parámetro SNR en señales EEG se define como:

$$\text{SNR (dB)} = 10 \cdot \log_{10} \left(\frac{PS}{PN} \right)$$

donde:

- PS es la potencia de la señal deseada.
- PN es la potencia del ruido.

Antecedentes

En muchas investigaciones se utiliza la extracción de señales EEG para poder realizar diferentes análisis, un ejemplo de esto lo podemos ver en [7], en la cual se busca tener topografías de microestados del cerebro, los cuales se obtienen al momento en que se le presenta a una persona diferentes caras, con expresiones como felicidad o enojo. Durante intervalos de tiempo de cuasi estabilidad, se extraen las señales EEG para poder generar las topografías de microestados, donde el problema está en los mismos intervalos, los cuales se miden dentro de los rangos de 80 ms a 120 ms.

Es importante saber los tiempos de medida de las señales EEG, ya que se puede generar ruido si el tiempo es constante, además de otras causas, por ejemplo cuando la persona se mueve, se altera o incluso parpadea, es por esto que es necesario utilizar filtros en los sistemas, ya que estos reducen el ruido que se genera y ayudan a tomar lecturas con mayor tiempo de estabilidad. Por suerte, existen algunas formas de mejorar los sistemas, por ejemplo, se pueden implementar amplificadores diferenciales para aumentar la señal adquirida, así como en [74], donde se usan múltiples amplificadores diferenciales en el análisis de las señales EEG, con la finalidad de detectar a tiempo cuando una persona tendrá convulsiones.

En esta investigación, se utiliza un sistema que consta de un circuito amplificador diseñado en tecnología CMOS de 65 nm para cubrir el rango dinámico de las señales EEG, con esto se obtienen resultados de medición del circuito de indicador de intensidad de la señal recibida con un consumo de energía de 31.6 nW. El circuito mencionado cubre un rango dinámico de 45 dB y tiene un error de linealidad de menos de 1 dB, lo cual deja pauta a implementar un filtro que permita reducir aún más el error de linealidad. Existen investigaciones donde se usa el análisis de las señales EEG en conjunto con el análisis de otras partes del cuerpo, por ejemplo, en [75] se utilizan diferentes filtros en un mismo sistema, ya que buscan analizar los cambios en los diámetros de la pupila de las personas, cuando realizan diferentes tareas en lapsos de tiempo definidos. En este tipo de análisis, se utilizan diferentes softwares para el procesamiento de datos, como lo es *Brain Vision Recorder* y el uso de filtros de paso alto y bajo con IIR de 0.5 Hz y 40 Hz. Aunque en casos como estos, sería importante la implementación de amplificadores operacionales, para permitir una lectura más precisa al momento de encontrarse con movimientos involuntarios del ojo.

Otro ejemplo del uso de filtros con diferentes sistemas, se puede ver en el uso de microsistemas de bajo consumo y bajo ruido que sirven para el registro de señales electroencefalográficas, como lo hacen en [8], donde se utiliza un sistema que cuenta con 32 canales de tiempo-multiplexados en la interfaz del electrodo y ofrece la posibilidad de codificar datos delta, espacialmente para aprovechar

la gran correlación de señales capturadas de canales cercanos. No obstante, se muestra un ejemplo del uso en conjunto de amplificadores y filtros, ya que utilizan una combinación de amplificación de doble muestreo correlacionado de banda estrecha y sobre muestreo de la señal en el *front-end*, esto se hace con el objetivo de reducir el ruido generado por los parpadeos. Ahora bien, este tipo de filtro con amplificadores, serían excelentes de implementar en trabajos como el de [11], donde se realizan registros de la actividad cerebral cuando las personas tienen los ojos abiertos y cerrados, su objetivo es mostrar el aumento de poder de las ondas cerebrales de la banda alfa, el problema es que los movimientos involuntarios del ojo pueden ocasionar muchos problemas al momento de realizar el análisis de las señales.

También para las señales EEG existen filtros que se implementan de manera digital, como en [76], donde se utiliza un amplificador electroencefalográfico de matriz densa con estación geodésica de fotogrametría. Este tipo de amplificador de matriz densa registra la actividad cortical del cerebro con hasta 500 Hz de frecuencia a través de las Redes de Sensores Geodésicos *HydroCel GSN 130* de 256 canales. El amplificador funciona con el *software Net Station 4.5.4*, el GPS está bajo el control de *Net Local 1.00.00* y *GeoSource 2.0*, pero, la eliminación de los parpadeos y los movimientos involuntarios(ruido), así como la calibración de la mirada, se realizan gracias a la aplicación de un seguidor ocular dedicado y operado por *SmartEye*, aunque es importante considerar en trabajos como el mencionado anteriormente, la utilización de un filtro físico, para evitar que todo recaiga en lo digital. No obstante, existen publicaciones inductoras donde se nos muestran trabajos con estas señales, como [77], donde se realizan recopilaciones de diferentes trabajos que utilizan la extracción de las señales EEG. Además, en [78], indican la importancia del análisis de las señales EEG para conocer su comportamiento y características, lo cual es la base de muchas nuevas investigaciones, pues si no se tienen las características y comportamientos de las señales EEG, es muy difícil realizar un análisis correcto.

Pasando ahora a los antecedentes locales, en la UAQ existen diferentes ejemplos cuando se habla de las señales EEG, principalmente existe un trabajo en el cual se diseñó un sistema BCI para la extracción de señales EEG y este es el de la Dra. Luz María Sánchez Reyes [9], en el cual se utilizó el Kit ADS1299EEG-FE. Este dispositivo está diseñado con una arquitectura realizada en LabVIEW, la cual cuenta con un filtro digital para evitar el ruido generado por diversos factores, sin contar los físicos, como lo son los electrodos, movimientos de los cables o variantes en la entrada de alimentación, pero esta investigación será la base para esta tesis. Otros ejemplos de las investigaciones realizadas en la UAQ son los trabajos que indican la importancia de las señales EEG para diferentes enfermedades mentales, como lo es la demencia, [79], en el cual nos indican que las señales EEG sirven para analizar a las personas afectadas con esta enfermedad mental, debido a que son pruebas no invasivas que analizan la actividad eléctrica cerebral, lo cual evita hasta cierto punto que la persona entre en pánico o ansiedad, ya que esto último depende de la persona con quien se esté trabajando. En [10], se hacen clasificaciones basadas en máquinas de soporte vectorial, donde presentan una compilación de trabajos en el idioma español latino.

Publicaciones como la de [2], nos dicen que durante el año 2020, el INEGI calculó que el 43 % de los suicidios registrados fue de personas entre los 10 a los 29 años. Esto quiere decir que, durante ese año se registraron un total de, 7896 suicidios, de los cuales, 3453 fueron de personas consideradas jóvenes. Un ejemplo grave de esto es Yucatán, ya que al ser uno de los estados con mayor nivel de suicidios, el INEGI presentó que el 40 % de las personas que murieron en ese estado pertenece al

grupo de edad de personas jóvenes. El diputado Jhonatan Colmenares Rentería en [2] atribuye que este problema sucede debido a la falta de mecanismos preventivos para evitar trastornos de salud mental y, por ende, suicidios.

Por todo lo que se ha expuesto anteriormente, esta tesis se dirigió al desarrollo de la etapa de control de un filtro para señales EEG que se pueda implementar en un sistema BCI y así obtener mejores resultados al momento de trabajar con dichas señales y que pueden seguirse utilizando en favor de la salud.

3.0.1. Principales referencias en la literatura

En esta subsección, se encontrarán de manera rápida los nombres de las investigaciones, proyectos y publicaciones que se usaron para los antecedentes. En el Cuadro 3.1 se puede observar las investigaciones y publicaciones a nivel global.

Cuadro 3.1: Cuadro de referencias de las investigaciones y publicaciones más importantes.

Año	Autor	Título	Descripción
2022	G. Prete, P. Croce, F. Zappasodi, L. Tommasi, y P. Capotosto	<i>Exploring brain activity for positive and negative emotions by means of EEG microstates</i>	Se generan diferentes tipos de análisis usando las señales EEG, en las cuales se muestran varianzas del 80 % en adultos sanos, dependiendo de la zona craneal en la que se enfocan y en el factor más importante, el estado de la persona, siendo que en reposo la mayoría de los adultos sanos cuentan con una diferencia de 140 a 300 ms en los microestados analizados, mientras que en personas excitadas se encuentran una diferencia de 300 a 550 ms. No obstante, el ruido se presenta en mayor frecuencia cuando el tiempo de análisis es prolongado, lo cual explica el porqué las señales EEG deben ser analizadas durante intervalos de tiempo específicos [7].
2022	Zhang, N. Mirchandani, S. Abdelfattah, M. Onabajo, y A. Shrivasta-va.	<i>An Ultra-Low Power RSSI Amplifier for EEG Feature Extraction to Detect Seizures.</i>	Se muestra el análisis y adquisición de señales EEG mediante amplificadores frontales analógicos, los cuales mandan la señal potenciada por medio de diferentes filtros, en los cuales, las señales se dividen y se asignan en cinco bandas de frecuencia: Delta 0-4 Hz; Theta 4-7 Hz; Alfa 8-15 Hz; Beta 16-31 Hz; y Gamma 32 Hz. Debido a que se utilizan las diferentes bandas de frecuencia, los filtros utilizados son pasa bandas, mostrando así, las bandas de frecuencia utilizadas en las señales EEG, no obstante, el hecho de que dichas señales se adquieren al momento en que una persona convulsiona, se puede deducir que los filtros utilizados son diseñados para reducir el ruido generado por los movimientos involuntarios del cuerpo [74].
2022	Yu, Shijing and Mückschel, Moritz and Beste, Christian	<i>Superior frontal regions reflect the dynamics of task engagement and theta band-related control processes in time-on task effect</i>	Se analizan las señales EEG en conjunto con un sistema que puede medir los cambios de diámetro de la pupila, con el cual se muestra que los cambios en el diámetro pupilar son provocados por las demandas de la tarea que la persona este realizando, llegando a tener una dilatación de 150° cuando la persona se encuentra mentalmente agotada. Estos datos indican una demanda cognitiva mayor cuando una persona se encuentra bajo los efectos de fatiga, provocando que las lecturas EEG contengan un mayor porcentaje de ruido, por lo cual se debe evitar trabajar con personas fatigadas cuando se realizan análisis de señales EEG [75].

Cuadro 3.1: Continuación al cuadro de referencias de las investigaciones y publicaciones más importantes

2021	N. Perez-Prieto, A. Rodriguez-Vazquez, M. Alvarez-Dolado, y M. Delgado-Restituto.	<i>A 32-Channel Time-Multiplexed Artifact-Aware Neural Recording System</i>	Se muestra un sistema compuesto por una matriz de conmutación para multiplexar señales neuronales de entrada, dos amplificadores diferenciales de instrumentación de bajo ruido en cascada para lograr muestrear, filtrar y amplificar las señales capturadas por los electrodos. Se destaca del multiplexor que puede configurarse en dos modos de detección, monopolar y bipolar, dependiendo de si las señales se refieren a una referencia común o si se miden las diferencias de voltaje entre electrodos cercanos. [8].
2019	Wójcik, Grzegorz M. and Kawiak, Andrzej y Kwasniewicz, Lukasz y Schneider, Piotr y Masiak, Jolanta.	<i>Azure Machine Learning tools efficiency in the electroencephalographic signal P300 standard and target responses classification.</i>	Se muestra un amplificador EEG de matriz densa con estación geodésica de fotogrametría. Para realizar el análisis, el dispositivo mide la actividad de las áreas de Brodmann, seguidamente calcula la carga eléctrica media que fluye a través de áreas particulares. El dispositivo cuenta con 5 herramientas de aprendizaje automático, los cuales son: regresión logística, árbol de decisión potenciado, máquina de puntos de Bayes, red neuronal clásica y clasificador de perceptrón promediado. Con esto se puede inducir que los dispositivos de análisis EEG pueden ser utilizados con muchas herramientas distintas para lograr un objetivo [76].
2022	Cao, J., Zhao, Y., Shan, X., Wei, H. L., Guo, Y., Chen, L., Erkoyuncu, J. A. y Sarrianiannis, P. G.	<i>Brain functional and effective connectivity based on electroencephalography recordings: A review</i>	Se muestran varios métodos basados en modelos para métricos, los cuales son comúnmente aceptados para estimar la conectividad efectiva de las señales EEG por medio de multicanales. Se aclara que la conectividad efectiva paramétrica se basa en modelos teóricos que describen cómo las áreas del cerebro que interactúan y se influyen entre sí, esto lo llaman el modelo causal dinámico. Se destaca que la conducción de volumen es un problema importante cuando se analizan registros de señales EEG, ya que influyen en los análisis de conectividad entre sensores y espacios. [77].
2022	H. Chu, Y. Cao, J. Jiang, J. Yang, M. Huang, Q. Li, C. Jiang, and X. Jiao.	<i>Optimized electroencephalogram and functional near-infrared spectroscopy-based mental workload detection method for practical applications.</i>	Se explican diferentes trabajos realizados con las señales EEG, en la cual se destaca el uso del método ANOVA, usado para analizar la diferencia de respuesta de potencia en diferentes bandas, bajo varios niveles de carga de trabajo mental. Se muestran resultados de un análisis estadístico, en el cual se usaron 62 electrodos en el cuero cabelludo para muestrear la zona, en el cual se implementaron cientos de comparaciones simultáneamente [78].
2022	Hohaia, W., Saurels, B. W., Johnston, A., Yarrow, K., y Arnold, D. H.	<i>Occipital alpha-band brain waves when the eyes are closed are shaped by ongoing visual processes</i>	Se muestran diferentes análisis de datos mediante scripts personalizados de MATLAB con la herramienta Field-Trip17 y el comando integrado de transformación Fast-Fourier. Para las frecuencias de 2 Hz, 60 Hz y 49–51 Hz utilizo un filtro Butterworth de sexto orden con una dirección de dos pasos. Al trabajar en sintonía con el ojo humano, el ruido generado por el parpadeo se eliminó mediante un análisis de componentes independientes (ICA). [11].

3.0.2. Trabajos previos en la UAQ

En esta subsección se encontrarán los trabajos, investigaciones y publicaciones realizadas a nivel local, lo cual se puede observar en el Cuadro 3.2.

Cuadro 3.2: Cuadro de las referencias de artículos e investigaciones utilizados para los antecedentes a nivel local.

Año	Autor	Título	Descripción
2017	L. M. Sanchez-Reyes.	Diseño e implementación de un sistema BCI para el análisis de EEG.	Se muestra el diseño de un sistema BCI con la capacidad de tener una interfaz modificable que permita una mejor visualización para el usuario. Se explica el proceso para la programación de un procesador embebido, para lograr la capacidad de ser modificable la interfaz. Se destaca la importancia del dispositivo en el área médica y su capacidad en tratamientos enfocados hacia personas con discapacidades motrices [9].
2019	D. C. Toledo-Pérez, J. Rodríguez-Reséndiz, R. A. Gómez-Loenzo, y J. C. Jauregui-Correa	<i>Support Vector Machine-Based EMG signal classification Techniques</i>	Se muestra el uso de máquinas de soporte vectorial para algoritmos de clasificación de movimientos corporales, imágenes, sonidos y señales que conllevan ruido en cada uno de sus análisis. Se describe que las SVM construyen un hiperplano de separación óptimo en un espacio de características de gran dimensión, esto es debido a las entradas que se asignan mediante funciones no lineales, para distinguir entre dos o más tipos de objetos. De las SVM se destaca el algoritmo de entrenamiento, ya que se reformula como un problema a resolver por medio de programación cuadrática, en donde dicen que la solución es global y única. [10].
2021	L. M. Sanchez-Reyes, J. Rodriguez-Resendiz, G. N. AVECILLA-Ramirez, M. L	<i>Impact of EEG Parameters Detecting Dementia Diseases</i>	Se muestra un compendio de 82 artículos relacionados con las señales EEG y su importancia en la detección de enfermedades mentales. Se explica que las señales EEG son el registro de oscilaciones de voltaje provocadas por corrientes iónicas intra y extraneuronales de una población de neuronas con una determinada distribución espacial. Lo más destacado son los parámetros obtenidos en todos los artículos, los cuales son: adquisición, procesamiento, clasificación y evaluación del desempeño. Dichos parámetros se relacionan directamente con los resultados de eficiencia, ventajas y coste asociado. [79].

3.0.3. Tabla de patentes

En esta sub-sección se encontrarán patentes realizadas a lo largo de los años sobre las señales EEG 3.3.

Cuadro 3.3: Cuadro de patentes que utilizan señales EEG

Año	Autor	Título	Descripción
2011	J. L. Bardasano-Rubio, J. De La Hoz-Fabra, J. L. Ramos-Jacome, J. Á. UDE-De La Torre, Y. Fernández-Campo.	Medios de registro electroencefalográfico secuencial durante la estimulación magnética transcraneal de baja intensidad.	Se muestra un dispositivo de doble casco que permite realizar el registro de las señales electroencefalográficas tras aplicarles una estimulación tras-craneal de baja intensidad, lo cual permite una lectura precisa del comportamiento del cerebro ante estímulos directos. [80].
2014	A. Ortiz-Coso, M. Aguilar-Herrero, M. Lopez-Valdés, J. Minguez-Zafra	Electrodo de medida de electroencefalogramas	Se muestra el diseño e implementación de un electrodo que tiene como objetivo captar las señales electroencefalográficas para su análisis. La característica principal es que dicho electrodo, funciona adecuadamente aun cuando se mueve de manera giratoria sobre su mismo eje, permitiendo una lectura más precisa, aun cuando la persona cuente con algún problema físico que le impida mantenerse en reposo [81].
2017	J. Changjun, Y. Chungang, C. Hongzhong, H. Lianghua	<i>Deep learning method based on Mental imagery eeg data</i>	Se muestra un método de aprendizaje profundo, basado en datos de señales EEG de imágenes mentales, en las cuales la eliminación del ruido se lleva a cabo en los datos iniciales para luego filtrar los datos de las ondas obtenidas, permitiendo que los datos finales cuenten con un mínimo de ruido y el análisis de las señales EEG sea más preciso [82].
2014	F. Yunfa, S. Huiwen, Y. Zhengtao, G. Jianyi	<i>BCI (Brain-Computer Interface) electroencephalogram helmet</i>	Se presenta el desarrollo e implementación de un sistema BCI que consiste en un casco diseñado con las siguientes características: un electrodo deslizante, un electrodo no deslizante, un soporte de plástico endurecido, un clip de electrodo de referencia y un cable de conexión del electrodo de referencia. Estos componentes permiten que el análisis de las señales EEG sean muy precisos [83].

En la literatura, también se han generado diferentes tipos de filtros que permiten la reducción del ruido en las señales EEG, pero como se puede ver en la Figura 3.1 este tipo de filtros cuentan con ciertas características que perjudican la interpretación de las señales EEG, como lo es el desplazamiento de fase, el cual es un problema crucial al momento de trabajar con diferentes enfermedades mentales como la epilepsia, en donde la fase es relevante para conocer los tiempos en que se presenta o puede presentarse.

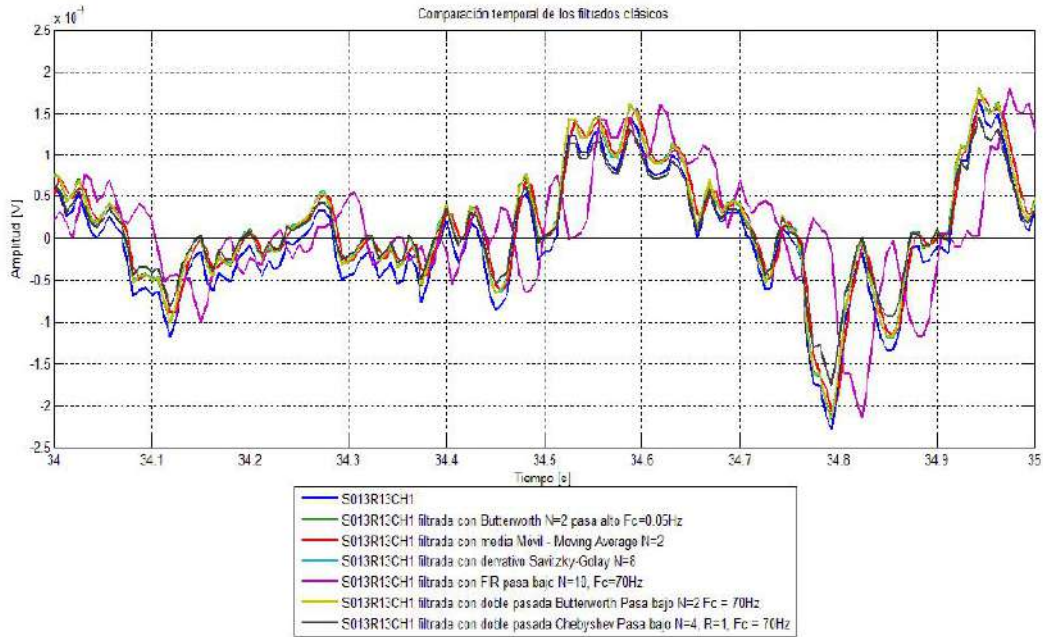


Figura 3.1: Gráfica comparativa de las señales EEG en la literatura [1].

Metodología

En esta sección se hablará sobre la metodología propuesta para esta tesis, pasando por una serie de pasos que se pueden ver de mejor manera en la línea de tiempo de la Figura 4.1.

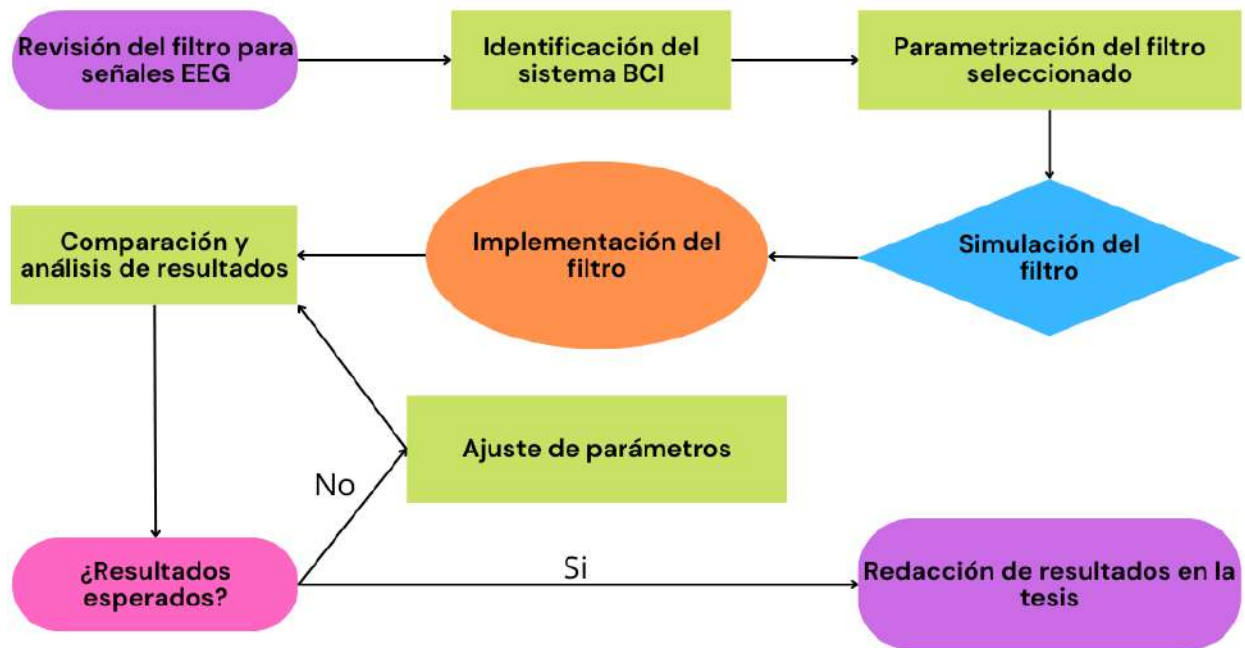


Figura 4.1: Diagrama de la metodología.

4.0.1. Revisión del filtro pasa bajas para EEG

Inicialmente, se llevó a cabo una investigación exhaustiva para comprender mejor los filtros más utilizados en el procesamiento de señales electroencefalográficas (EEG). Esta investigación implicó un análisis detallado de diversas fuentes académicas y técnicas, incluyendo estudios previos, publicaciones científicas, y documentación técnica relacionada con sistemas de interfaz cerebro-computadora (BCI). A través de esta exploración, se logró identificar una amplia gama de filtros utilizados en el campo, cada uno con características y aplicaciones específicas, tal como se muestra en los antecedentes de esta tesis.

Durante la investigación, se analizaron diferentes tipos de filtros, incluyendo filtros pasa-banda, pasa-altas, pasa-bajas, y filtros con inteligencia artificial. Cada uno de estos filtros tiene aplicaciones específicas dependiendo de la frecuencia de las señales EEG que se desean analizar. Por ejemplo, los filtros pasa-bajas son eficaces para atenuar las frecuencias altas y conservar las bajas, lo cual es crucial cuando se estudian ondas cerebrales como las delta y theta. Por otro lado, los filtros pasa-altas son útiles para eliminar ruidos de baja frecuencia, como los causados por el movimiento del usuario.

No obstante, después de una consideración cuidadosa de las ventajas y desventajas de cada tipo de filtro, se decidió optar por un filtro digital adaptativo con una estructura de Butterworth. Esta elección se basó en varios factores clave. En primer lugar, los filtros Butterworth son conocidos por su respuesta de frecuencia extremadamente plana en la banda de paso, lo que significa que todas las frecuencias dentro de un rango especificado se amplifican por igual, evitando distorsiones en la forma de onda de la señal EEG.

Además, la naturaleza adaptativa del filtro seleccionado permite que se ajuste dinámicamente a cambios en las señales EEG, lo cual es particularmente útil en aplicaciones BCI donde las señales cerebrales pueden variar significativamente de un momento a otro. Este enfoque garantiza una mayor flexibilidad y precisión en la filtración de señales, lo cual es crucial para obtener resultados confiables en sistemas BCI.

Finalmente, se consideró la facilidad de implementación y uso del filtro en sistemas BCI. El filtro de Butterworth, con su diseño sencillo y eficaz, ofrece una excelente opción para aplicaciones que requieren un equilibrio entre precisión en el procesamiento de señales y simplicidad operativa. Esto lo hace ideal para su uso en múltiples sistemas BCI, donde la eficiencia y la fiabilidad son fundamentales.

En resumen, la decisión de utilizar un filtro digital adaptativo con estructura de Butterworth para el procesamiento de señales EEG en sistemas BCI se basó en un análisis minucioso de las necesidades específicas de estas aplicaciones, así como en las características técnicas y prácticas de los diversos filtros disponibles. Esta elección estratégica busca optimizar la calidad de las señales EEG procesadas, asegurando así la efectividad y confiabilidad de los sistemas BCI.

4.0.2. Identificación del sistema BCI

Tras analizar y elegir el filtro que se utilizaría, se llevó a cabo una evaluación exhaustiva de los diferentes tipos de sistemas BCI (interfaz cerebro-computadora) disponibles en el mercado y en la investigación académica. El objetivo principal de esto fue comprender en profundidad las características de las señales que manejan estos sistemas, así como las metodologías y tecnologías que emplean para procesar y entregar resultados. Esta comprensión detallada era crucial para minimizar los riesgos de fallo en las pruebas iniciales de nuestra implementación.

Durante la investigación, se encontró que existe una variedad notable de sistemas BCI, cada uno con sus especificidades en cuanto a captación, procesamiento y salida de señales cerebrales. Por ejemplo, algunos sistemas se centran en señales relacionadas con la actividad motora, mientras que otros podían detectar señales asociadas a procesos cognitivos o emocionales. Asimismo, se descubrió que la empresa Texas Instruments posee una extensa línea de productos y desarrollos en el ámbito de los sistemas BCI, lo cual resalta la creciente importancia y diversificación de estas tecnologías.

Con base en la información recopilada, se procedió a diseñar un enfoque general que permitiera la implementación del filtro seleccionado, adaptado específicamente para su uso en conjunto con sistemas BCI. Este diseño se ilustra en la Figura 4.2. En la primera etapa de este esquema, se contempla la extracción de señales EEG. Esta es una fase crítica, ya que la calidad y precisión de las señales recogidas son fundamentales para el éxito de las etapas subsiguientes.

Posteriormente, las señales EEG son procesadas por un sistema BCI. En esta fase, se analizan y se traducen las señales cerebrales en comandos o datos interpretables, que pueden ser utilizados en una variedad de aplicaciones, desde la asistencia médica hasta el control de dispositivos.

Finalmente, el diseño contempla la implementación del filtro. Aquí, se presentan dos opciones viables: la primera es la implementación del filtro en una Raspberry Pi. Esta opción destaca por su rentabilidad y portabilidad, lo que la hace ideal para aplicaciones de bajo costo y alta flexibilidad. La segunda opción es la implementación del filtro en un ordenador computacional más potente. Esta alternativa ofrece mayor capacidad de procesamiento y es más adecuada para aplicaciones que requieren un análisis de datos más complejo o recursos computacionales intensivos.

En resumen, la fase de investigación y diseño en esta tesis de los sistemas BCI se centró en la comprensión detallada de las tecnologías existentes y en la elaboración de un enfoque que fuera flexible y eficiente para la implementación del filtro. Esto se hizo con el objetivo de maximizar la eficacia y minimizar los riesgos en el procesamiento de señales EEG, asegurando así la viabilidad y el éxito de esta tesis en una variedad de aplicaciones prácticas.

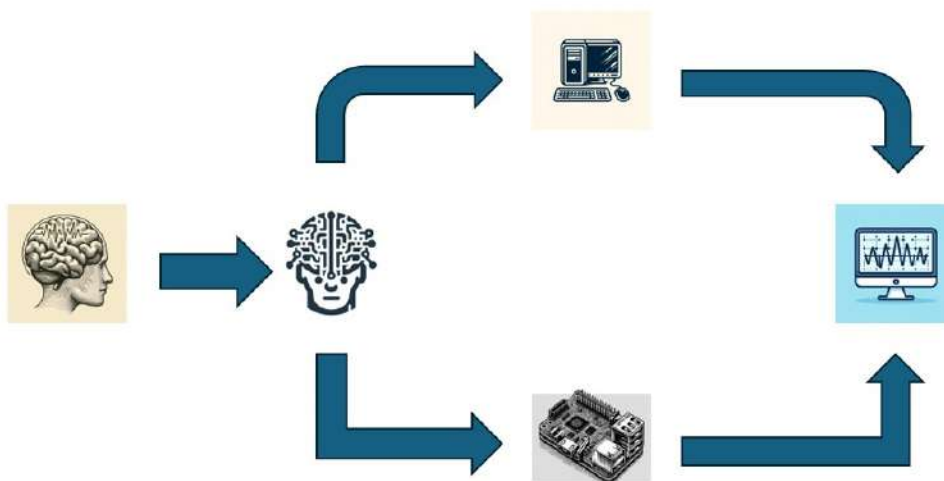


Figura 4.2: Diagrama de la implementación del filtro diseñado.

4.0.3. Parametrización y configuración del filtro seleccionado

Una vez seleccionado el tipo de filtro adecuado, se inició la etapa de diseño y parametrización detallada del filtro, con el objetivo específico de abordar el problema del ruido identificado previamente en la etapa de análisis de los sistemas BCI. Esta fase de diseño fue crucial para asegurar que el filtro no solo eliminara el ruido no deseado, sino que también preservara la integridad de las señales EEG útiles.

Para lograr una configuración precisa del filtro, se realizó una investigación profunda sobre las características de los filtros digitales, específicamente enfocada en su implementación mediante Python. Esta investigación involucró el estudio de diferentes librerías y módulos disponibles, que son ampliamente reconocidos por su eficacia y flexibilidad en el procesamiento de señales digitales.

Como resultado de la investigación, se diseñó un filtro digital adaptativo con la estructura general de un filtro pasa bajas tipo Butterworth. Esta elección se basó en la capacidad del filtro para proporcionar una respuesta de frecuencia suave y plana en la banda de paso. Además, su naturaleza adaptativa permite que el filtro se ajuste a diferentes tipos de pruebas, lo que es fundamental para aplicaciones en sistemas BCI que pueden enfrentarse a una amplia variedad de escenarios y bases de datos.

Inicialmente, se configuró el filtro como uno de orden 5, basado en un equilibrio entre la eficiencia en la eliminación de ruido y la preservación de la calidad de la señal. Sin embargo, se diseñó el sistema de filtrado con la flexibilidad necesaria para modificar este parámetro según sea necesario. Esto significa que el filtro puede ser fácilmente reajustado para adaptarse a diferentes problemas relacionados con el ruido en las señales EEG, ya sea aumentando el orden del filtro para una mayor atenuación de ruido o reduciéndolo para evitar la sobre-filtración y la pérdida de información crucial de la señal.

Este enfoque modular y adaptable en el diseño del filtro asegura que pueda ser utilizado de manera eficaz en una variedad de situaciones, desde pruebas experimentales hasta aplicaciones prácticas en sistemas BCI. La combinación de una sólida base teórica en la elección del filtro y una implementación flexible en Python nos permite abordar eficientemente los desafíos asociados con el ruido en las señales EEG, maximizando así la efectividad de los sistemas BCI en los que se implemente nuestro filtro.

4.0.4. Simulación del filtro

Una vez que se tuvieron los valores teóricos del filtro, se realizó una simulación para verificar que funcionará correctamente, de esta manera, se pudo comprobar que los valores teóricos son los correctos para la implementación física del filtro y esto se muestra en la Figura 4.3 donde se simuló una señal senoidal con ruido, la cual se encontraba en una amplitud de 2 Hz, pero cuando se ve la señal filtrada, la amplitud cambio a 1 Hz y el ruido en la señal senoidal desapareció.

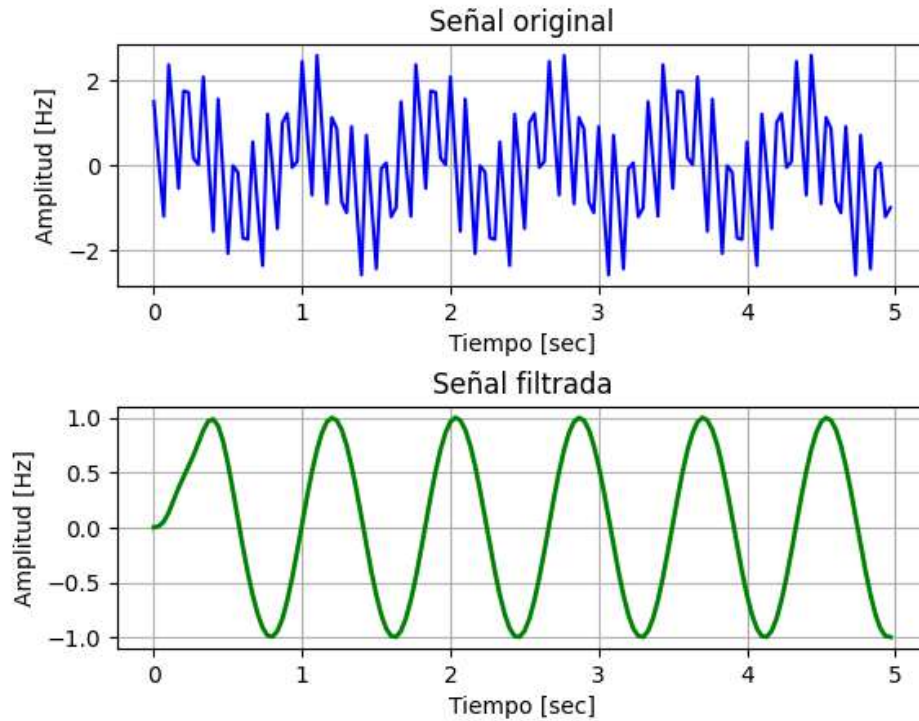


Figura 4.3: Gráficas de los resultados teóricos del filtro.

4.0.5. Implementación del filtro

Con los valores teóricos comprobados mediante la simulación, se procedió a modificar el código del filtro para su implementación en el sistema BCI. La característica principal que se modificó fue la entrada de datos, que si bien, en la simulación era de manera directa, se cambió para que los datos los obtuviera de una base de datos en Excel. No obstante, al implementar el filtro en diferentes bases de datos, se obtuvieron resultados bastante favorables, ya que al aplicar el filtro en múltiples pruebas diferentes, se logró el resultado esperado de obtener una reducción del ruido en un rango mayor al 40%, además de que se logró encontrar la frecuencia de corte óptima en cada experimento realizado, esto con la finalidad de ayudar a futuras investigaciones que requieran saber este mismo dato.

A continuación se muestra el código final con el cual se diseñó el filtro de esta tesis, en donde cabe destacar que la letra ñ fue cambiada por la n y los acentos fueron removidos por errores de compatibilidad del formato:

```

1 import numpy as np
2 from scipy.signal import butter, lfilter, freqz
3 from scipy.signal import filtfilt
4 import matplotlib.pyplot as plt
5 import pandas as pd
6
7 def butter_lowpass(cutoff, fs, order=5):
8     nyq = 0.5 * fs
9     normal_cutoff = cutoff / nyq
10    b, a = butter(order, normal_cutoff, btype='low', analog=False)

```



```

11     return b, a
12
13 def butter_lowpass_filter(data, cutoff, fs, order=5):
14     b, a = butter_lowpass(cutoff, fs, order=order)
15     y = filtfilt(b, a, data)
16     return y
17
18 def find_optimal_cutoff(data, fs, target_noise_reduction=0.5, max_iterations=1000,
19 tolerance=0.01):
20     min_cutoff = 1
21     max_cutoff = fs / 5
22     iteration = 0
23     current_cutoff = max_cutoff / 2
24     while iteration < max_iterations:
25         filtered_signal = butter_lowpass_filter(data, current_cutoff, fs)
26         noise_reduction = np.std(data - filtered_signal) / np.std(data)
27
28         if np.abs(noise_reduction - target_noise_reduction) < tolerance:
29             break
30
31         if noise_reduction < target_noise_reduction:
32             max_cutoff = current_cutoff
33         else:
34             min_cutoff = current_cutoff
35
36         current_cutoff = (max_cutoff + min_cutoff) / 2
37         iteration += 1
38
39     return current_cutoff, filtered_signal
40 # Configuración del filtro
41 fs = 30
42
43 datos_eeg = pd.read_csv("EEG_Eye_State_Classification.csv")
44
45 data = datos_eeg['P7'].values
46
47 # Calcular el ruido antes de aplicar el filtro
48 noise_before_filter = np.std(data)
49
50 # Encontrar el valor de corte óptimo para resaltar las ondas alfa y aplicar el
51 filtro
52 optimal_cutoff, filtered_signal = find_optimal_cutoff(data, fs,
53 target_noise_reduction=0.4)
54
55 # Calcular el ruido después de aplicar el filtro
56 noise_after_filter = np.std(filtered_signal)
57
58 # Trazar las señales originales y filtradas
59 plt.figure(figsize=(10, 6))
60
61 fig, ax = plt.subplots()
62 ax.plot(data, 'b-', label='Señal original (EEG)', linewidth=1)
63 ax.plot(filtered_signal, 'r-', label='Señal filtrada', linewidth=1)
64 ax.set_xlim(2000, 2500)
65 ax.set_ylim(4560, 4650)

```

```

64 plt.title('Comparacion de Senales EEG con Zoom')
65 plt.xlabel('Muestras')
66 plt.ylabel('Amplitud')
67 plt.legend()
68 plt.grid()
69 plt.show()
70
71 # Mostrar la frecuencia de corte y los espectros en frecuencia
72 print(f"Valor de corte optimo: {optimal_cutoff} Hz")
73 print(f"Ruido antes de aplicar el filtro: {noise_before_filter}")
74 print(f"Ruido despues de aplicar el filtro: {noise_after_filter}")
75
76 # Calculo y visualizacion del espectro en frecuencia antes y despues de filtrar
77 frequencies_before, power_spectrum_before = np.fft.rfftfreq(data.size, d=1./fs), np.
    abs(np.fft.rfft(data))**2
78 frequencies_after, power_spectrum_after = np.fft.rfftfreq(filtered_signal.size, d
    =1./fs), np.abs(np.fft.rfft(filtered_signal))**2
79
80 plt.figure(figsize=(10, 6))
81 plt.loglog(frequencies_before, power_spectrum_before, label='Antes de Filtrar',
    linewidth = 1)
82 plt.loglog(frequencies_after, power_spectrum_after, label='Despues de Filtrar',
    linewidth = 1)
83 plt.title('Espectro en Frecuencia de la Senal EEG')
84 plt.xlabel('Frecuencia (Hz)')
85 plt.ylabel('Potencia')
86 plt.axvline(x=optimal_cutoff, color='k', linestyle='—', label=f'Corte Optimo: {
    optimal_cutoff} Hz')
87 plt.legend()
88 plt.grid()
89 plt.show()

```

El código se estructura en tres funciones principales:

1. *butter_lowpass(cutoff, fs, order=5)*: Permite diseñar un filtro de Butterworth de baja frecuencia. La función acepta una frecuencia de corte (*cutoff*), una frecuencia de muestreo (*fs*) y un orden de filtro opcional (*order*). Se utiliza la función *butter* de *scipy.signal* para calcular los coeficientes del filtro (b, a) basándose en la frecuencia de corte normalizada.
2. *butter_lowpass_filter*: Se utiliza para aplicar el filtro diseñado en la función *butter_lowpass* a una señal de entrada (*data*). Siendo un filtro de quinto orden, cada etapa introduce un cambio de fase que podría sumar hasta 90 grados por etapa en la frecuencia de corte, lo que lleva a un cambio de fase total de hasta 450 grados a lo largo de la banda de transición, es por eso que esta función evita el desplazamiento de fase. Esto se logra mediante la función *filtfilt* de *scipy.signal*, el cual es un método de filtrado en dos etapas conocido como filtrado de fase cero, el cual evita el desplazamiento de fase al filtrar primero hacia adelante y luego hacia atrás.
3. *find_optimal_cutoff*: Esta función busca de manera iterativa el valor de frecuencia de corte óptimo que logra una reducción de ruido objetivo en la señal EEG filtrada. También permite definir el orden del filtro y su caracterización para que el filtrado de fase cero mantenga equilibrada la pendiente de la respuesta en frecuencia en ves de aumentarla.

Para poder realizar estas funciones, se utilizaron las ecuaciones 2.10, 2.11 y 2.12. Además, se tomaron en cuenta los siguientes puntos:

- **Búsqueda del Valor de Corte Óptimo:** Se realiza una búsqueda iterativa para encontrar el valor de corte óptimo que maximiza la reducción de ruido en la señal, empleando un enfoque de búsqueda binaria.
- **Evaluación del Desempeño del Filtro:** La eficacia del filtro se evalúa comparando la desviación estándar de la señal antes y después del filtrado para cuantificar la reducción del ruido [72].

4.0.6. Bases de datos utilizadas

Las principales bases de datos que se utilizaron para documentar los resultados de esta tesis se pueden encontrar en los repositorios de Github. En la primera base de datos se realizó una medición de señales EEG continua con el programa Emotiv EEG Neuroheadset. El estudio se realizó para detectar a través de una cámara el estado de los ojos durante la medición de las señales EEG, este estudio se realizó en 14 personas [84].

La segunda base de datos, que es una de las más extensas, consta con más de 1500 registros de señales EEG, obtenidos de 109 voluntarios mediante el uso del sistema BCI2000. Este estudio se realizó para caracterizar el comportamiento cerebral de las personas al realizar diferentes tareas motoras mientras observaban diferentes imágenes [85].

Consideraciones éticas

Debido a que esta tesis está adecuada para el diseño de un dispositivo que trabaja directamente con personas para el análisis de las señales EEG, es importante tener en cuenta algunos protocolos necesarios en cuestiones de ética para poder realizar algún tipo de prueba por parte de cualquier investigador que siga la información de esta tesis, los cuales son: Todas las personas involucradas en pruebas deberán ser informadas por completo de los procedimientos que se realizaran, de la misma manera. Se deberá seguir el artículo 4 de la Carta Magna el cual señala que toda persona tiene derecho a la protección de la salud, por lo cual todo participante se le debe proporcionar en caso de ser necesario o solicitado, un chequeo médico después de realizarse cualquier prueba correspondiente para asegurar que no hubo algún tipo de problema consecuente a las pruebas.

Toda prueba realizada debe estar con base en la norma oficial mexicana NOM-022-STPS-2008, que establece las condiciones de seguridad en los centros de trabajo para prevenir los riesgos por electricidad estática. Se deben tener en cuenta los requisitos de seguridad y métodos de prueba de aparatos electrónicos considerados en la norma NOM-001-SCFI-2018, así mismo se debe contar como base para la selección de las condiciones y protecciones necesarias para evitar accidentes o daños en la salud de los participantes. Las estrategias aplicadas para cumplir con las condiciones y la completa seguridad durante el desarrollo de alguna prueba se resumen en los siguientes puntos:

- Para mantener la seguridad de todos los voluntarios, se debe realizar un chequeo general de todo el equipo antes de ser utilizado, en caso de que algún componente contara con algún tipo de falla, sin importar que tan mínimo sea, se debe remplazar inmediatamente.
- Todo persona que se someta a alguna prueba donde se utilice el filtro, debe llenar una carta de consentimiento que acreditara que se encontraban en un buen estado de salud y que en pleno uso de sus facultades mentales realizaron la prueba de manera voluntaria.
- Se debe mantener una total confidencialidad en toda la información proporcionada por los voluntarios.
- En caso de realizarse alguna prueba en una persona catalogada como menor de edad, se debe respetar el artículo 63 que especifica que la protección de la salud física y mental de los menores es una responsabilidad que comparten los padres o tutores legales.

Resultados obtenidos

Una vez implementado el filtro a la base de datos obtenida con las pruebas de los sistemas BCI, se obtuvieron diferentes resultados, los cuales en su mayoría lograron el objetivo de reducir el ruido en un rango del 40 % al 50 %, pero para tener un mejor resultado visual, se tuvo que parametrizar nuevamente el código del filtro para obtener los resultados mostrados a continuación. Las gráficas se muestran en dos grupos: la señal EEG y el espectro en frecuencia de la señal, con lo cual se puede ver que se está reduciendo el ruido obtenido. No obstante, los datos numéricos obtenidos al aplicar el filtro se muestran antes de cada grupo respectivo de gráficas.

Cabe resaltar que los resultados mostrados en las pruebas 1 hasta la 7 se obtuvo una reducción del ruido en los rangos del 40 % al 50 %, pero en las pruebas 8, 9 y 10, la reducción de ruido obtenido es del 4 % al 5 %, esto se debe a que estas pruebas ya habían sido tratadas anteriormente con otros filtros, lo cual demuestra que el filtro diseñado en esta tesis puede implementarse a otros filtros para mejorar los resultados esperados en los análisis con sistemas BCI.

- Prueba 1
 - Valor de corte óptimo: 5.0 Hz.
 - Ruido antes de aplicar el filtro: 2924.691912547068
 - Ruido después de aplicar el filtro: 1623.6647213773858

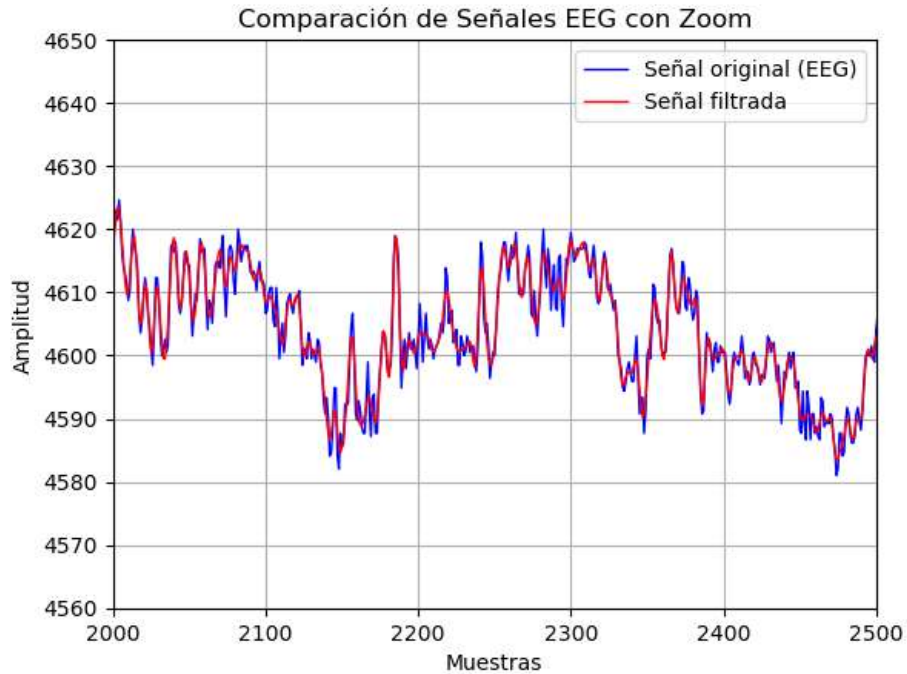


Figura 6.1: Gráfica de la señal EEG de la prueba 1.

En la gráfica 6.1 se puede observar que la señal filtrada, la cual está mostrada como la línea roja, cuenta con menor ruido que la señal original. No obstante, a pesar de que el filtro es de orden 5, la señal no muestra un cambio de fase gracias al método de filtrado de fase cero, el cual evita el desplazamiento de fase a cambio de un aumento en la pendiente de la respuesta en frecuencia, pero para evitar esto, se caracterizó el filtro y se comprobó su correcto funcionamiento al realizar una gráfica del espectro en frecuencia, permitiendo a su vez el uso del filtro de orden 5.

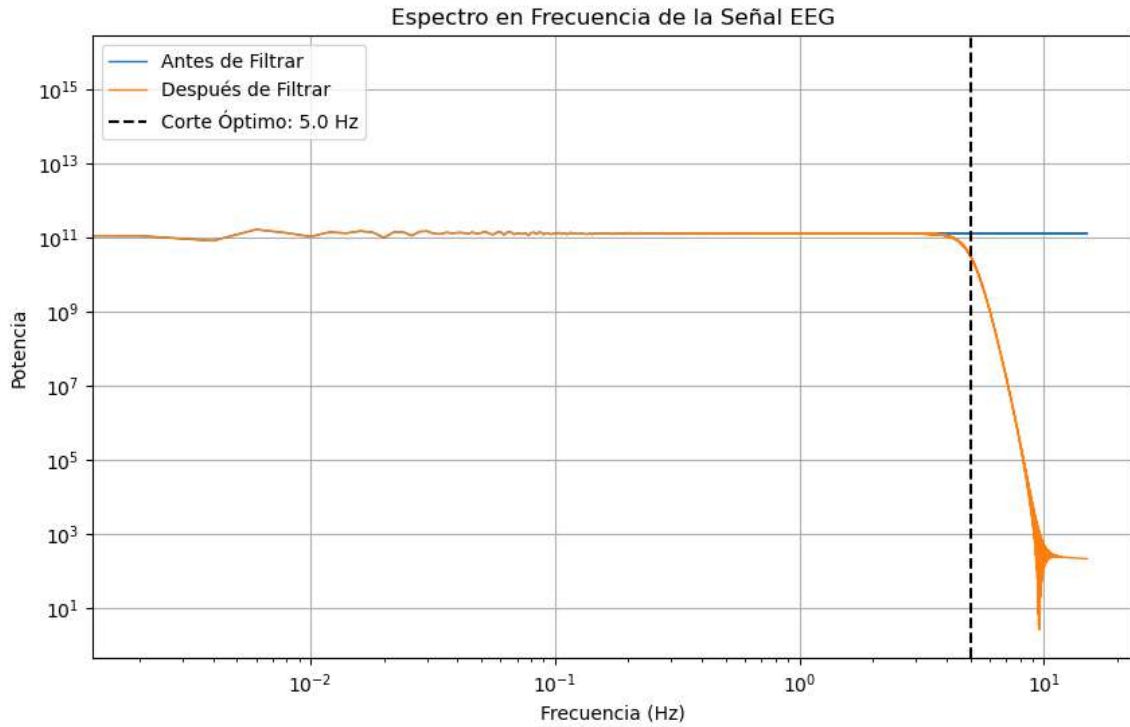


Figura 6.2: Gráfica del espectro en frecuencia de la señal EEG de la prueba 1.

En la gráfica 6.2 se puede observar que la señal filtrada se encuentra cerca a la señal original hasta el punto de corte óptimo de 5 Hz. Esto indica que el filtro ha mantenido de manera correcta la información en el rango de baja frecuencia. No obstante, la pendiente de la caída después de la frecuencia de corte es muy notable, pero esto es característico de los filtros Butterworth, lo cual muestra una buena separación entre la banda de paso y la banda de rechazo.

A continuación se muestran otras pruebas documentadas con la aplicación del filtro.

■ Prueba 2

- Valor de corte óptimo: 5.0 Hz.
- Ruido antes de aplicar el filtro: 2491.988992897752
- Ruido después de aplicar el filtro: 1383.3963948833318

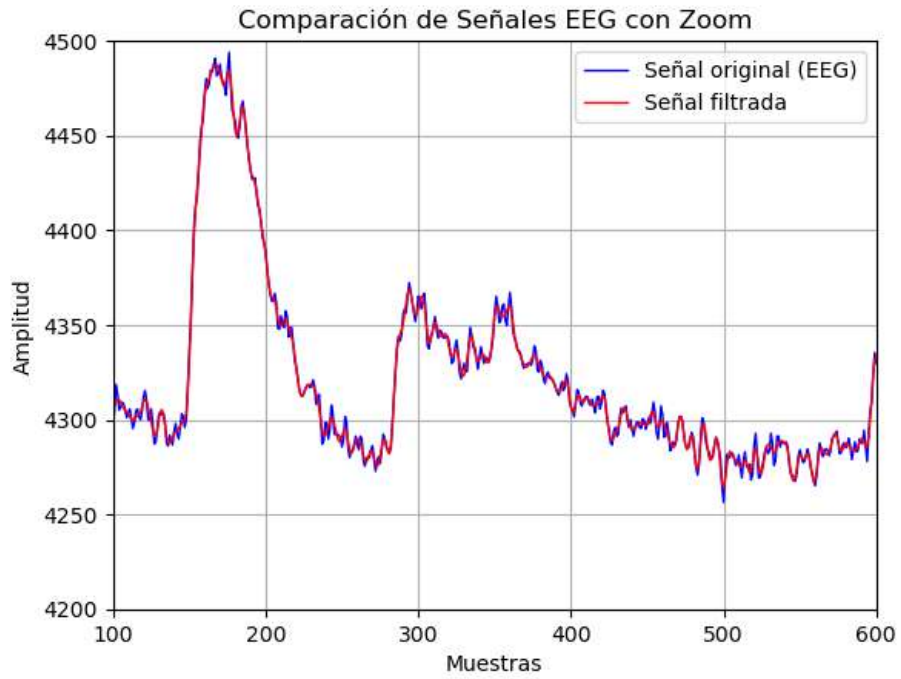


Figura 6.3: Gráfica de la señal EEG de la prueba 2.




Figura 6.4: Gráfica del espectro en frecuencia de la señal EEG de la prueba 2.

■ Prueba 3

- Valor de corte óptimo: 5.0 Hz.
- Ruido antes de aplicar el filtro: 5216.230517089912
- Ruido después de aplicar el filtro: 2895.454813813438




Figura 6.5: Gráfica de la señal EEG de la prueba 3.

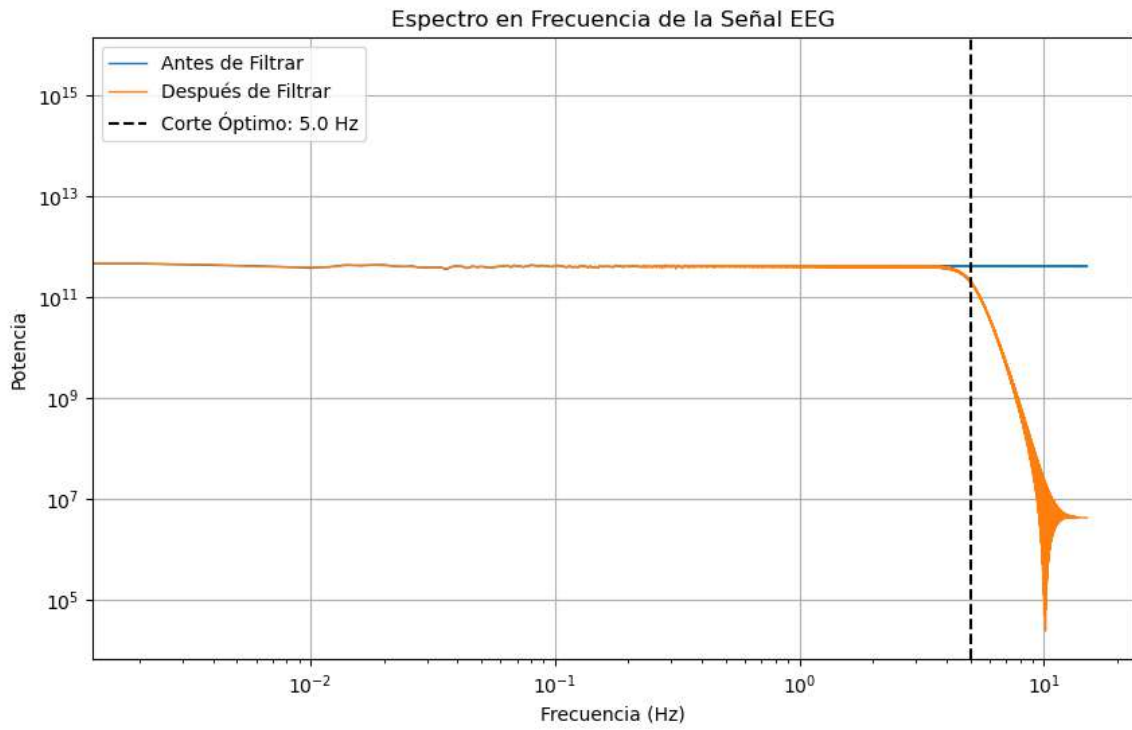


Figura 6.6: Gráfica del espectro en frecuencia de la señal EEG de la prueba 3.

■ Prueba 4

- Valor de corte óptimo: 5.0 Hz.
- Ruido antes de aplicar el filtro: 4600.772970994082
- Ruido después de aplicar el filtro: 2553.730902167921




Figura 6.7: Gráfica de la señal EEG de la prueba 4 sin aplicar el filtrar.




Figura 6.8: Gráfica del espectro en frecuencia de la señal EEG de la prueba 4.

■ Prueba 5

- Valor de corte óptimo: 5.0 Hz.
- Ruido antes de aplicar el filtro: 2136.3372130015923
- Ruido después de aplicar el filtro: 1186.0117529078154




Figura 6.9: Gráfica de la señal EEG de la prueba 5 sin aplicar el filtrar.




Figura 6.10: Gráfica del espectro en frecuencia de la señal EEG de la prueba 5.

■ Prueba 6

- Valor de corte óptimo: 5.0 Hz.
- Ruido antes de aplicar el filtro: 1208.3296248072675
- Ruido después de aplicar el filtro: 671.2265419109799




Figura 6.11: Gráfica de la señal EEG de la prueba 6 sin aplicar el filtrar.

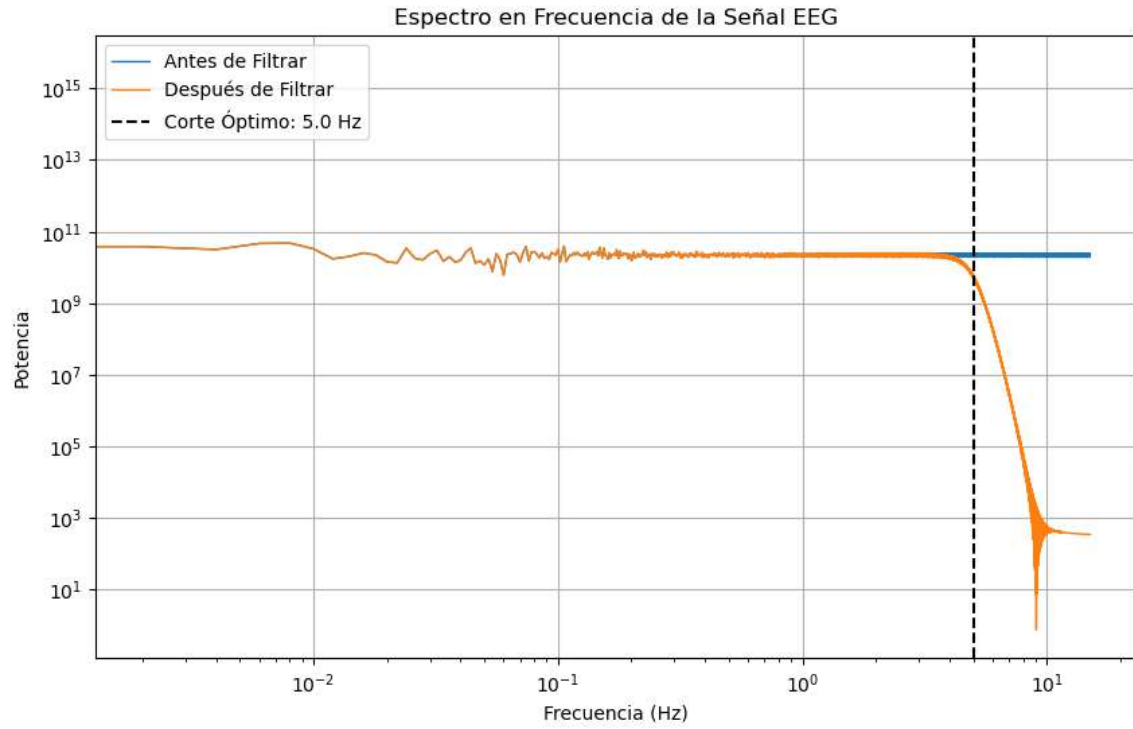


Figura 6.12: Gráfica del espectro en frecuencia de la señal EEG de la prueba 6.

■ Prueba 7

- Valor de corte óptimo: 5.0 Hz.
- Ruido antes de aplicar el filtro: 5891.088400889177
- Ruido después de aplicar el filtro: 3269.6243974458193




Figura 6.13: Gráfica de la señal EEG de la prueba 7 sin aplicar el filtrar.




Figura 6.14: Gráfica del espectro en frecuencia de la señal EEG de la prueba 7.

■ Prueba 8

- Valor de corte óptimo: 2.5 Hz.
- Ruido antes de aplicar el filtro: 0.1823463394987607
- Ruido después de aplicar el filtro: 0.17776388916918312




Figura 6.15: Gráfica de la señal EEG de la prueba 8 sin aplicar el filtrar.

■ Prueba 9

- Valor de corte óptimo: 2.5 Hz.
- Ruido antes de aplicar el filtro: 0.14959046878371718
- Ruido después de aplicar el filtro: 0.14402224506762004




Figura 6.16: Gráfica de la señal EEG de la prueba 9 con el filtro aplicado.

■ Prueba 10

- Valor de corte óptimo: 2.5 Hz.
- Ruido antes de aplicar el filtro: 0.11563827286381599
- Ruido después de aplicar el filtro: 0.11091249266498299




Figura 6.17: Gráfica de la señal EEG de la prueba 10 sin aplicar el filtrar.

Es importante aclarar que las pruebas 8, 9 y 10 no cuentan con la gráfica de espectro en frecuencia, ya que al ser pruebas donde ya se había utilizado un procesamiento con otros filtros, el resultado varía bastante dependiendo de cada prueba. Además, debido a este último punto, el método de filtrado por fase cero no resulta conveniente, ya que atenúa de más las señales EEG, es por este motivo que se utiliza un método convencional en el filtro usando el comando *filtfilt* de *scipy.signal*, lo cual permite mantener un filtrado más tenue pero con un ligero desplazamiento en la fase.

En la tabla 6.1 se muestra un resumen de los datos obtenidos de las pruebas, así como su porcentaje de la reducción del ruido obtenido, en donde las pruebas 1 a la 7 el único procesamiento de datos realizado fue con el filtro de esta tesis, mientras que las pruebas 8 a la 10 ya cuentan con un procesamiento anterior, lo cual verifica que el filtro se adecua bien a trabajar con otros filtros. En la tabla 6.2 se muestra el promedio de los porcentajes del error obtenidos en las pruebas

Cuadro 6.1: Resultados obtenidos en las pruebas

Número de prueba	Ruido sin el filtro	Ruido con el filtro	Reducción del error
1	2924.6919	1623.6647	44.4 %
2	2491.9889	1383.3963	44.5 %
3	5216.2305	2895.4548	44.5 %
4	4600.7729	2553.7309	44.5 %
5	2136.3372	1186.0117	44.4 %
6	1208.3296	671.2265	44.4 %
7	5891.0884	3269.6243	44.5 %
8	0.1823	0.1777	2.4 %
9	0.1495	0.1440	3.7 %
10	0.1156	0.1109	4.1 %

Cuadro 6.2: Promedio del porcentaje del error obtenido en las pruebas

Número de prueba	Promedio del porcentaje del error
1 - 7	44.4 %.
8 - 10	3.4 %

Para reforzar la validez del filtro, se utilizó la ecuación 2.9 para conocer la desviación estándar y utilizando los resultados de la prueba 2, se obtuvieron los siguientes resultados:

Dado el ruido antes del filtrado de $\sigma_{\text{antes}} = 2491,99$ y buscando una reducción teórica del ruido de al menos un 40 %, pero menos de un 50 %, la desviación estándar después del filtrado se estimo como:

$$\sigma_{\text{después}} = \sigma_{\text{antes}} \times (1 - R)$$

Con $R = 0,44$, se obtiene:

$$\sigma_{\text{después}} = 2491,99 \times (1 - 0,4) = 1395,11744$$

Como los resultados obtenidos de la prueba con el filtro fueron: Ruido después de aplicar el filtro = 1383,3963 y el resultado teórico fue de 1395,1174, el margen de error entre el resultado teórico y el resultado obtenido es de $\pm 0,84\%$. , con lo cual se puede validar teóricamente la efectividad del filtro en la reducción esperada del ruido.

En la tabla 6.3 se muestra el margen de error de todas las pruebas mostradas anteriormente, en donde se observa que el margen de error de las pruebas donde solo se aplicó el filtro de esta tesis se encuentra debajo del 1%, mientras que las pruebas donde hubo un procesamiento antes del filtro, el margen de error varía dependiendo de los decimales utilizados.

Cuadro 6.3: Margen de error de las pruebas.

Núm. de prueba	Valor teórico	Valor real	Margen de error
1	1638.912	1623.664	0.92 %
2	1395.117	1383.396	0.83 %
3	2923.062	2895.454	0.94 %
4	2576.431	2553.730	0.88 %
5	1196.821	1186.011	0.90 %
6	677.228	671.226	0.88 %
7	3297.641	3269.624	0.84 %
8	0.166	0.177	6.63 %
9	0.086	0.144	66.67 %
10	0.165	0.110	6.82 %

Conclusión

Basado en la investigación y resultados obtenidos, el filtro pasa bajas propuesto para la mejora de la calidad de señales EEG en un sistema BCI ha demostrado ser efectivo en la reducción significativa del ruido presente en las señales EEG. Con un valor de corte óptimo de 5.0 Hz dependiendo de la prueba realizada, se logró una disminución del 44 % del ruido en cada prueba, lo cual evidencia una mejora considerable en la calidad de las señales EEG capturadas.

Durante el proceso de validación, se llevaron a cabo 10 pruebas, de las cuales 7 mostraron una reducción del ruido superior al 40 %, cumpliendo así con la hipótesis planteada y los objetivos propuestos inicialmente. Sin embargo, es importante destacar que en 3 de estas pruebas, la reducción del ruido fue solo entre un 4 % y un 5 %. Este comportamiento se observó en pruebas realizadas con señales previamente procesadas por otro filtro, lo cual no solo valida la hipótesis de que el filtro diseñado es capaz de trabajar de manera eficiente en conjunto con otros sistemas de filtrado, sino que también demuestra su capacidad para preservar la integridad de las señales EEG sin sobre filtrarlas.

La mayor aportación científica en esta tesis es se encuentra en creación de un filtro que puede utilizarse en diversas pruebas, ya que cuenta con los siguientes puntos importantes:

- Mejora en la claridad de las señales, ya que es efectivo para eliminar las frecuencias no deseadas. Esto es beneficioso para el análisis detallado y la interpretación de las señales EEG.
- Preserva la información temporal, pues al no haber desplazamiento de fase, la información temporal en la señal se conserva mejor, lo que es esencial para el análisis temporal preciso en estudios que dependen de la sincronización de la señal, como la correlación de eventos neuronales específicos en el tiempo, por ejemplo, en la epilepsia, la fase es muy relevante porque las crisis epilépticas pueden caracterizarse por una sincronización anormal de la actividad neuronal. Esto a su vez permite tener una fiabilidad en la interpretación, ya que la señal filtrada refleja más fielmente la señal original en términos de eventos y su ocurrencia temporal.
- Eficacia del método de filtrado de fase cero: La aplicación exitosa del filtrado de fase cero demuestra que esta técnica puede ser una herramienta valiosa en el procesamiento de señales EEG, siempre y cuando se logre mantener una correcta configuración en el filtro donde se aplique.

Con todo esto, se puede verificar que sin importar que el filtro es de orden 5, su correcta caracterización permite que cumpla su objetivo de reducir el ruido de las señales EEG de manera correcta, manteniendo la capacidad de ser aplicado mediante dispositivos de bajo costo y/o en colaboración con otros filtros.

Este hallazgo es particularmente relevante en el contexto de la salud mental en México, donde la utilización de tecnologías BCI cobra importancia legislativa y social. La capacidad del filtro para integrarse con otros sistemas de filtrado amplía las posibilidades de uso en diferentes contextos clínicos y de investigación, potenciando la extracción de señales EEG de alta calidad para el diagnóstico y tratamiento de trastornos neuropsiquiátricos y el estudio de fenómenos sociales relacionados con la salud mental.

En conclusión, este estudio contribuye significativamente al campo de la neurotecnología y la salud mental, proveyendo una herramienta valiosa para la mejora de las interfaces cerebro-computadora y la calidad de las señales EEG, lo que puede facilitar avances en el tratamiento y comprensión de diversas condiciones neuropsiquiátricas y su impacto social.

Bibliografía

- [1] L. J. G. Figueroa, “Análisis de señales eeg para detección de eventos oculares, musculares y cognitivos,” trabajo de fin de maestría, Universidad Politécnica de Madrid, Madrid, Spain, Sept. 2016.
- [2] J. Colmenar Renteria, “Proyecto de decreto,” 2022.
- [3] N. Yeung, M. M. Botvinick, and J. D. Cohen, “The neural basis of error detection: Conflict monitoring and the error-related negativity.,” *Psychological Review*, vol. 111, no. 4, p. 931, 2004.
- [4] P. Rabbitt, “Error correction time without external error signals,” *Nature*, vol. 212, no. 5060, pp. 438–438, 1966.
- [5] P. Rabbitt, “Time to detect errors as a function of factors affecting choice-response time,” *Acta Psychologica*, vol. 27, pp. 131–142, 1967.
- [6] P. M. Rabbitt, “Three kinds of error-signalling responses in a serial choice task,” *Quarterly Journal of Experimental Psychology*, vol. 20, no. 2, pp. 179–188, 1968.
- [7] G. Prete, P. Croce, F. Zappasodi, L. Tommasi, and P. Capotosto, “Exploring brain activity for positive and negative emotions by means of EEG microstates,” *Scientific Reports*, vol. 12, no. 1, pp. 1–11, 2022.
- [8] N. Perez-Prieto, A. Rodriguez-Vazquez, M. Alvarez-Dolado, and M. Delgado-Restituto, “A 32-Channel Time-Multiplexed Artifact-Aware Neural Recording System,” *IEEE Transactions on Biomedical Circuits and Systems*, vol. 15, no. 5, pp. 960–977, 2021.
- [9] L. M. S. REYES *et al.*, “Diseño e implementación de un sistema bci para el análisis de eeg.,” 2019.
- [10] D. C. Toledo-Pérez, J. Rodríguez-Reséndiz, R. A. Gómez-Loenzo, and J. C. Jauregui-Correa, “Support Vector Machine-based EMG signal classification techniques: A review,” *Applied Sciences (Switzerland)*, vol. 9, no. 20, 2019.
- [11] W. Hohaia, B. W. Saurels, A. Johnston, K. Yarrow, and D. H. Arnold, “Occipital alpha-band brain waves when the eyes are closed are shaped by ongoing visual processes,” *Scientific Reports*, vol. 12, no. 1, p. 1194, 2022.

- [12] J. M. Fiore, *Operational Amplifiers and Linear Integrated Circuits*. California: LibreTexts, 1 ed., 2016.
- [13] A. S. Guzmán and A. C. Ramírez, “Introduciendo sigprou, una interfaz gráfica de usuario para el análisis y procesamiento de señales eeg,” *Ciencia Latina Revista Científica Multidisciplinar*, vol. 5, no. 6, pp. 13060–13074, 2021.
- [14] M. Schmoigl, C. Schranz, and G. R. Müller-Putz, “Methods for motion artifact reduction in online brain-computer interface experiments: a systematic review,” *Frontiers in Human Neuroscience*, vol. 8, pp. 1–17, 2023.
- [15] K. TEKİN and H. GÜLER, “Second generation current controlled current conveyor based low pass filter design for the processing of eeg signals,” *Turkish Journal of Science and Technology*, vol. 18, no. 2, pp. 405–413, 2023.
- [16] N. Mirchandani and A. Shrivastava, “High stability gain structure and filter realization with less than 50 ppm/° c temperature variation with ultra-low power consumption using switched-capacitor and sub-threshold biasing,” in *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*, pp. 1–5, 2018.
- [17] S. Cogollos Borrás, “Fundamentos de la teoría de filtros,” *Colección Manual de referencia*, 2016.
- [18] J. I. Huircán, “Filtros activos, conceptos básicos y diseño,” *Departamento de Ingeniería Eléctrica, Universidad de La Frontera. Araucanía, Chile*, 2012.
- [19] E. Pérez, “Implementación de filtros pasa baja: Bessel y chebyshev,” 2017.
- [20] D. Báez-Villegas, D. Báez-López, and P. Cholula, “Diseño, realizacion y sensibilidad de filtros elipticos modificados,”
- [21] I. Bravo, A. Gardel, A. Hernández, R. Mateos, F. Meca, and R. Rivera, “Implementación de filtros fir en fpga’s,” 1970.
- [22] J. Guiñón, E. Ortega, J. G.-A. Aviñó, and V. P. Herranz, “Filtrado de senales (i): Implementación y análisis del filtro de media móvil,” *Ingeniería química*, no. 448, pp. 220–227, 2007.
- [23] J. R. R. Fernández, *Filtro analógico pasa bajas de segundo orden con parámetros variantes en el tiempo*. PhD thesis, Master’s thesis, Instituto Nacional de Astrofisica, Optica y Electrónica, 2012.
- [24] M. Unser and A. Aldroubi, “A review of wavelets in biomedical applications,” *Proceedings of the IEEE*, vol. 84, no. 4, pp. 626–638, 1996.
- [25] A. J. Casson, D. C. Yates, S. Patel, and E. Rodriguez-Villegas, “An analogue bandpass filter realisation of the continuous wavelet transform,” in *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1850–1854, 2007.
- [26] R. G. Gutierrez Gallegos, “Análisis y diseño de un filtro notch basado en anillos resonadores abiertos srr de triple banda 2.5/4/5.5ghz,” 2021.

- [27] H. Chu, Y. Cao, J. Jiang, J. Yang, M. Huang, *et al.*, “Optimized electroencephalogram and functional near-infrared spectroscopy-based mental workload detection method for practical applications,” *BioMedical Engineering OnLine*, vol. 21, no. 1, p. 9, 2022.
- [28] N. Sharma, S. Jain, K. Sharma, and S. Malhotra, “Design of a low-power 3rd order notch filter for biomedical applications,” in *2022 IEEE International Conference of Electron Devices Society Kolkata Chapter (EDKCON)*, pp. 509–512, IEEE, 2022.
- [29] B. Aldalur and M. Santamaría, “Realce de imágenes: filtrado espacial,” *Revista de Teledetección*, vol. 17, no. 2, pp. 31–42, 2002.
- [30] F. Serbet and T. Kaya, “Statistical analysis and eeg signal filtering using design of window function based on optimization methods,” *Journal of Circuits, Systems and Computers*, vol. 32, no. 18, 2023.
- [31] M. Sharma, P. Makwana, R. S. Chad, and U. R. Acharya, “A novel automated robust dual-channel eeg-based sleep scoring system using optimal half-band pair linear-phase biorthogonal wavelet filter bank,” *Applied Intelligence*, pp. 1–19, 2023.
- [32] H. Hu, Z. Pu, H. Li, Z. Liu, and P. Wang, “Learning optimal time-frequency-spatial features by the cissa-csp method for motor imagery eeg classification,” *Sensors*, vol. 22, no. 21, p. 8526, 2022.
- [33] J. Barrera-García, F. Cisternas-Caneo, B. Crawford, M. Gómez Sánchez, and R. Soto, “Feature selection problem and metaheuristics: A systematic literature review about its formulation, evaluation and applications,” *Biomimetics*, vol. 9, p. 9, 2024.
- [34] A. Frizera, R. Ceres, and J. L. Pons, “Filtrado adaptativo de componentes involuntarias en marcha asistida por andador para detección de intenciones,” *Revista Iberoamericana de Automática e Informática Industrial RIAI*, vol. 8, no. 2, pp. 71–80, 2011.
- [35] A. Garcés Correa, L. L. Orosco, P. Diez, and E. Lacier Leber, “Adaptive filtering for epileptic event detection in the eeg,” *Journal of Medical and Biological Engineering*, vol. 39, pp. 912–918, 2019.
- [36] M. Akin, “Comparison of wavelet transform and fft methods in the analysis of eeg signals,” *Journal of Medical Systems*, vol. 26, no. 3, pp. 241–247, 2002.
- [37] M. Krishnappa and M. B. Anandaraaju, “Adaptive filters based efficient eeg classification for steady state visually evoked potential based bci system,” *International Journal of Reconfigurable and Embedded Systems (IJRES)*, vol. 12, no. 2, pp. 215–221, 2023.
- [38] F. E.-Z. M. Labib, I. A. Fouad, M. S. Mabrouk, and A. A. Sharawy, “Multiple classification techniques toward a robust and reliable p300 bci system,” *Biomedical Engineering: Applications, Basis and Communications*, vol. 32, no. 02, 2020.
- [39] A. E. Donoso, “Reducción de artefactos oculares en señales eeg: Filtrado adaptativo como alternativa a la regresión lineal,” 2009.
- [40] L. J. Padilla Sepúlveda *et al.*, “Implementación de un método de estimación y predicción espacio-tiempo con datos faltantes basado en filtro de kalman,” 2018.

- [41] K. P. L. B. G. Okuda, Kosuke; Højgaard and T. Takeuchi, “Initial memory consolidation and the synaptic tagging and capture hypothesis,” *European Journal of Neuroscience*, vol. 54, pp. 6826 – 6849, 2021.
- [42] M. Rahman and M. A. M. Joadder, “A space-frequency localized approach of spatial filtering for motor imagery classification,” *Health Information Science and Systems*, vol. 8, pp. 1–8, 2020.
- [43] R. Huang, K. Qing, D. Yang, and K.-S. Hong, “Real-time motion artifact removal using a dual-stage median filter,” *Biomedical Signal Processing and Control*, vol. 72, Part A, p. 103301, 2022.
- [44] N. Cheng and K. Murari, “Oserr: an open-source standalone electrophysiology recording system for rodents,” *Scientific Reports*, vol. 10, p. 13794, 2020.
- [45] S. Lee, J. Henry, A. K. Tryba, Y. Esengul, P. C. Warnke, S. Wu, and W. van Drongelen, “Digital reconstruction of infraslow activity in human intracranial recordings using a deconvolution-based inverse filter,” *Scientific Reports*, vol. 12, p. 13701, 2022.
- [46] A. Mur, R. Dormido, and N. Duro, “An unsupervised method for artefact removal in eeg signals,” *Sensors*, vol. 19, p. 2302, 2019.
- [47] D. R. Alkhorshid, S. F. Molaezadeh, and M. R. Alkhorshid, “Analysis: Electroencephalography acquisition system: Analog design,” *Biomedical Instrumentation & Technology*, vol. 54, no. 5, pp. 346–351, 2020.
- [48] M. Premkumar, S. Sathiya priya, M. Arun, and V. Sashan, “Medical signal processing via digital filter and transmission reception using cognitive radio technology,” *Traitement du Signal*, vol. 39, no. 4, pp. 1357–1362, 2022.
- [49] T. Pander, “Eeg signal improvement with cascaded filter based on owa operator,” *Signal, Image and Video Processing*, vol. 13, no. 6, pp. 1165–1171, 2019.
- [50] D. Bhati, R. B. Pachori, and V. M. Gadre, “Optimal design of three-band orthogonal wavelet filter bank with stopband energy for identification of epileptic seizure eeg signals,” in *Machine Intelligence and Signal Analysis*, pp. 197–207, Springer, 2019.
- [51] L. Barnes, K. Lee, A. Kempa-Liehr, and L. Hallum, “Detection of sleep apnea from single-channel eeg using convolutional neural networks,” *PLOS ONE*, vol. 17, no. 9, p. e0272167, 2022.
- [52] C. Brunner, A. Delorme, and S. Makeig, “Eeglab—an open source matlab toolbox for electrophysiological research,” *Biomedical Engineering/Biomedizinische Technik*, vol. 58, no. SI-1-Track-G, p. 000010151520134182, 2013.
- [53] R. Oostenveld, P. Fries, E. Maris, and J.-M. Schoffelen, “Fieldtrip: open source software for advanced analysis of meg, eeg, and invasive electrophysiological data,” *Computational Intelligence and Neuroscience*, vol. 2011, pp. 1–9, 2011.

- [54] B. Z. Sekerci, M. Y. Dikmen, and L. Hanoğlu, “An erp analysis of time-based and event-based prospective memory task,” *Anatomy: International Journal of Experimental & Clinical Anatomy*, vol. 13, 2019.
- [55] N. A. Badcock, K. A. Preece, B. de Wit, K. Glenn, N. Fieder, J. Thie, and G. McArthur, “Validation of the emotiv epoc eeg system for research quality auditory event-related potentials in children,” *PeerJ*, vol. 3, p. e907, 2015.
- [56] J. Vesanto, J. Himberg, E. Alhoniemi, J. Parhankangas, S. Team, and L. Oy, “Som toolbox for matlab 5,” tech. rep., Citeseer, 2000.
- [57] A. Gramfort, M. Luessi, E. Larson, D. A. Engemann, D. Strohmeier, C. Brodbeck, R. Goj, M. Jas, T. Brooks, L. Parkkonen, *et al.*, “Meg and eeg data analysis with mne-python,” *Frontiers in Neuroscience*, p. 267, 2013.
- [58] Y. Renard, F. Lotte, G. Gibert, M. Congedo, E. Maby, V. Delannoy, O. Bertrand, and A. Lécuyer, “Openvibe: An open-source software platform to design, test, and use brain-computer interfaces in real and virtual environments,” *Presence*, vol. 19, no. 1, pp. 35–53, 2010.
- [59] C. A. Kothe and S. Makeig, “Bcilab: a platform for brain-computer interface development,” *Journal of Neural Engineering*, vol. 10, no. 5, p. 056014, 2013.
- [60] Y. Miyadera, S. Nakamura, T. Nanashima, and S. Yokoyama, “Labchart: A support system for collaborative research activities in university laboratories and its practical evaluations,” in *2008 12th International Conference Information Visualisation*, pp. 169–178, IEEE, 2008.
- [61] B. Blankertz, R. Tomioka, S. Lemm, M. Kawanabe, and K.-R. Muller, “Optimizing spatial filters for robust eeg single-trial analysis,” *IEEE Signal Processing Magazine*, vol. 25, no. 1, pp. 41–56, 2007.
- [62] H. Wu, N. Yu, F. Li, B. Fu, G. Shi, and M. Dong, “A parallel multiscale filter bank convolutional neural networks for motor imagery eeg classification,” *Frontiers in Neuroscience*, vol. 13, p. 1275, 2023. Accessed: 2023-02-31.
- [63] F. Karimi, Q. Almeida, and N. Jiang, “Large-scale frontoparietal theta, alpha, and beta phase synchronization: A set of eeg differential characteristics for freezing of gait in parkinson’s disease?,” *Frontiers in Aging Neuroscience*, vol. 14, 2022.
- [64] U. Shah, M. Alzubaidi, F. Mohsen, A. Abd-Alrazaq, T. Alam, and M. Househ, “The role of artificial intelligence in decoding speech from eeg signals: A scoping review,” *Sensors*, vol. 22, no. 18, p. 6975, 2022.
- [65] M. J. Antony, B. P. Sankaralingam, R. K. Mahendran, A. A. Gardezi, M. Shafiq, J.-G. Choi, and H. Hamam, “Classification of eeg using adaptive svm classifier with csp and online recursive independent component analysis,” *Sensors*, vol. 22, no. 19, p. 7596, 2022.
- [66] K. Jia, Z. Liu, F. Qiao, X. Liu, Q. Wei, and H. Yang, “Aicnn: Implementing typical cnn algorithms with analog-to-information conversion architecture,” in *2017 IEEE Computer Society Annual Symposium on VLSI (ISVLSI)*, pp. 80–85, 2017.

- [67] S. Supriya, S. Siuly, H. Wang, and Y. Zhang, “Epilepsy detection from eeg using complex network techniques: A review,” *IEEE Reviews in Biomedical Engineering*, vol. 16, pp. 292–306, 2023.
- [68] Pawan and R. Dhiman, “Machine learning techniques for electroencephalogram based brain-computer interface: A systematic literature review,” *Measurement: Sensors*, vol. 28, p. 100823, 2023.
- [69] F. J. Pérez, “Filtros activos, el filtro pasa bajas.”
- [70] R. C. Dorf and R. H. Bishop, *Sistemas de control moderno*. Madrid: Pearson Educación, 10 ed., 2005.
- [71] R. V. Carrillo-Serrano, “Material didáctico control avanzado.” Notas de clase, 9 2022.
- [72] E. N. Bruce, *Biomedical Signal Processing and Signal Modeling*. Wiley-Interscience, 2001.
- [73] C. Guarnizo-Lemus, “Análisis de reducción de ruido en señales eeg orientado al reconocimiento de patrones,” *TecnoLógicas*, 2008.
- [74] Y. Zhang, N. Mirchandani, S. Abdelfattah, M. Onabajo, and A. Shrivastava, “An Ultra-Low Power RSSI Amplifier for EEG Feature Extraction to Detect Seizures,” *IEEE Transactions on Circuits and Systems II: Express Briefs*, vol. 69, no. 2, pp. 329–333, 2022.
- [75] S. Yu, M. Mückschel, and C. Beste, “Superior frontal regions reflect the dynamics of task engagement and theta band-related control processes in time-on task effects,” *Scientific Reports*, vol. 12, no. 1, pp. 1–14, 2022.
- [76] G. M. Wójcik, A. Kawiak, L. Kwasniewicz, P. Schneider, and J. Masiak, “Azure Machine Learning tools efficiency in the electroencephalographic signal P300 standard and target responses classification,” *Bio-Algorithms and Med-Systems*, pp. 1–8, 2019.
- [77] J. Cao, Y. Zhao, X. Shan, H.-l. Wei, Y. Guo, L. Chen, J. A. Erkoyuncu, and P. G. Sarrigiannis, “Brain functional and effective connectivity based on electroencephalography recordings: A review,” *Human Brain Mapping*, vol. 43, no. 2, pp. 860–879, 2022.
- [78] H. Chu, Y. Cao, J. Jiang, J. Yang, M. Huang, Q. Li, C. Jiang, and X. Jiao, “Optimized electroencephalogram and functional near-infrared spectroscopy-based mental workload detection method for practical applications,” *BioMedical Engineering Online*, vol. 21, no. 1, pp. 1–17, 2022.
- [79] L.-M. Sánchez-Reyes, J. Rodríguez-Reséndiz, G. N. AVECILLA-Ramírez, M.-L. García-Gomar, and J.-B. Robles-Ocampo, “Impact of eeg parameters detecting dementia diseases: A systematic review,” *IEEE Access*, vol. 9, pp. 78060–78074, 2021.
- [80] J. Bardasano-Rubio, J. De La Hoz-Fabra, J. Ramos-Jacome, J. UDE-De La Torre, and A. Fernández-Campo, “Medios de registro electroencefalográfico secuencial durante la estimulación magnética transcraneal de baja intensidad.” Patente, 7 2011.
- [81] A. Ortiz-Coso, M. Aguilar-Herrero, M. Lopez-Valdés, and J. Minguez-Zafra, “Electrodo de medida de electroencefalogramas.” Patente, 6 2014.

- [82] J. Changjun, Y. Chungang, and H. Hongzhong, C.and Lianghua, “Deep learning method based on mental imagery eeg data.” Patente, 6 2017.
- [83] F. Yunfa, S. Huiwen, Y. Zhengtao, and G. Jianyi, “Deep learning method based on mental imagery eeg data.” Patente, 9 2014.
- [84] O. Roesler, “EEG Eye State.” UCI Machine Learning Repository, 2013. DOI: <https://doi.org/10.24432/C57G7J>.
- [85] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, “Bci2000: A general-purpose brain-computer interface (bci) system,” *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1034–1043, 2004.

