



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

POSGRADO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN
INSTITUTO DE INVESTIGACIONES EN MATEMÁTICAS APLICADAS Y EN SISTEMAS

INTERFAZ CEREBRO COMPUTADORA (BCI) CON IMAGINACIÓN
MUSICAL

T E S I S

QUE PARA OPTAR POR EL GRADO DE:
MAESTRO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

PRESENTA:

JOSÉ FRANCISCO NERI GONZÁLEZ

Director de Tesis:
Dr. Caleb Antonio Rascón Estebané
IIMAS, UNAM

Ciudad Universitaria, CD.MX., diciembre 2018



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

"Por mi raza hablará el espíritu"
José Vasconcelos Calderón

Agradecimientos

A mi universidad

Gracias a la Universidad Nacional Autónoma de México por ser mi alma máter. Particularmente al IIMAS y demás entidades que conforman el posgrado PCIC, donde culminé una etapa más en mi formación académica.

A mi familia

Agradezco y dedico este trabajo a mi madre Enriqueta, a mi tía Marga y tía Cecilia por ser mis tres pilares principales y quienes me han apoyado a finalizar un logro más en mi vida; ustedes me impulsan a sacar lo mejor de mí. A mi hermana Mariana e hijos (Pilar y Eduardo), por darme su cariño incondicional en todo momento. Y a mi prima Paula e hijos, quienes estuvieron animándome desde que inicié a estudiar la maestría.

A mis amigos

Muchas gracias a Alejandra Villegas , Astrid Hollands y Adriana Gutiérrez por demostrarme su apoyo, cariño y amistad siempre. También a Lilivette Cruz, Norman Morales, Rosalba Merlos, Carlos Barrera y Gabriela Altamirano por ser los mejores amigos durante tantos años y ayudarme a sobrellevar momentos complicados de la maestría. Agradezco a Derek Cheung, Diana González, Gerardo González y Carlos Hernández por su compañerismo y amistad en esta etapa académica, fueron clave importante durante estos dos años; ustedes saben que los aprecio mucho. Le agradezco mucho a Hernando Ortega y equipo GIDETEC, por su apoyo y comprensión como equipo de trabajo y

por creer en mi durante el tiempo que colaboramos juntos en el proyecto de "Mano robótica".

A mi asesor

Gracias al Dr. Caleb Rascón Estebané por sus consejos, por ser un excelente profesor y asesor, por ser tan paciente y perseverante conmigo. Le agradezco por la organización y constancia que inyectó en mi para que este proyecto se lograra finalizar a tiempo y exitosamente.

A colaboradores

Gran parte de este proyecto no se hubiese logrado por la ayuda del M. C. Miguel Porta y su alumno Saúl Pérez, ambos académicos de la Universidad Autónoma Metropolitana, Unidad Iztapalapa, a quienes reconozco su apoyo y colaboración en la recolección adecuada del corpus EEG. También dedico este trabajo a la profesora Gabriela Pérez y sus alumnos de la Facultad de Música, UNAM por su participación y tiempo invertido en el protocolo de recolección de datos EEG. Por último, quiero agradecer al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico que me otorgó durante mi formación en la maestría.

A mis sinodales

Gracias a mis sinodales, por tomarse el tiempo para leer esta tesis y aconsejarme correctamente para presentar un trabajo de calidad.

Resumen

Actualmente existen diferentes tipos de interfaces que permiten la comunicación entre hombre-máquina. Básicamente el ser humano es capaz de interactuar con una computadora a través de diferentes canales de entrada/salida, por ejemplo: voz, visión, audición, tacto y movimiento. Sin embargo, existen dispositivos que permiten la comunicación hombre-máquina mediante el registro de actividad cerebral, y son conocidas como Interfaces Cerebro Computadora (BCI).

En los últimos años se han desarrollado cada vez más BCI's que permiten a los seres humanos interactuar con diversos tipos de aplicaciones, tales como: videojuegos, control de prótesis, robots, drones, entre otras. Actualmente los sistemas BCI han mostrado su verdadero potencial en varias aplicaciones, pero también han comenzado a ser muy utilizados en aplicaciones referentes a la música.

Esta tesis presenta una investigación en el área de imaginación musical como paradigma BCI junto con técnicas de aprendizaje automático. Es decir, explorar la identificación y clasificación de características presentes en la actividad cerebral de una persona en el momento exacto que imagina una actividad musical (imaginación musical).

En este proyecto se establece que un sistema capaz de identificar una actividad musical imaginada está conformado por una Interfaz Cerebro Computadora (BCI), un módu-

lo de análisis de señales EEG, un módulo de aprendizaje y clasificación de patrones cerebrales y, por último, un módulo de audición. No obstante, este trabajo se acota únicamente al uso de una BCI basada en imaginación musical permitiendo la recolección de un corpus EEG, posteriormente realizar un análisis de señales EEG e iniciar experimentos para la clasificación de patrones cerebrales. Esto con el propósito de implementar un sistema que permita discernir entre un conjunto acotado de actividades musicales imaginadas de manera intencional por un usuario (usando *Music Imagery*), extrayendo su actividad cerebral por medio de una BCI y utilizando coeficientes MFCC como características para el entrenamiento de modelos de aprendizaje de máquina, y así identificar fragmentos musicales durante el proceso de imaginación musical.

Índice general

Índice de figuras	XIII
Índice de tablas	XVII
1. Introducción	1
1.1. Definición del problema	3
1.2. Objetivo	5
1.2.1. Objetivos particulares	6
1.3. Contribución y relevancia	6
1.4. Estructura de la tesis	6
2. Estado del arte	9
2.1. Clasificación de percepción e imaginación de estímulos musicales	9
2.2. Exploración de imaginación musical y motora	11
2.3. Exploración de imaginación musical con otros paradigmas BCI	13
2.4. Bases de datos EEG utilizando imaginación musical	13
3. Señales cerebrales	15
3.1. Interfaz Cerebro Computadora	15
3.2. Métodos de adquisición	16
3.2.1. No invasivo	17
3.2.2. Invasivo	17

3.3. Imaginación musical	18
4. Metodología	19
4.1. Recolección de corpus EEG	19
4.1.1. Selección de sujetos de prueba	19
4.1.2. Preparación de equipo y entorno para registro EEG	20
4.1.3. Percepción e imaginación musical	22
4.1.4. Base de datos EEG	24
4.2. Preprocesamiento de datos EEG	25
4.2.1. Filtrado espectral de datos EEG	25
4.2.2. Selección y eliminación de canales EEG	25
4.2.2.1. Eliminación de canales por inspección	26
4.2.2.2. Kurtosis	27
4.2.2.3. Coeficiente de correlación de Pearson	28
4.2.3. Segmentación de datos EEG	30
4.3. Análisis de datos	33
4.3.1. Transformada Discreta de Fourier (DFT)	34
4.3.2. Coeficientes Cepstrales en las Frecuencias de Mel (MFCC)	35
4.4. Clasificación	36
4.4.1. Regresión logística	37
4.4.2. Máquina de soporte vectorial	37
5. Evaluación y Resultados	39
5.1. Selección y evaluación de parámetros iniciales	39
5.1.1. Pruebas preliminares	39
5.2. Resultados: Clasificación de <i>Blank Mind</i> e imaginación musical	45
5.2.1. Prueba No. 1: Eliminación de canales por inspección	45
5.2.2. Prueba No. 2: Eliminación de canales por Kurtosis	48
5.2.3. Prueba No. 3: Eliminación de canales por coeficiente de correlación de Pearson	51

5.2.4. Prueba No. 4: Clusterización de electrodos aplicando coeficiente de correlación de Pearson	54
5.2.5. Prueba No. 5: Clasificación de 5 clases por sujeto	58
5.2.6. Prueba No. 6: Clasificación de 5 clases para todos los sujetos . .	60
5.2.7. Prueba No. 7: Clasificación de 4 clases para 3 sujetos	62
5.3. Resultados: Clasificación de imaginación musical	63
5.4. Resumen general de observaciones	66
6. Conclusiones	71
6.1. Resumen y contribuciones	71
6.2. Trabajo a futuro	74
6.3. Colaboraciones	74
A. Fragmentos musicales	77
A.1. Partituras musicales	77
Bibliografía	79

Índice de figuras

1.1. Esquema general de un sistema para la identificación de una actividad musical imaginada.	5
4.1. Configuración de 32 electrodos (identificados en color verde) según el Sistema Internacional 10-20.	21
4.2. Adquisición de actividad cerebral de un sujeto mientras realizaba el experimento de percepción e imaginación musical.	22
4.3. <i>BaseLine</i> (Estado de relajación, <i>mente en blanco</i> o <i>Blank Mind</i>).	23
4.4. <i>Entrenamiento</i> : PB = Percepción del fragmento musical en tono B; IB = Imaginación del fragmento musical en tono B.	23
4.5. <i>Secuencia</i> : 4 series de 10 fragmentos musicales en orden aleatorio.	24
4.6. Ejemplo de un registro cerebral donde un electrodo dejó de hacer contacto con el cuero cabelludo del sujeto. El canal No. 12 muestra visualmente demasiado ruido, siendo eliminado del electroencefalograma.	26
4.7. Forma de la curva según el valor de <i>Kurtosis(k)</i>	27
4.8. Ejemplo de un registro cerebral donde se aplica Kurtosis. Los canales No. 14, 16 y 18 se encuentran fuera del umbral y son rechazados.	28
4.9. Definición de red de canales EEG adyacentes para el cálculo del Coeficiente de Correlación de Pearson.	30

4.10. Los canales conectados con líneas azules representan correlaciones que no cumplen alguno de los 2 criterios definidos por el Coeficiente de Correlación de Pearson.	31
4.11. Extracción de segmentos de interés para el registro de relajación o <i>mente en blanco</i> y para cada uno de los fragmentos musicales imaginados. . . .	32
4.12. 32 señales EEG correspondientes a un fragmento musical imaginado. . .	32
4.13. Señal EEG resultante correspondiente a un fragmento musical imaginado.	33
4.14. Ejemplo de un problema de dos clases linealmente separable por el hiperplano H_3	38
5.1. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 17 coeficientes MFCC.	46
5.2. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 21 coeficientes MFCC.	46
5.3. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 25 coeficientes MFCC.	47
5.4. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 17 coeficientes MFCC.	49
5.5. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 21 coeficientes MFCC.	49
5.6. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 25 coeficientes MFCC.	50
5.7. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 17 coeficientes MFCC.	52
5.8. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 21 coeficientes MFCC.	52
5.9. Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 25 coeficientes MFCC.	53
5.10. Segmentación de electrodos EEG para 3 sujetos (S04, S05 y S07) en dos clusters.	55

5.11. Comparación de 2 clústers según su precisión de clasificación para 2 clases utilizando 17 coeficientes MFCC.	56
5.12. Comparación de 2 clústers según su precisión de clasificación para 2 clases utilizando 21 coeficientes MFCC.	57
5.13. Comparación de 2 clústers según su precisión de clasificación para 2 clases utilizando 25 coeficientes MFCC.. . . .	57
5.14. Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 17 coeficientes MFCC.	59
5.15. Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 21 coeficientes MFCC.	59
5.16. Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 25 coeficientes MFCC.	60
5.17. Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 17, 21 y 25 coeficientes MFCC con la información homologada de los 12 sujetos.	61
5.18. Gráfica representando la precisión de clasificación de 4 clases, 2 algoritmos y utilizando 17, 21 y 25 coeficientes MFCC con la información homologada de 3 sujetos.	63
5.19. Gráfica representando la precisión de clasificación de 6 modelos separando dos clases y utilizando 17 coeficientes MFCC.	64
5.20. Gráfica representando la precisión de clasificación de 6 modelos separando dos clases y utilizando 21 coeficientes MFCC.	65
5.21. Gráfica representando la precisión de clasificación de 6 modelos separando dos clases y utilizando 25 coeficientes MFCC.	65
5.22. Gráfica lineal representando la precisión de clasificación entre un fragmento musical imaginado y un estado de relajación (<i>Blank Mind</i>). . . .	68
5.23. Gráfica lineal representando la precisión de clasificación entre 2 fragmentos musicales imaginados.	69
A.1. Partitura del fragmento musical en tono B	77

ÍNDICE DE FIGURAS

A.2. Partitura del fragmento musical en tono C	77
A.3. Partitura del fragmento musical en tono D	77
A.4. Partitura del fragmento musical en tono G	78

Índice de tablas

4.1. Perfil musical de los sujetos de prueba	20
4.2. 4 fragmentos musicales (o estímulos musicales). Los audios están disponibles en <i>SoundCloud</i> [1].	23
5.1. Promedio de precisión de clasificación de dos clases aplicando dos algoritmos de aprendizaje de máquina para 4 tamaños de ventanas de muestras (sin traslape).	40
5.2. Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 32 muestras (sin traslape).	41
5.3. Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 64 muestras (sin traslape).	41
5.4. Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 128 muestras (sin traslape).	42
5.5. Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 256 muestras (sin traslape).	42
5.6. Máquina de Soporte Vectorial. Promedio de precisión de clasificación de dos clases aplicando diferentes tamaños de ventanas de muestras (sin traslape) y números de coeficientes MFCC.	43

ÍNDICE DE TABLAS

5.7. Regresión Logística. Promedio de precisión de clasificación de dos clases aplicando diferentes tamaños de ventanas de muestras (sin traslape) y números de coeficientes MFCC.	44
5.8. Comparación de resultados obtenidos en este proyecto respecto a las principales investigaciones relacionadas al área de imaginación musical. .	70

Introducción

Actualmente existen diferentes tipos de interfaces que permiten la comunicación entre hombre-máquina. Básicamente el ser humano es capaz de interactuar con una computadora a través de diferentes canales de entrada/salida, por ejemplo: voz, visión, audición, tacto y movimiento. Sin embargo, existen dispositivos que permiten la comunicación hombre-máquina mediante el registro de actividad cerebral, y son conocidos como Interfaces Cerebro Computadora (o bien BCI por las siglas en inglés de *Brain Computer Interface*) [2].

Existen diferentes definiciones en la literatura respecto a una Interfaz Cerebro Computadora, pero por el momento se considera la siguiente, es un dispositivo que provee al cerebro un nuevo canal de control y comunicación [3]. Es decir, una BCI registra ondas eléctricas generadas por el cerebro en diferentes zonas de la cabeza humana, traduce estas señales en acciones y comandos que permiten controlar entornos físicos o virtuales.

En los últimos años se han desarrollado cada vez más BCI's que permiten a los seres humanos interactuar con diversos tipos de aplicaciones, tales como: videojuegos [4], control de prótesis [5], robots [6], drones [7], entre otras. Y recientemente, también se han comenzado a utilizar en aplicaciones referentes a la música.

Por ejemplo, algunos compositores han generado música a través de señales adqui-

ridas por electroencefalografía (EEG), tal como el compositor estadounidense Alvin Lucier quien fue pionero en utilizar señales cerebrales como fuente de música, en su pieza llamada *Music for Solo Performer (1965)*, donde utilizó ondas alfa para hacer vibrar instrumentos de percusión [8]. También el compositor David Rosenboom empleó técnicas de EEG para la creación de sonido y música [9]. A partir de estos proyectos comienza a existir más presencia de las BCI en las artes, tal como *DECONcert*, proyecto donde un grupo de personas participaron con el fin de obtener sus señales cerebrales y explorar la combinación de estas junto con ondas generadas por el agua, y así crear música [10]. Hay que destacar que estos proyectos no utilizan ninguna técnica basada en aprendizaje automático, con el objetivo de distinguir patrones cerebrales justo cuando una persona piensa o imagina una actividad musical de manera intencional con el fin de crear música.

Hay algunas investigaciones que buscan desarrollar herramientas para la generación de música, por ejemplo, se creó un proyecto donde se pretende explorar los sistemas BCI para la composición musical, donde el usuario por medio de una interfaz GUI (Interfaz Gráfica de Usuario) y una BCI puede componer música a partir de la técnica de P300. Básicamente el usuario selecciona notas musicales mostradas en un panel y el sistema las coloca en un pentagrama para que posteriormente sean reproducidas. En esta investigación se pretende que la creación de melodías cortas proporcione una experiencia agradable para los usuarios [11].

Otro ejemplo, consiste en producir una interpretación musical mediante la integración de datos extraídos de señales EEG. Es decir, el desarrollo de un instrumento musical que utiliza ondas cerebrales mientras se ejecuta un proceso mental de imaginación musical complementado con técnicas de sonificación y visualización. El proyecto se llama *Brain dreams Music*. El proceso de extracción de características es por medio de Patrones Espaciales Comunes y la clasificación usando Análisis Discriminante Lineal [12]. Es importante mencionar que falta incursionar más en la aplicación de aprendizaje de

máquina en este tipo de investigaciones.

Tomando como base estos sistemas, en esta tesis se realiza una investigación en el área de imaginación musical como paradigma BCI junto con técnicas de aprendizaje de máquina. Es decir, explorar la identificación y clasificación de características presentes en la actividad cerebral de una persona en el momento exacto que imagina una actividad musical. Tal como, Rebecca Schaefer [13] y Sebastian Stober [14] quienes han incursionado en verificar si es posible clasificar con precisión estímulos musicales percibidos e imaginados a partir de datos EEG. Esto es, distinguir entre ambas actividades, y entendiendo como:

- *Percepción*: cuando una persona es sometida a un estímulo musical de tipo auditivo (escuchar una canción, una nota o un tono musical).
- *Imaginación*: cuando se le solicita a la persona que piense o recree mentalmente el estímulo auditivo que ha escuchado previamente. Este proceso se denomina Imaginación Musical (*Music Imagery*) concepto definido en el capítulo 3.

Por lo tanto, en este primer capítulo se plantea la definición del problema, el objetivo, las metas y la contribución de este proyecto de investigación relacionado con el uso de una BCI utilizando imaginación musical.

1.1. Definición del problema

La mayoría de los humanos somos capaces de imaginar música y este proceso puede ser definido como una recreación interna deliberada de la experiencia perceptiva de escuchar música [15]. Este proceso regularmente sucede con el simple hecho de escuchar una melodía, y posteriormente recrearla intencionalmente de manera imaginada como una actividad puramente mental. Esto es conocido como una *actividad musical imaginada*.

1. INTRODUCCIÓN

Idealmente, el uso de una BCI basada en imaginación musical podría permitir construir un sistema de composición musical o un sistema de identificación de canciones con solo pensarla. Por tal motivo, hay proyectos que investigan el uso de la imaginación musical como paradigma para las Interfaces Cerebro Computadora (BCI). Basados principalmente en la posibilidad de identificar patrones específicos que puedan encontrarse en los datos EEG, realizando inicialmente un pre procesamiento de datos EEG, un análisis y una clasificación con técnicas de aprendizaje de máquina.

Por ejemplo, las señales cerebrales ya han sido utilizadas para clasificar la percepción de melodías. En un experimento realizado por Schaefer [16] participaron 10 sujetos quienes escucharon 7 segmentos de melodías de entre 3 y 4 segundos de duración, alternando los estímulos de forma aleatoria. La precisión de la clasificación varió entre el 25 % y 70 % entre los sujetos.

En otro experimento [17] se estudió la existencia de información compartida entre ritmos auditivos percibidos e imaginados por un grupo de 10 personas. Entrenaron dos clasificadores, uno con datos de percepción y probado con datos de imaginación, y de manera inversa. Para el clasificador entrenado con percepción y probado con imaginación tuvo un rendimiento para el mejor de los sujetos de 66.4 %. Y para el clasificador entrenado con imaginación y probado con percepción el rendimiento tuvo un valor de 59.8 % para el mejor de los sujetos. El autor, con base en los resultados, concluye que efectivamente es posible encontrar información compartida entre ambas actividades.

Por lo tanto, este proyecto se enfoca a investigar la clasificación de 4 fragmentos musicales (actividades musicales) imaginados y un estado de relajación (*mente en blanco* o *Blank Mind*) con el propósito de explorar si es posible hacer una distinción entre ellos, y así contribuir en la construcción de un sistema para la identificación de actividades musicales imaginadas.

Con base en investigaciones previas [12], un sistema que permita identificar una actividad musical imaginada utilizando una BCI está conformada generalmente por una Interfaz Cerebro Computadora (BCI), un módulo de análisis de señales EEG, un módulo de aprendizaje y clasificación de patrones cerebrales, y finalmente un módulo de audición como es presentado en la figura 1.1.

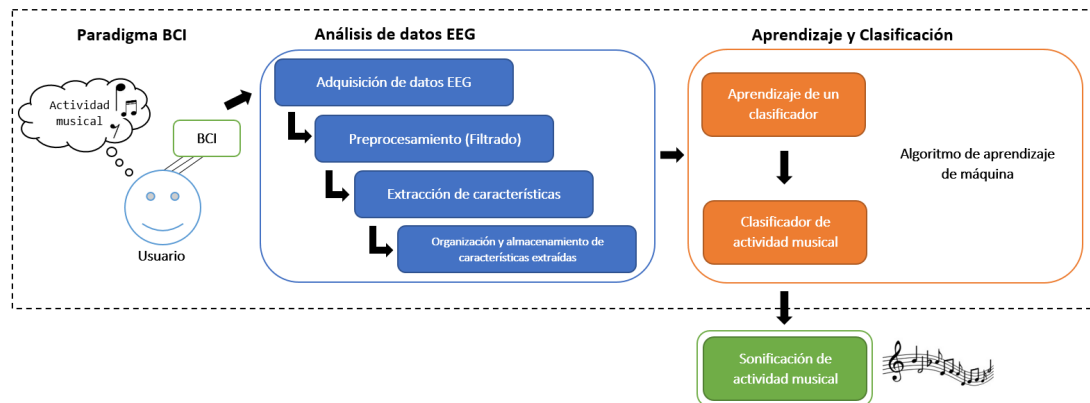


Figura 1.1: Esquema general de un sistema para la identificación de una actividad musical imaginada.

Esta tesis se enfoca únicamente en el uso de una BCI con un paradigma de imaginación musical, así como en el módulo de análisis, aprendizaje y clasificación de señales EEG. En la figura 1.1 se observan estos módulos dentro de la sección punteada. El módulo de sonificación se refiere a la reproducción de la melodía identificada por el sistema con base en la actividad musical imaginada; sin embargo, su desarrollo se contemplará como trabajo a futuro.

1.2. Objetivo

Implementar un sistema que permita discernir entre un conjunto acotado de actividades musicales imaginadas de manera intencional por un usuario (usando imaginación musical como paradigma BCI), extrayendo su actividad cerebral por medio de una Interfaz Cerebro Computadora (BCI).

1.2.1. Objetivos particulares

- Adquirir un corpus de datos EEG de músicos profesionales mientras realizan tareas de imaginación musical.
- Analizar el corpus adquirido y encontrar características representativas que ayuden a discernir entre diferentes actividades musicales imaginadas.
- Clasificar patrones de las señales cerebrales que representan un fragmento musical imaginado y un estado de relajación (*mente en blanco* o *Blank Mind*) para identificar una distinción entre ellos.

1.3. Contribución y relevancia

La contribución y relevancia de este trabajo es:

- Recopilar un corpus con datos EEG aplicando un paradigma de imaginación musical.
- Explorar el uso de coeficientes MFCC como características de representación de los datos EEG.
- Contribuir en la exploración de la imaginación musical como paradigma BCI.
- Un avance importante en el desarrollo de un sistema de composición musical para personas que no tengan habilidad motora.
- Expandir el uso de Interfaces Cerebro Computadora para la composición musical.
- Contribuir en la investigación de análisis de señales EEG para la comunicación hombre-máquina mediante una BCI.

1.4. Estructura de la tesis

Este trabajo está dividido en 6 capítulos. En el primer capítulo se presenta una breve introducción referente a BCI's e imaginación musical, así como la definición del

problema, objetivo, contribuciones y metas a cumplir en el proyecto. El capítulo 2 describe los antecedentes referentes a imaginación musical como paradigma BCI. En el capítulo 3 se mencionan las características de un dispositivo BCI y se define imaginación musical. El capítulo 4 contiene la metodología para la recolección de un corpus de señales cerebrales con imaginación musical, el preprocesamiento, el análisis y clasificación de datos EEG. El capítulo 5 muestra la evaluación y resultados de los diferentes modelos entrenados para la clasificación de fragmentos musicales imaginados. Y por último, en el capítulo 6 se incluyen las conclusiones y trabajo a futuro correspondientes a esta investigación.

Estado del arte

En este capítulo se presentan los antecedentes en el área de imaginación musical como paradigma BCI. En primer lugar se exponen diferentes investigaciones donde se describe la clasificación de estímulos musicales percibidos e imaginados. Posteriormente, proyectos relacionados con la clasificación de actividades musicales imaginadas combinadas con imaginación motora, y también otros paradigmas utilizados por las BCI's, para comprobar cuales son los más eficientes. Al mismo tiempo, se menciona el preprocesamiento de datos, el análisis de datos, métodos de clasificación y resultados. Y por último, se presenta una base de datos pública relacionada a la adquisición de señales EEG con actividades musicales imaginadas.

2.1. Clasificación de percepción e imaginación de estímulos musicales

Una exploración básica acerca de investigar si la música funciona como paradigma para las BCI se ha realizado en varias investigaciones.

Por ejemplo, Schaefer [13] realizó unos experimentos donde participaron 6 sujetos quienes ejecutaron un ejercicio de percepción e imaginación de 4 frases musicales de manera intercalada. Se observó en este primer acercamiento que la percepción de las frases musicales es totalmente detectable hasta en un 90 % de las veces, y la imaginación solo en

algunos sujetos es efectiva entre 70 % y 90 % de precisión. Concluyendo que es una buena aproximación en el área y que la música imaginada es un paradigma BCI prometedor.

En este caso, no hay mención de la adquisición de datos EEG y del preprocesamiento de datos. No obstante, hace referencia a que utilizó un modelo basado en Regresión Logística Lineal para clasificar 4 clases.

En otra investigación, Vlek [17] ejecutó un experimento de percepción e imaginación de acentos musicales, con el fin de verificar si es posible decodificarlos mediante señales cerebrales. En esta prueba participaron 10 sujetos. La secuencia del experimento consistió en 3 fases: percepción, atenuación (*fade*) e imaginación. En la parte de imaginación, se les solicitó a los sujetos la instrucción explícita de imaginar lo que escuchaban y no usar otras estrategias, tales como aplaudir o contar para mantener el ritmo.

Los resultados mostraron que para la percepción el mejor sujeto alcanzó una tasa de clasificación de 74.9 %, y un promedio en todos los sujetos de 69.6 %. Para la imaginación el mejor sujeto alcanzó una tasa de clasificación de 65.7 %, y un promedio en todos los sujetos de 60.8 %. Esto indicando, según los autores, que los resultados permiten decodificar acentos musicales imaginados y percibidos a partir de señales cerebrales, siendo benéfico para la investigación y aplicaciones de las BCI.

La adquisición de señales se hizo con 64 electrodos a una frecuencia de muestreo de 2048 Hz. Se eliminaron canales malos aplicando 4 criterios relacionados a la amplitud, correlación y varianza de las señales. Los trials que funcionaban correctamente para el análisis fueron preprocesados con el método de Referencia Promedio Común (CAR). Este método tiene como fin mejorar la relación señal a ruido de la señal EEG. Posteriormente, la señal se filtró entre un rango de 0.5 y 15 Hz. Se aplicó Análisis de Componentes Principales (PCA) y un promedio de Potenciales Relacionados con Eventos (ERP) para una mejor visualización de la respuesta neurofisiológica a la percepción

e imaginación. Y para clasificar se utilizó Regresión Logística (LR) regularizado con L2.

Así también, Stober [18] cita que los sistemas MIIR (*Music Imagery Information Retrieval Systems*) un día serán capaces de reconocer una canción únicamente con nuestros pensamientos. Inicia recolectando una base de datos pública llamada OpenMIIR, donde participaron 10 sujetos. Utilizó 12 piezas musicales como estímulos con duración entre 7 y 12 segundos en orden aleatorio. La señal EEG de los sujetos se registró con 4 condiciones referentes a la percepción e imaginación musical.

En este estudio se recolectó únicamente la información con 64 canales EEG con una frecuencia de muestreo de 512 Hz. Eliminando canales malos de manera visual y aplicando un filtro entre los rangos de 0.5 y 30 Hz. Para remover artefactos¹ causados por el parpadeo de los ojos se aplicó Análisis de Componentes Independientes (ICA). Y únicamente analizó Potenciales Relacionados con Eventos (ERP).

Posteriormente, Sternin [15] retoma esta base de datos, aplicando técnicas de aprendizaje profundo usando una red neuronal convolucional (CNN) para clasificar los estímulos musicales percibidos e imaginados. Uno de los modelos entrenados fue capaz de clasificar 12 clases con 28.7% de precisión para los estímulos percibidos. Sin embargo, no fue así para los estímulos musicales imaginados, la clasificación resultó con un 7.41% de precisión. Concluyendo con esto que es necesario explorar otras características en los datos para clasificar con mayor efectividad los estímulos musicales.

2.2. Exploración de imaginación musical y motora

La tarea cognitiva más comúnmente utilizada en los estudios de BCI es la imaginación motora, ya que produce cambios en la actividad EEG que ocurren naturalmente en la planificación del movimiento y son relativamente simples de detectar [19].

¹Actividades eléctricas que contaminan las señales cerebrales.

Por tal motivo, hay investigaciones que exploran estos dos tipos de paradigmas para verificar su comportamiento.

Por ejemplo, Soriano [20] explora el uso de dos tipos de imaginación (motora y musical) como potenciales paradigmas de sistemas BCI. Participaron 9 personas realizando experimentos de imaginación musical (imaginar una canción) e imaginación motora (imaginar el movimiento de la mano derecha), intercalando un descanso o pensar en una *luz blanca*. La variabilidad de los resultados fue muy grande entre los sujetos. Indicando que no hay un patrón de similitud en la actividad EEG, únicamente se aprecia en resonancias magnéticas debido a que se activaban zonas cerebrales similares en ambas tareas. Comprobando que la actividad de imaginación musical fue la más complicada de clasificar casi para todos los sujetos. De hecho, la tasa de éxito fue superior al 50 %, solo un sujeto quedó por debajo de este valor.

La adquisición de los datos se hizo con 64 electrodos con una frecuencia de muestreo de 5 KHz. Para evitar artefactos (movimientos o parpadeos) en la señal se aplicaron filtros CAR (Common Average Reference). Se etiquetaron las señales con valores escalares para poder clasificar: descanso o pensar en *una luz blanca* (valor 0), imaginación musical (valor 1) e imaginación motora (valor 2). La extracción de atributos para caracterizar mejor los estímulos se hizo usando Densidad Espectral de Potencia (PDS) obtenido con el Método de Welch, y la selección de características se realizó con base en el índice de Davies-Bouldin. Por último, la clasificación se realizó con Análisis Discriminante Lineal (LDA).

2.3. Exploración de imaginación musical con otros paradigmas BCI

La imaginación musical también se ha evaluado junto con otras tareas cognitivas para verificar su eficacia. Curran [21] propone evaluar diferentes tareas cognitivas para diferenciarlas utilizando señales cerebrales EEG. Participaron 10 sujetos realizando la ejecución de 4 tareas cognitivas:

1. Navegación espacial (Imaginar que se mueven de un cuarto a otro)
2. Imaginación auditiva (Imaginar un tono familiar)
3. Imaginación motora (Imaginar movimiento en la mano izquierda)
4. Imaginación motora (Imaginar movimiento en la mano derecha)

Estas tareas se clasificaron por parejas. Y el mejor rendimiento de clasificación fue para el par Navegación espacial - Imaginación auditiva con 74 %. Concluyendo con este resultado que la imaginación auditiva es posible discriminarla de una tarea cognitiva diferente con alta probabilidad de éxito.

El registro de datos se hizo con 7 electrodos de plata con una frecuencia de muestreo de 384 Hz. Aplicando un filtro paso banda entre el rango 0.1 y 100 Hz. La señal EEG fue parametrizada usando un modelo autorregresivo (AR) para cada uno de los canales EEG con el fin de estimar coeficientes de reflexión. Y la clasificación de datos se realizó con un modelo basado en Regresión Logística.

2.4. Bases de datos EEG utilizando imaginación musical

En esta sección se describe la única base de datos pública que se encontró con información EEG basada en imaginación musical.

OpenMIIR

Los sistemas de recuperación de información de imaginación musical (MIIR por las siglas en inglés de *Music Imagery Information Retrieval Systems*) tienen como objetivo que algún día puedan reconocer una canción solo a través del pensamiento. Como avance para que esto suceda, se publica OpenMIIR que es un conjunto de datos de dominio público de grabaciones de electroencefalografía (EEG) tomadas durante la percepción y la imaginación de música [18].

Características:

- 10 sujetos de prueba
- 64 canales EEG
- 12 fragmentos cortos de música entre 7 y 16 segundos utilizados como estímulos
- 10 archivos EEG sin procesar se encuentran en formato FIF
- Recomiendan procesar los archivos con la herramienta MNE (MEG + EEG Analysis And Visualization)

Por lo tanto, se observa que hay pocas bases de datos referentes a imaginación musical. Así que es importante contribuir en la recolección y publicación de nuevas bases de datos EEG que permitan a la comunidad generar nuevas investigaciones en el área. OpenMIIR no fue utilizada en este proyecto debido a que los perfiles de los sujetos corresponden a personas que no tienen un entrenamiento musical profesional, y no cuenta con registros EEG donde los sujetos muestren un estado de relajación; siendo estos puntos importantes para esta tesis.

Señales cerebrales

En este capítulo se presenta una breve introducción referente a las Interfaces Cerebro Computadora basadas en señales cerebrales (EEG). Y se explica la imaginación musical como paradigma BCI.

3.1. Interfaz Cerebro Computadora

Las neuronas cerebrales se comunican entre sí produciendo pequeñas señales eléctricas, que llevan el nombre de impulsos [22]. Estos impulsos en conjunto generan una actividad eléctrica cerebral que puede ser medida a través de una prueba de electroencefalografía (EEG).

La electroencefalografía (EEG) es un método clínico o de investigación que consiste en el registro de actividad eléctrica cerebral utilizando electrodos que se colocan sobre el cuero cabelludo de una persona [23].

Los artefactos son otras actividades eléctricas que contaminan las señales cerebrales, por ejemplo:

- Actividad bioeléctrica causada por el parpadeo y movimiento de los ojos (EOG por las siglas en inglés de *Electrooculography*).
- Actividad bioeléctrica causada por los músculos (EMG por las siglas en inglés de

Electromyography).

- Actividad electromagnética en el ambiente.

Varias Interfaces Cerebro Computadora están basadas en electroencefalografía (EEG). Es decir, registran cambios en la actividad cerebral en diferentes momentos y en diferentes áreas del cerebro. Por lo tanto, una BCI se define como un sistema que permite la comunicación hombre-máquina mediante la adquisición de señales eléctricas cerebrales, y el cual es capaz de traducir pensamientos cognitivos (o intenciones) del usuario en acciones reales para interactuar con un entorno físico o virtual [2].

Según Bernhard [23] para que una BCI sea considerada como tal, debe cumplir las siguientes características básicas:

1. Registrar actividad cerebral (Invasivo o No invasivo).
2. Proveer retroalimentación al usuario en tiempo real.
3. Basarse en el control intencional.

Estas características implican que el usuario debe elegir realizar una tarea mental siempre que desee alcanzar un objetivo con una BCI. Un dispositivo que detecta de forma pasiva cambios en la actividad cerebral que ocurren sin ningún tipo de intención, como la actividad EEG asociada con la carga de trabajo, la excitación o el sueño, no son BCI.

3.2. Métodos de adquisición

La elección del método de adquisición tiene consecuencias importantes de usabilidad, ética, diseño del sistema y calidad de la señal.

Principalmente hay 2 métodos de adquisición de señales cerebrales en las BCI.

3.2.1. No invasivo

Este método consiste en colocar una serie de electrodos o sensores de tal forma que no se realiza una intrusión sobre el cerebro o cuerpo humano. Es la forma más utilizada debido a que no es necesario algún tipo de cirugía. EEG es un método de los más utilizados en BCI.

Existen otras técnicas no invasivas que se utilizan frecuentemente pero regularmente es costoso y los equipos son muy voluminosos, por ejemplo:

- Magnetoencefalografía (MEG por las siglas en inglés de *Magnetoencephalography*) [24].
- Tomografía por Emisión de Positrones (PET por las siglas en inglés de *Positron Emission Tomography*) [25].
- Tomografía Computarizada por Emisión de Fotones Individuales (SPECT por las siglas en inglés de *Single-Photon Emission Computed Tomography*) [26].
- Imagen por Resonancia Magnética Funcional (fMRI por las siglas en inglés de *functional Magnetic Resonance Imaging*) [27].
- Espectroscopia Funcional del Infrarrojo Cercano (fNIRS por la siglas en inglés de *functional Near-Infrared Spectroscopy*) [28].

3.2.2. Invasivo

El método invasivo requiere cirugía para implantar los sensores necesarios. Esta cirugía incluye la apertura del cráneo a través de un procedimiento quirúrgico llamado craneotomía y el corte de las membranas que cubren el cerebro.

Las técnicas invasivas combinan excelente calidad en la señal, muy buena resolución espacial y un alto rango de frecuencia. Además, los artefactos no son problema en este

tipo de técnicas. Sin embargo, existen desventajas, tal como el grave inconveniente de que requiere cirugía lo cual implica riesgos, y un costo elevado.

3.3. Imaginación musical

En el capítulo 2 se mencionan antecedentes que involucran paradigmas BCI basados en la imaginación. Uno de los objetivos de este proyecto es analizar señales cerebrales que se adquieren durante la percepción e imaginación de música basando en un paradigma BCI.

Algunos estudios han identificado una relación entre áreas cerebrales que se activan durante la imaginación y percepción de música [29, 30, 31, 32]. Además, la imaginación no es exclusivamente visual, ya que cualquier persona puede hacer mención que alguna vez ha sido molestada por alguna melodía publicitaria que suena repetidamente en su mente [33].

De manera más formal, según Schaefer, la imaginación musical puede definirse como una recreación interna deliberada de la experiencia perceptiva de escuchar música [34]. Esto significa que todos hemos experimentado imaginación musical en algún momento [35].

Varios neurocientíficos computacionales han realizado avances importantes al respecto. Sin embargo, la capacidad de clasificar entre fragmentos de música puramente imaginados y un estado de relajación no ha sido explorada.

Por lo tanto, debido a que existe una correlación entre la percepción e imaginación musical, en esta investigación se retoma dicho paradigma BCI para el análisis de señales cerebrales, así como el entrenamiento de modelos que permitan clasificar fragmentos musicales imaginados y un estado de relajación.

Metodología

En este capítulo se expone el paradigma BCI para la recolección de un corpus EEG con imaginación musical. También se explica el preprocesamiento y análisis de datos EEG. Y por último, se describen los métodos de clasificación que se realizaron utilizando aprendizaje de máquina supervisado.

4.1. Recolección de corpus EEG

Existen varias investigaciones relacionadas al uso de BCI basadas en imaginación musical y otras tareas cognitivas. No obstante, la información o bases de datos EEG disponibles en repositorios públicos es casi nula. Por tal motivo, este proyecto se enfoca a recolectar una base de datos que involucre registros de electroencefalografía mientras usuarios ejecutan percepción e imaginación musical. Brevemente se describe el paradigma BCI.

4.1.1. Selección de sujetos de prueba

Al medir las respuestas en el tronco encefálico de músicos y no músicos durante la percepción de una melodía, se mostró que los músicos tienen un sistema sensorial especializado para procesar aspectos del sonido [36]. Además, pocos investigadores han sometido únicamente a músicos a un paradigma BCI basado en imaginación musical. Por lo tanto, se decide conformar un corpus de datos cerebrales con 12 personas dedicadas a la música profesionalmente (4 mujeres y 8 hombres) entre 18 y 30 años. Esto

4. METODOLOGÍA

Sujeto ID	Experiencia musical
S01	Compositor, toca la guitarra y es cantante
S02	Toca la guitarra
S03	Cantante y toca el piano
S04	Estudiante de composición y toca la guitarra
S05	Estudiante de composición y toca el piano
S06	Estudiante de composición, toca la guitarra, el contrabajo y las congas
S07	Profesor de música y toca la guitarra
S08	Estudiante de interpretación y toca el piano
S09	Toca el violín y la flauta transversal
S10	Toca el piano y percusiones
S11	Toca el contrabajo
S12	Estudiante de composición, toca el piano y es cantante

Tabla 4.1: Perfil musical de los sujetos de prueba

con el objetivo de comprobar si tienen mayor facilidad para imaginar un fragmento musical. El perfil musical de cada sujeto de prueba se describe en la tabla 4.1.

Cada participante firmó una carta de confidencialidad, donde se explica el protocolo de adquisición de datos EEG y algunas consideraciones que debía tomar (dormir 8 horas mínimo, no tomar café, no usar químicos en el cabello, etc.) para no alterar o sesgar el registro de señales cerebrales.

4.1.2. Preparación de equipo y entorno para registro EEG

Para realizar el registro de señales cerebrales se utilizó un dispositivo de adquisición y procesamiento de datos EEG llamado *g.USBamp* [37], utilizando 32 electrodos colocados según el sistema internacional 10-20 (ver figura 4.1) [38] y con una tasa de muestreo de 256 Hz. Se empleó el sistema *BCI2000* [39] como software de adquisición.

El experimento se realizó en la cabina de radio de la Universidad Autónoma Metropolitana (UAM), Unidad Iztapalapa para aislar, lo más posible, el ruido ambiental y las distracciones para el sujeto mientras realizaba el ejercicio de percepción e imaginación musical. En la figura 4.2 se muestra cuando un sujeto está realizando el experimento.




Figura 4.1: Configuración de 32 electrodos (identificados en color verde) según el Sistema Internacional 10-20.



Figura 4.2: Adquisición de actividad cerebral de un sujeto mientras realizaba el experimento de percepción e imaginación musical.

4.1.3. Percepción e imaginación musical

La adquisición de señales cerebrales de un sujeto se desarrolló utilizando un paradigma BCI basado en percepción e imaginación musical. La *percepción* es cuando el sujeto escucha un fragmento musical. La *imaginación* se refiere a la recreación mental del fragmento musical escuchado previamente por el sujeto.

Este experimento se efectuó en 3 etapas:

1. *BaseLine* (Estado de relajación, *mente en blanco* o *Blank Mind*): En esta fase se le solicita al sujeto que se relaje y no piense en nada en particular (*mente en blanco*). Un conjunto de señales auditivas le dan la pauta al sujeto para que inicie en un estado de relajación, así como cuando inicia y finaliza el ejercicio. Este evento tiene un periodo de tiempo de 109.4 segundos, de los cuales únicamente se consideran 70 segundos. Un esquema del registro se muestra en la figura 4.3.



Figura 4.3: *BaseLine* (Estado de relajación, *mente en blanco* o *Blank Mind*).

2. *Entrenamiento*: Es un registro de prueba para asegurar que el participante entendió la dinámica del ejercicio de percepción (**P**) e imaginación (**I**) musical. El sujeto escucha únicamente 4 fragmentos musicales con una duración de 6 segundos cada uno (ver tabla 4.2), intercalando un periodo de tiempo de 6 segundos enseguida de cada estímulo musical para que el sujeto inmediatamente lo imagine. El proceso del registro se muestra en el figura 4.4. Este evento tiene un periodo de tiempo de 139.4 segundos.




Figura 4.4: *Entrenamiento*: **PB** = Percepción del fragmento musical en tono B; **IB** = Imaginación del fragmento musical en tono B.

Los fragmentos o estímulos musicales corresponden únicamente a 4 notas musicales (según el sistema inglés de notación musical): B, C, D y G. Estos fragmentos musicales tienen el mismo ritmo armónico entre sí, solo la nota musical es la que cambia. Para mayor detalle, las partituras de cada pieza musical se muestran en el apéndice A.1.

Identificador	Fragmento musical	Duración
B	Fragmento musical en tono B	6 s
C	Fragmento musical en tono C	6 s
D	Fragmento musical en tono D	6 s
G	Fragmento musical en tono G	6 s

Tabla 4.2: 4 fragmentos musicales (o estímulos musicales). Los audios están disponibles en *SoundCloud* [1].

3. *Secuencia*: Es el registro de interés donde se ejecutan diferentes series de percepción (**P**) e imaginación (**I**) musical por el sujeto. Son 4 series cada una con 10

4. METODOLOGÍA

fragmentos musicales aleatorios, intercalando las tareas de percepción e imaginación. Este evento tiene un periodo de tiempo de 946.4 segundos, considerando las 4 series de manera continua. Este evento se muestra en la figura 4.5.



Figura 4.5: *Secuencia:* 4 series de 10 fragmentos musicales en orden aleatorio.

Los sujetos llevaron a cabo las 3 fases descritas anteriormente con los ojos cerrados. Hicieron uso de un par de audífonos para escuchar señales auditivas que indican cuando inicia y termina cada fase, y cuando deben imaginar cada fragmento musical después de escucharlo previamente.

Por último, hay que destacar que principalmente se busca discernir entre señales cerebrales registradas durante el estado de relajación o *mente blanco* y un fragmento musical imaginado. Esto involucra un preprocesamiento, análisis y clasificación de los datos adquiridos durante la primera y tercera fase del paradigma BCI.

4.1.4. Base de datos EEG

La recolección de las señales cerebrales de los músicos (sujetos) y la conformación de la base de datos, se hizo en colaboración entre el Instituto de Investigaciones en Matemáticas Aplicadas y en Sistemas (IIMAS) de la Universidad Nacional Autónoma de México (UNAM) y por el Laboratorio de Neuroimagenología (LINI) de la Universidad Autónoma Metropolitana (UAM), Unidad Iztapalapa.

La base de datos EEG tiene las siguientes características:

- 12 sujetos de prueba con experiencia musical

- 32 canales EEG
- Tasa de muestreo de 256 Hz
- 12 archivos con formato *.DAT, para cada sujeto existe:
 - Estado de relajación o *Blank Mind* con 70 segundos de información
 - Percepción con 60 segundos de información total para cada fragmento musical
 - Imaginación con 60 segundos de información total para cada fragmento musical

4.2. Preprocesamiento de datos EEG

4.2.1. Filtrado espectral de datos EEG

Los datos adquiridos de cada sujeto que participó en la prueba de percepción e imaginación musical fueron preprocesados utilizando *MATLAB*, específicamente con el software *EEGLAB* que permite el procesamiento de datos de electroencefalografía. Con esta herramienta se realizó un filtrado espectral en cada uno de los registros. Un filtro FIR paso bandas fue aplicado con frecuencia de corte entre 1 y 14 Hz [17], tomando como referencia algunos rangos espectrales de las bandas de electroencefalografía [40].

4.2.2. Selección y eliminación de canales EEG

Los registros de electroencefalografía (EEG) regularmente son muy ruidosos. Contienen artefactos causados por la actividad muscular, el parpadeo de los ojos, presencia de altas impedancias en los electrodos o algún problema en la conexión de los electrodos durante el transcurso del registro.

Con el fin de analizar señales de mejor calidad, se aplicaron 3 métodos para la eliminación de canales malos que se encuentren en el registro EEG: Eliminación de canales por inspección, Kurtosis y Coeficiente de Correlación de Pearson.




Figura 4.6: Ejemplo de un registro cerebral donde un electrodo dejó de hacer contacto con el cuero cabelludo del sujeto. El canal No. 12 muestra visualmente demasiado ruido, siendo eliminado del electroencefalograma.

4.2.2.1. Eliminación de canales por inspección

Es un proceso que se realiza frecuentemente en el preprocesamiento de señales cerebrales. Es decir, visualizar los electroencefalogramas con las señales adquiridas ayuda a eliminar canales EEG que no son adecuados para su análisis. Es una técnica que complementa otros métodos para la eliminación de canales contaminados por ruido.

Esta técnica se aplicó si durante la adquisición de señales cerebrales se presentaron los siguientes problemas:

- Si durante el registro EEG se observó que algún electrodo dejó de hacer contacto con el cuero cabelludo del sujeto.
- Si la señal de algún canal EEG presenta demasiado ruido visualmente.

Los canales que no presentaron ninguno de estos inconvenientes se consideraron como adecuados para su próximo análisis. En la figura 4.6 se observa el ejemplo de un canal EEG que presenta demasiado ruido.

4.2.2.2. Kurtosis

Una actividad eléctrica puede aparecer en uno de los canales EEG y estar ausente en los canales restantes. Tales eventos se pueden detectar calculando el valor de Kurtosis en cada uno de los canales EEG. Esta medida indica la presencia de valores atípicos en conjuntos de datos, un valor muy alto o bajo revela que canal muestra un evento particular [41].

La medida de kurtosis muestra que tan apuntada o achatada está una distribución. Es decir, indica la cantidad de datos que hay cercanos a la media, de manera que a mayor grado de Kurtosis, más apuntada será la forma de la curva [42]. Al tomar la distribución normal como referencia, una distribución según su valor de Kurtosis se puede clasificar en tres grupos: leptocúrtica, platicúrtica y mesocúrtica como se muestran en la figura 4.7.




Figura 4.7: Forma de la curva según el valor de $Kurtosis(k)$.

Kurtosis se mide promediando la cuarta potencia de la diferencia entre cada elemento del conjunto y la media, dividido entre la desviación típica elevado también a la cuarta potencia. Sea el conjunto $X = (x_1, x_2, \dots, x_N)$, entonces el valor de Kurtosis se define por la ecuación: 4.1:

$$k(x) = \frac{1}{S^4} \left[\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4 \right] - 3 \quad (4.1)$$

Donde:

4. METODOLOGÍA

\bar{x} : Media aritmética de la distribución.

S : Desviación estándar de la distribución.

En este experimento se propone un umbral para el valor de Kurtosis entre el rango de -3 y 3 para cada uno de los canales, tomando como base los límites de una distribución normal [42]. En la figura 4.8 se observa un registro cerebral donde se aplicó Kurtosis, rechazando tres canales EEG (No. 14, 16 y 18) que sobrepasan los umbrales establecidos.




Figura 4.8: Ejemplo de un registro cerebral donde se aplica Kurtosis. Los canales No. 14, 16 y 18 se encuentran fuera del umbral y son rechazados.

4.2.2.3. Coeficiente de correlación de Pearson

Debido a la resolución espacial limitada de un electroencefalograma, un subconjunto de electrodos locales mide la actividad correlacionada espacialmente. Un canal con una correlación baja de su actividad respecto con la de sus vecinos tiene una mayor probabilidad de contener artefactos [41].

Para saber si un canal EEG está correlacionado con respecto a sus vecinos, se calculó el Coeficiente de Correlación de Pearson [43] entre dos señales, utilizando la ecuación 4.2:

$$Cor(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.2)$$

Donde:

$Cor(x, y)$: Es el coeficiente de correlación de Pearson entre las señales x y y .

El valor de correlación $Cor(x, y)$ varía en el intervalo $[-1, 1]$, las propiedades son las siguientes:

- Si $Cor(x, y) = -1$, entonces hay una correlación negativa lineal perfecta entre x y y .
- Si $Cor(x, y) = 1$, entonces hay una correlación positiva lineal perfecta entre x y y .
- Si $Cor(x, y) = 0$, entonces no hay una correlación entre x y y .

En este experimento, nos interesa que exista una correlación positiva lineal entre x y y . Por lo tanto, empleando el coeficiente de correlación de Pearson, se definieron 2 criterios para rechazar un canal EEG:

1. Si el promedio de correlación de los canales vecinos es menor que 0.4. Definido por la ecuación 4.3:

$$\mu_{Cor}^i = \frac{1}{n} \sum_{j=1}^n Cor(X_i, X_j) \quad (4.3)$$

Donde:

μ_{Cor}^i : Promedio del coeficiente de correlación de Pearson.

n : Número de canales vecinos de X_i .

$Cor(X_i, X_j)$: Coeficiente de correlación de Pearson entre canal X_i y X_j .

2. Si el canal cuenta con 3 o más correlaciones menores que 0.4

Los criterios anteriores utilizan un umbral de 0.4 de correlación mínima entre canales vecinos. Este valor se decidió a partir de haber llevado a cabo pruebas preliminares en




Figura 4.9: Definición de red de canales EEG adyacentes para el cálculo del Coeficiente de Correlación de Pearson.

las que se observó que valores de correlación mayores a 0.6 no tenían un efecto en la selección de canales. Se deja como trabajo a futuro explorar el impacto de este umbral en la selección de los canales, así como del desempeño final del sistema.

El software evalúa estos criterios mediante la definición de una red de canales EEG adyacentes como se muestra en la figura 4.9. La red está basada en la configuración de canales EEG según el sistema internacional 10-20 que se muestra en la figura 4.1. En la figura 4.10 se observa un ejemplo de correlaciones que no cumplen alguno de los 2 criterios.

4.2.3. Segmentación de datos EEG

Para un análisis más adecuado, se eliminaron los segmentos de ruido e información que no son de interés en cada uno de los registros cerebrales. Es decir, únicamente se conservaron periodos de tiempo donde los eventos de *Blank Mind* e imaginación de

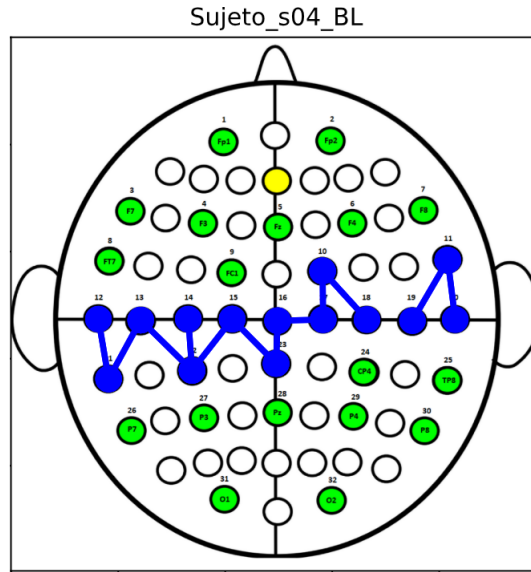


Figura 4.10: Los canales conectados con líneas azules representan correlaciones que no cumplen alguno de los 2 criterios definidos por el Coeficiente de Correlación de Pearson.

los 4 fragmentos musicales estaban siendo ejecutados, esto con el objetivo de extraer características de la información posteriormente.

En la figura 4.11 se observan los segmentos de interés que se extraen para el registro de relajación o *mente en blanco*, así como para cada uno de los fragmentos musicales imaginados por el sujeto.

Una vez segmentada la información de interés, se procedió a promediar todos los canales EEG seleccionados, por medio de la ecuación 4.4:

$$x(t) = \frac{1}{n} \sum_{i=0}^n c_i(t) \quad (4.4)$$

Donde:

n : Número de canales EEG.

$c_i(t)$: Señal del canal i .

$x(t)$: Señal resultante.

4. METODOLOGÍA

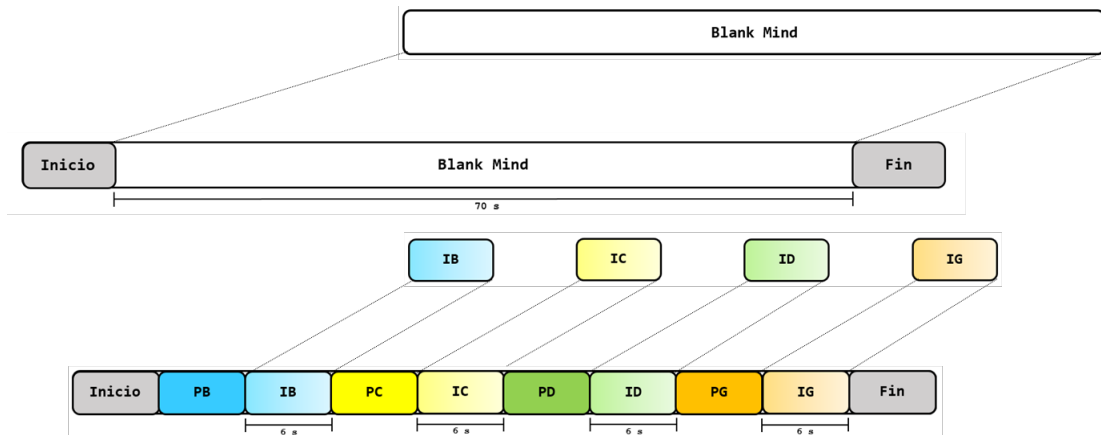


Figura 4.11: Extracción de segmentos de interés para el registro de relajación o *mente en blanco* y para cada uno de los fragmentos musicales imaginados.

En la figura 4.12 se muestra un electroencefalograma con 32 señales EEG y en 4.13 se muestra la señal resultante $x(t)$ correspondiente al promedio de los 32 canales EEG seleccionados anteriormente.

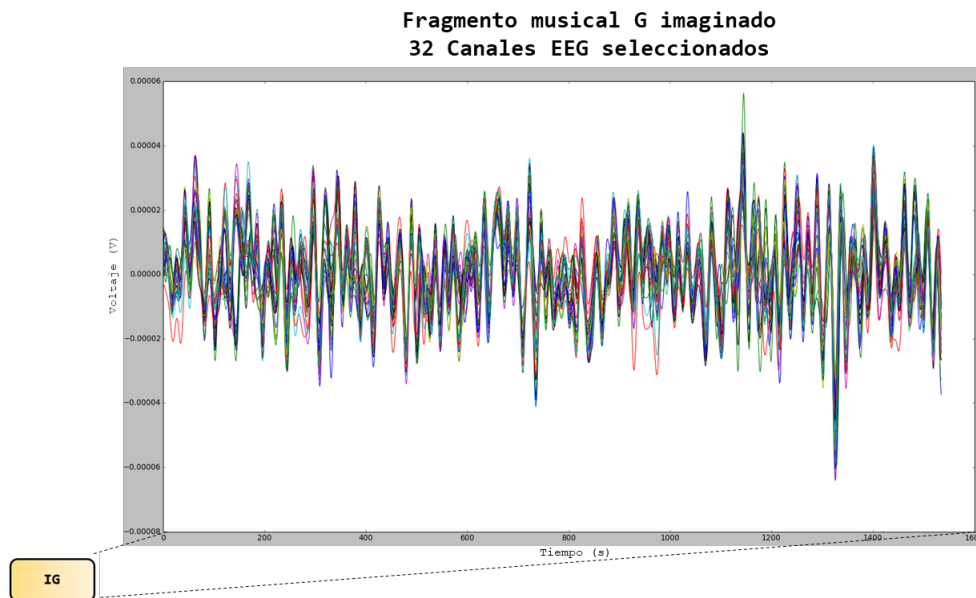


Figura 4.12: 32 señales EEG correspondientes a un fragmento musical imaginado.

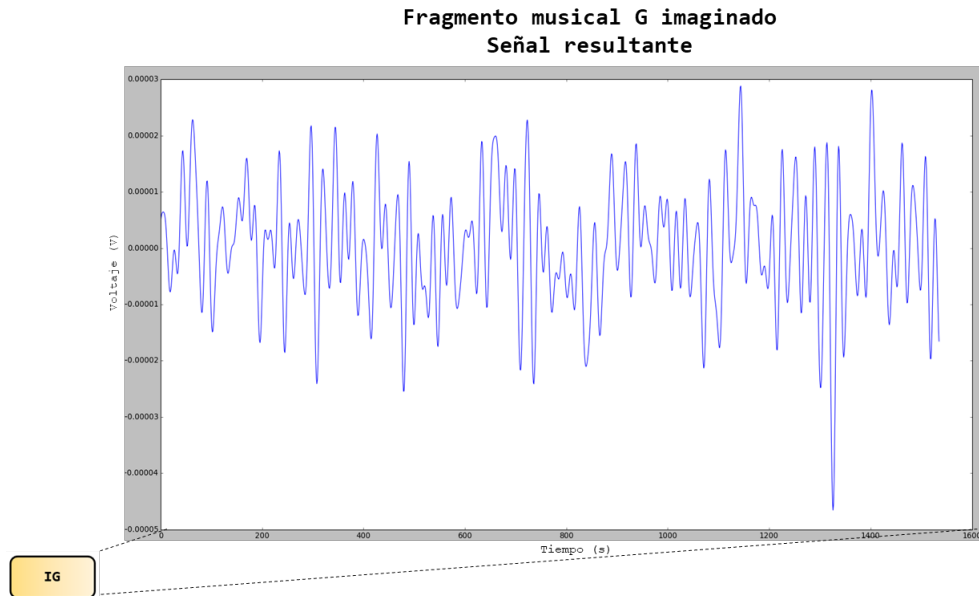


Figura 4.13: Señal EEG resultante correspondiente a un fragmento musical imaginado.

4.3. Análisis de datos

La extracción de características es la determinación de los elementos que conforman un vector de características que describen un patrón, reduciendo al mismo tiempo el espacio dimensional para representarlo. Las características se usan para representar patrones con el objetivo de minimizar la pérdida de información importante [44].

La selección de características juega un papel relevante en la clasificación de sistemas basados en aprendizaje de máquina. En nuestro caso, para clasificar actividades cognitivas es necesario seleccionar las características que representen el estado de relajación o *Blank Mind* y los fragmentos musicales imaginados. Por tal motivo, se propone el uso de los siguientes métodos: Transformada Discreta de Fourier (DFT por las siglas en inglés de *Discrete Fourier Transform*) y Coeficientes Cepstrales en las Frecuencias de Mel (MFCC por las siglas en inglés de *Mel-Frequency Cepstral Coefficients*).

4.3.1. Transformada Discreta de Fourier (DFT)

La señal EEG adquirida se encuentra en el dominio del tiempo y la distribución de energía está dispersa. Para extraer las características, la señal EEG es analizada para dar una descripción de la energía de la señal como una función del tiempo y/o frecuencia [45].

La DFT es una técnica muy usada para el análisis de frecuencia en áreas como acústica, imagen/video, audio, instrumentación y sistemas de comunicaciones [46]. Así también es un método muy frecuente en el análisis de señales EEG. Y con base en algunos estudios previos, las características en el dominio de la frecuencia son adecuadas para reconocer las tareas mentales basadas en señales EEG [47, 48, 49, 50], por tal motivo su exploración en este trabajo.

El primer método de análisis fue aplicar la Transformada Discreta de Fourier a la señal y así encontrar su espectro. La señal EEG no es estacionaria, lo que significa que su espectro cambia con el tiempo; dicha señal se puede aproximar como estacionaria, al utilizar una secuencia de segmentos de señal estacionarios independientes [51]. Las funciones de Fourier no representan adecuadamente las señales no estacionarias. Por lo tanto, la señal es dividida en pequeñas ventanas con solapamiento y la DFT se calcula para cada una de ellas, y así generar un conjunto de espectros que se utilizan como características. En el capítulo 5 se mencionan los diferentes tamaños de ventanas que se evaluaron, pero el tamaño de la ventana más eficiente fue de 256 muestras con un solapamiento de 255 muestras.

La ecuación de la Transformada Discreta de Fourier está definida por 4.5:

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-\frac{2\pi j}{N}kn} \quad (4.5)$$

Donde:

N : Número de muestras en $x[n]$.

$x[n]$: Señal de prueba discreta.

$X[k]$: Espectro en función de la frecuencia discreta.

El cálculo de la DFT fue importante para la obtención de los espectros de las señales EEG que se utilizaron como datos de entrenamiento para los clasificadores.

4.3.2. Coeficientes Cepstrales en las Frecuencias de Mel (MFCC)

Coeficientes Cepstrales en las Frecuencias de Mel es un método de extracción de características para la representación del habla y frecuentemente es usado en sistemas de reconocimiento de voz. El cálculo de los coeficientes MFCC es una de las técnicas de parametrización más populares. Además, se ha experimentado su uso para la extracción de características en diversas aplicaciones relacionadas al análisis de señales [52].

Particularmente se ha aplicado en la clasificación de tareas EEG. Por ejemplo, clasificación de tareas con imaginación motora [53] [54], clasificación de emociones [55] e imaginación visual [56], donde se obtuvo una alta precisión de clasificación de hasta 90%. Sin embargo, no se ha encontrado registro de su uso en imaginación musical, por tal su aplicación y exploración en esta investigación.

Para calcular los coeficientes MFCC, la señal es dividida en pequeñas ventanas con sobrelapes, cada uno de estos fragmentos de información fueron convertidos al dominio de la frecuencia por medio de la DFT. Posteriormente, los espectros se multiplican por un banco de filtros triangulares espaciados de acuerdo con la escala de frecuencias de Mel 4.6, donde f corresponde con la frecuencia representada en el eje de escala lineal.

$$mel(f) = 2595 \log_{10} \left(1 + \frac{f}{700} \right) \quad (4.6)$$

Una vez que la envolvente del espectro de la señal EEG es multiplicada por el banco, se calcula la energía correspondiente en cada uno de los filtros. Y enseguida, se hace uso de la Transformada Discreta del Coseno (DCT), que lleva los coeficientes espectrales al dominio de la frecuencia convirtiéndolos en coeficientes cepstrales (MFCC) 4.7:

$$c_n = \sqrt{\frac{2}{k}} \sum_{k=1}^k (\log S_k) \cos \left[n(k - 0.5) \frac{\pi}{k} \right] \quad (4.7)$$

Donde:

S_k : Salida del banco de filtro.

k : Longitud de S_k .

c_n : Coeficientes cepstrales.

Los coeficientes MFCC y espectros de los fragmentos de la señal EEG se calcularon con la librería de *python_speech_features* [57].

4.4. Clasificación

En aprendizaje de máquina supervisado, dado un conjunto de muestras de entrenamiento $D = \{(\underline{x}_1, y_1), (\underline{x}_2, y_2), \dots, (\underline{x}_n, y_n)\}$, el objetivo es encontrar una aproximación de la función desconocida $g : X \rightarrow Y$, que ha generado las muestras. Cada \underline{x}_i es un vector de características y y_i es la etiqueta del vector de características correspondiente. X es la matriz de características y Y es un vector correspondiente a la etiqueta de cada fila de X [58].

Algunos paradigmas estadísticos de clasificación son muy utilizados para predecir el resultado de una variable categórica en función de las variables independientes o predictorias. Por ejemplo, Regresión Logística ha sido usado en estudios relacionados a la clasificación de actividades relacionadas con imaginación musical [17] [21] [13], con buenos resultados en la clasificación de clases. Máquina de Soporte Vectorial no se encontró registro para la clasificación de actividades musicales imaginadas, pero se ha

implementado en el reconocimiento de emociones musicales [59] y en la clasificación general de señales EEG [60] [61]. Por lo tanto, debido a que han sido funcionales, se propone la implementación de estas técnicas para la clasificación de fragmentos musicales imaginados.

4.4.1. Regresión logística

La Regresión Logística (LR por las siglas en inglés de *Logistic Regression*) [62] es un algoritmo supervisado y es un clasificador de aprendizaje discriminativo que directamente estima los parámetros de la función de distribución a posteriori $P(c|\underline{x})$. Este algoritmo asume la distribución $P(c|\underline{x})$ que es dada por 4.8:

$$P(c = k|\underline{x}) = \frac{\exp(\underline{w}_k^T \underline{x})}{\sum_{j=1}^K \exp(\underline{w}_j^T \underline{x})} \quad (4.8)$$

donde \underline{w}_j representa los parámetros a estimar y K es el número de clases. Entonces el método de máxima verosimilitud se usa para aproximar directamente a \underline{w}_j . Como la matriz Hessiana para el modelo de regresión logística es positiva definida, la función de error tiene un mínimo único. El sobreajuste puede ocurrir en la regresión logística cuando los datos son escasos y de gran tamaño, lo cual puede evitarse usando la regularización L1 y L2 [63].

4.4.2. Máquina de soporte vectorial

Máquina de Soporte Vectorial (SVM por las siglas en inglés de *Support Vector Machine*) es un algoritmo de clasificación discriminativo capaz encontrar un hiperplano de decisión con la distancia máxima (margen) a los puntos de datos más cercanos (vectores de soporte) de cada clase (ver figura 4.14). La función de decisión de SVM está completamente especificada por un subconjunto de los puntos de datos de entrenamiento y la función de costo es una función convexa que conduce a una solución óptima para la tarea de optimización [64].




Figura 4.14: Ejemplo de un problema de dos clases linealmente separable por el hiperplano H_3 .

El uso de un *kernel* es beneficioso, especialmente cuando los puntos de datos no se pueden separar con un hiperplano en el espacio de características original. Esto puede conducir a una separación más fácil de los puntos de datos en el espacio de destino. Por lo tanto, el algoritmo SVM evita el problema de dimensionalidad confiando en los puntos de datos solo a través del *kernel* [65]. Un SVM lineal puede aproximarse con un kernel RBF, y está diseñado inherentemente para tareas de clasificación de dos clases, pero se han propuesto métodos diferentes para adaptarlos a problemas multiclases [66].

Evaluación y Resultados

En este capítulo se presenta la evaluación y los resultados de diferentes modelos entrenados con técnicas de aprendizaje de máquina combinados con la extracción de características que representan a los datos EEG basados en imaginación musical.

5.1. Selección y evaluación de parámetros iniciales

Para ejecutar pruebas finales fue necesario seleccionar un conjunto de parámetros para el entrenamiento de los diferentes modelos, por lo cual se realizaron pruebas preliminares basadas en los siguientes parámetros iniciales:

- Número de sujetos
- Número de clases a clasificar
- Tamaño de ventana (con o sin traslape)
- Extracción de características de la señal
- Algoritmo de clasificación
- Método de selección y eliminación de canales EEG

5.1.1. Pruebas preliminares

Estas pruebas preliminares ayudaron a seleccionar la mejor combinación de parámetros para ejecutar una serie de pruebas finales, y así evaluar métodos de clasificación y

5. EVALUACIÓN Y RESULTADOS

extracción de características de la señal EEG que ayuden a revelar mejores resultados para discernir entre *Blank Mind* y fragmentos musicales imaginados. A continuación se presentan los resultados de las dos pruebas ejecutadas, donde el principal diferenciador es el método para la extracción de características de la señal.

Prueba preliminar No. 1: Transformada Discreta de Fourier (DFT)

Los parámetros utilizados en esta prueba fueron:

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (sin traslape): 256, 128, 64 y 32 muestras
- Extracción de características de la señal: Transformada Discreta de Fourier (DFT)
- Algoritmo de clasificación: Regresión Logística y Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

En la tabla 5.1 se muestra un resumen del promedio de precisión (%) de clasificación obtenido para diferentes tamaños de ventanas de muestras (sin traslape).

Promedio	Regresión Logística (LR)				Máquina de Soporte Vectorial (SVM)			
	BM - B	BM - C	BM - D	BM - G	BM - B	BM - C	BM - D	BM - G
Ventana 32 muestras (ver 5.2)	53.9%	52.1%	55.4%	53.9%	54.8%	53.1%	53.6%	54.0%
Ventana 64 muestras (ver 5.3)	53.3%	54.7%	52.0%	56.2%	53.9%	56.7%	52.6%	53.8%
Ventana 128 muestras (ver 5.4)	57.4%	54.0%	53.4%	53.5%	54.5%	52.1%	54.2%	50.6%
Ventana 256 muestras (ver 5.5)	55.8%	51.6%	55.8%	53.2%	55.4%	53.5%	48.4%	54.2%

BM BlankMind; B Fragmento musical imaginado en tono B; C Fragmento musical imaginado en tono C; D Fragmento musical en tono D; G Fragmento musical en tono G

Tabla 5.1: Promedio de precisión de clasificación de dos clases aplicando dos algoritmos de aprendizaje de máquina para 4 tamaños de ventanas de muestras (sin traslape).

5.1 Selección y evaluación de parámetros iniciales

ID	Regresión Logística (LR)				Máquina de Soporte Vectorial (SVM)			
	BM - B	BM - C	BM - D	BM - G	BM - B	BM - C	BM - D	BM - G
S01	48.6%	50.0%	61.1%	48.1%	53.8%	54.3%	54.3%	52.4%
S02	56.3%	50.0%	58.2%	59.1%	55.8%	50.5%	50.5%	51.4%
S03	49.5%	50.0%	54.8%	55.8%	54.8%	58.2%	56.3%	57.2%
S04	54.8%	52.4%	54.3%	55.3%	50.0%	57.2%	52.9%	54.8%
S05	54.8%	53.8%	53.8%	55.3%	51.4%	49.5%	53.8%	55.8%
S06	52.9%	51.9%	50.5%	50.5%	55.8%	53.4%	55.3%	51.9%
S07	53.8%	54.3%	55.3%	56.7%	56.3%	51.0%	50.5%	51.4%
S08	60.1%	52.4%	54.8%	59.6%	56.3%	55.3%	56.3%	58.7%
S09	56.3%	51.9%	54.3%	50.5%	54.3%	54.3%	57.7%	55.3%
S10	51.0%	48.6%	56.3%	54.3%	56.3%	54.3%	58.2%	53.8%
S11	51.9%	54.8%	56.7%	48.6%	55.8%	49.5%	48.1%	55.3%
S12	57.2%	54.8%	54.8%	53.4%	56.7%	49.5%	50.0%	50.0%
Promedio	53.9%	52.1%	55.4%	53.9%	54.8%	53.1%	53.6%	54.0%

BM Blank Mind; B Fragmento musical imaginado en tono B; C Fragmento musical imaginado en tono C; D Fragmento musical en tono D; G Fragmento musical en tono G

Tabla 5.2: Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 32 muestras (sin traslape).

ID	Regresión Logística (LR)				Máquina de Soporte Vectorial (SVM)			
	BM - B	BM - C	BM - D	BM - G	BM - B	BM - C	BM - D	BM - G
S01	51.9%	51.9%	43.3%	58.7%	51.0%	59.6%	52.9%	51.9%
S02	52.9%	56.7%	51.0%	54.8%	51.0%	55.8%	56.7%	57.7%
S03	54.8%	52.9%	57.7%	61.5%	55.8%	54.8%	56.7%	48.1%
S04	53.8%	56.7%	58.7%	57.7%	57.7%	56.7%	48.1%	54.8%
S05	53.8%	55.8%	54.8%	52.9%	48.1%	59.6%	51.9%	52.9%
S06	53.8%	51.0%	52.9%	58.7%	54.8%	53.8%	55.8%	52.9%
S07	51.9%	54.8%	53.8%	51.0%	55.8%	58.7%	51.9%	57.7%
S08	43.3%	60.6%	48.1%	62.5%	54.8%	59.6%	52.9%	52.9%
S09	62.5%	56.7%	49.0%	51.0%	55.8%	53.8%	53.8%	53.8%
S10	49.0%	51.9%	49.0%	52.9%	58.7%	57.7%	48.1%	57.7%
S11	51.0%	50.0%	50.0%	54.8%	47.1%	55.8%	47.1%	49.0%
S12	60.6%	57.7%	55.8%	57.7%	56.7%	53.8%	55.8%	56.7%
Promedio	53.3%	54.7%	52.0%	56.2%	53.9%	56.7%	52.6%	53.8%

BM Blank Mind; B Fragmento musical imaginado en tono B; C Fragmento musical imaginado en tono C; D Fragmento musical en tono D; G Fragmento musical en tono G

Tabla 5.3: Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 64 muestras (sin traslape).

5. EVALUACIÓN Y RESULTADOS

ID	Regresión Logística (LR)				Máquina de Soporte Vectorial (SVM)			
	BM - B	BM - C	BM - D	BM- G	BM - B	BM - C	BM - D	BM- G
S01	57.7 %	53.8 %	44.2 %	57.7 %	59.6 %	50.0 %	59.6 %	48.1 %
S02	53.8 %	55.8 %	46.2 %	34.6 %	48.1 %	40.4 %	53.8 %	51.9 %
S03	65.4 %	53.8 %	50.0 %	50.0 %	55.8 %	48.1 %	57.7 %	53.8 %
S04	48.1 %	63.5 %	65.4 %	63.5 %	61.5 %	55.8 %	40.4 %	53.8 %
S05	61.5 %	50.0 %	51.9 %	57.7 %	51.9 %	59.6 %	57.7 %	42.3 %
S06	51.9 %	55.8 %	57.7 %	59.6 %	50.0 %	51.9 %	50.0 %	50.0 %
S07	57.7 %	48.1 %	46.2 %	53.8 %	53.8 %	53.8 %	55.8 %	53.8 %
S08	57.7 %	57.7 %	55.8 %	53.8 %	57.7 %	48.1 %	61.5 %	51.9 %
S09	55.8 %	50.0 %	53.8 %	55.8 %	55.8 %	48.1 %	46.2 %	42.3 %
S10	67.3 %	55.8 %	51.9 %	55.8 %	53.8 %	61.5 %	50.0 %	48.1 %
S11	67.3 %	51.9 %	65.4 %	55.8 %	55.8 %	57.7 %	59.6 %	61.5 %
S12	44.2 %	51.9 %	51.9 %	44.2 %	50.0 %	50.0 %	57.7 %	50.0 %
Promedio	57.4 %	54.0 %	53.4 %	53.5 %	54.5 %	52.1 %	54.2 %	50.6 %

BM Blank Mind; B Fragmento musical imaginado en tono B; C Fragmento musical imaginado en tono C; D Fragmento musical en tono D; G Fragmento musical en tono G

Tabla 5.4: Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 128 muestras (sin traslape).

ID	Regresión Logística (LR)				Máquina de Soporte Vectorial (SVM)			
	BM - B	BM - C	BM - D	BM- G	BM - B	BM - C	BM - D	BM- G
S01	53.8 %	61.5 %	57.7 %	61.5 %	50.0 %	61.5 %	26.9 %	42.3 %
S02	57.7 %	57.7 %	50.0 %	53.8 %	50.0 %	57.7 %	53.8 %	42.3 %
S03	57.7 %	42.3 %	53.8 %	53.8 %	61.5 %	42.3 %	53.8 %	61.5 %
S04	61.5 %	53.8 %	42.3 %	53.8 %	65.4 %	53.8 %	46.2 %	30.8 %
S05	42.3 %	53.8 %	65.4 %	50.0 %	53.8 %	61.5 %	53.8 %	65.4 %
S06	46.2 %	34.6 %	61.5 %	42.3 %	53.8 %	57.7 %	42.3 %	61.5 %
S07	50.0 %	57.7 %	57.7 %	53.8 %	46.2 %	50.0 %	46.2 %	57.7 %
S08	61.5 %	50.0 %	61.5 %	57.7 %	65.4 %	50.0 %	53.8 %	61.5 %
S09	46.2 %	50.0 %	50.0 %	50.0 %	57.7 %	57.7 %	61.5 %	53.8 %
S10	61.5 %	53.8 %	42.3 %	61.5 %	46.2 %	34.6 %	50.0 %	42.3 %
S11	65.4 %	50.0 %	65.4 %	57.7 %	57.7 %	61.5 %	46.2 %	69.2 %
S12	65.4 %	53.8 %	61.5 %	42.3 %	57.7 %	53.8 %	46.2 %	61.5 %
Promedio	55.8 %	51.6 %	55.8 %	53.2 %	55.4 %	53.5 %	48.4 %	54.2 %

BM Blank Mind; B Fragmento musical imaginado en tono B; C Fragmento musical imaginado en tono C; D Fragmento musical en tono D; G Fragmento musical en tono G

Tabla 5.5: Precisión de clasificación de dos clases por sujeto aplicando dos algoritmos de aprendizaje de máquina con ventanas de 256 muestras (sin traslape).

Los modelos entrenados en esta primera prueba preliminar arrojaron un desempeño muy bajo para ambos algoritmos. La precisión que se obtuvo corresponde a un porcentaje abajo del 55 % en la mayoría de los casos, indicando con esto que los modelos no son capaces de separar adecuadamente las diferentes clases. Por lo tanto, el uso de espectros

como datos de entrenamiento, no mostraron resultados satisfactorios para identificar entre el estado de relajación o *Blank Mind* y un fragmento musical imaginado. Continuando con una segunda prueba preliminar que involucra el uso de coeficientes MFCC.

Prueba preliminar No. 2: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC)

Los parámetros utilizados en esta prueba fueron:

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (sin traslape): 256, 128, 64 y 32 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 5, 10, 15, 20 y 25 coeficientes
- Algoritmo de clasificación: Regresión Logística y Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

En las tablas 5.6 y 5.7 se muestra un resumen del promedio de precisión (%) de clasificación para diferentes ventanas de muestras (sin traslape) y números de coeficientes MFCC. En este ejercicio se resumieron diferentes modelos para una mejor selección de parámetros.

Promedio	Máquina de Soporte Vectorial (SVM)				
	MFCC = 5	MFCC = 10	MFCC = 15	MFCC = 20	MFCC = 25
Ventana 32 muestras	56.5 %	56.7 %	58.2 %	58.1 %	59.3 %
Ventana 64 muestras	60.1 %	58.4 %	57.8 %	58.1 %	57.6 %
Ventana 128 muestras	60.0 %	59.4 %	56.1 %	61.6 %	62.3 %
Ventana 256 muestras	62.1 %	60.2 %	63.0 %	67.3 %	65.2 %

Tabla 5.6: Máquina de Soporte Vectorial. Promedio de precisión de clasificación de dos clases aplicando diferentes tamaños de ventanas de muestras (sin traslape) y números de coeficientes MFCC.

5. EVALUACIÓN Y RESULTADOS

Promedio	Regresión Logística (LR)				
	MFCC = 5	MFCC = 10	MFCC = 15	MFCC = 20	MFCC = 25
Ventana 32 muestras	57.4 %	57.9 %	57.1 %	56.6 %	57.6 %
Ventana 64 muestras	58.7 %	58.3 %	58.1 %	57.8 %	56.5 %
Ventana 128 muestras	56.8 %	58.3 %	59.1 %	60.3 %	62.0 %
Ventana 256 muestras	62.2 %	60.4 %	61.0 %	63.6 %	61.6 %

Tabla 5.7: Regresión Logística. Promedio de precisión de clasificación de dos clases aplicando diferentes tamaños de ventanas de muestras (sin traslape) y números de coeficientes MFCC.

Al analizar los resultados de las tablas 5.6 y 5.7 el mejor resultado se obtuvo cuando se entrenaron los modelos con ventanas de 256 muestras (sin traslape) y con 15, 20 y 25 coeficientes MFCC. Particularmente en este caso, el algoritmo basado en Máquina de Soporte Vectorial obtuvo un mejor rendimiento con respecto a Regresión Logística. Además, se comprueba con estas dos pruebas preliminares que la extracción de características de la señal es más eficiente al utilizar coeficientes MFCC en vez de espectros obtenidos con DFT, comparando con los resultados de la tabla 5.1.

Por lo tanto, se concluye que los mejores parámetros iniciales por el momento son:

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (sin traslape): 256 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 15, 20 y 25 coeficientes
- Algoritmo de clasificación: Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

5.2. Resultados: Clasificación de *Blank Mind* e imaginación musical

En este apartado se muestran los resultados obtenidos de acuerdo al entrenamiento de diferentes modelos basados en la selección de parámetros iniciales. El objetivo de estas pruebas es comprobar la clasificación de dos clases: *Blank Mind* y un fragmento musical imaginado. Por lo tanto, enseguida se presentan los diferentes modelos entrenados que se exploraron con las observaciones correspondientes para cada uno.

5.2.1. Prueba No. 1: Eliminación de canales por inspección

Los parámetros utilizados en esta prueba fueron:

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Máquina de Soporte Vectorial y Regresión Logística (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

Los resultados se observan en las gráficas [5.1](#), [5.2](#) y [5.3](#), donde se compara el porcentaje de precisión de clasificación para cada uno de los sujetos y sus clases a diferenciar.

5. EVALUACIÓN Y RESULTADOS




Figura 5.1: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 17 coeficientes MFCC.




Figura 5.2: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 21 coeficientes MFCC.




Figura 5.3: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 25 coeficientes MFCC.

Observaciones para Prueba No. 1

- Al comparar los resultados previos, Máquina de Soporte Vectorial y 21 coeficientes MFCC es la mejor combinación para diferenciar entre *Blank Mind* y cualquier fragmento musical imaginado obteniendo entre 70% y 95% de precisión en la clasificación de las clases.
- Para 17 y 25 coeficientes MFCC el porcentaje de precisión para la clasificación fue más baja. Sin embargo, los porcentajes obtenidos son funcionales para clasificar dos clases.
- El solapamiento de las ventanas de información con 255 muestras permitió incrementar el conjunto de datos para el entrenamiento y pruebas de los modelos, ayudando a generar mejores resultados.
- En ambos casos, los sujetos S02, S05 y S09 presentaron un porcentaje por arriba del 85% de precisión en la clasificación. Curiosamente, el sujeto S05 tuvo una formación musical desde los 4 años.

- Regresión Logística presentó una precisión de clasificación por debajo del 60 %, siendo un método poco robusto para los datos EEG con imaginación musical.

5.2.2. Prueba No. 2: Eliminación de canales por Kurtosis

Los parámetros utilizados en esta prueba fueron:

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Máquina de Soporte Vectorial y Regresión Logística (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Kurtosis

Los resultados se muestran en las gráficas 5.4, 5.5 y 5.6, donde se compara el porcentaje de precisión de clasificación para cada uno de los sujetos y sus clases a diferenciar. En esta prueba se aplicó Kurtosis para la eliminación de canales malos en cada uno de los registros, con el fin de verificar si es posible incrementar el porcentaje de precisión.

5.2 Resultados: Clasificación de *Blank Mind* e imaginación musical




Figura 5.4: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 17 coeficientes MFCC.




Figura 5.5: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 21 coeficientes MFCC.

5. EVALUACIÓN Y RESULTADOS




Figura 5.6: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 25 coeficientes MFCC.

Observaciones para Prueba No. 2

- Comparando las gráficas previas, nuevamente Máquina de Soporte Vectorial y 21 coeficientes MFCC es la mejor combinación para diferenciar entre *Blank Mind* y cualquier fragmento musical imaginado obteniendo entre 70 % y 90 % de precisión en la clasificación de las clases.
- Para 17 y 25 coeficientes MFCC el porcentaje de precisión para la clasificación fue más baja. No obstante, los porcentajes obtenidos son efectivos para clasificar dos clases.
- Al eliminar señales EEG con la técnica de Kurtosis la precisión de clasificación entre clases varía entre $\pm 5\%$. Por lo tanto, al utilizar esta medida estadística los resultados no son afectados significativamente.
- Nuevamente se observa que los sujetos S02, S05 y S09 presentaron un porcentaje por arriba del 80 % de precisión en la clasificación.
- Regresión Logística presentó una precisión de clasificación por debajo del 60 %,

siendo un método poco robusto para los datos EEG con imaginación musical también al aplicar Kurtosis.

5.2.3. Prueba No. 3: Eliminación de canales por coeficiente de correlación de Pearson

Los parámetros utilizados en esta prueba fueron:

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Máquina de Soporte Vectorial y Regresión Logística (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Coeficiente de Correlación de Pearson

Los resultados se presentan en las gráficas [5.7](#), [5.8](#) y [5.9](#), donde se compara el porcentaje de precisión de clasificación para cada uno de los sujetos y sus clases a diferenciar. En esta prueba se aplicó Coeficiente de Correlación de Pearson para la eliminación de canales malos en cada uno de los registros, con el fin de verificar si hay cambios significativos en el porcentaje de precisión por la clasificación de los datos EEG.

5. EVALUACIÓN Y RESULTADOS




Figura 5.7: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 17 coeficientes MFCC.




Figura 5.8: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 21 coeficientes MFCC.




Figura 5.9: Gráfica representando la precisión de clasificación de 4 modelos separando dos clases y utilizando 25 coeficientes MFCC.

Observaciones para Prueba No. 3

- Las gráficas muestran que Máquina de Soporte Vectorial y 21 coeficientes MFCC es la mejor combinación para diferenciar entre *Blank Mind* y cualquier fragmento musical imaginado obteniendo entre 70 % y 90 % de precisión en la clasificación de las clases.
- Para 17 y 25 coeficientes MFCC el porcentaje de precisión para la clasificación fue más baja pero son favorables para clasificar dos clases.
- Al eliminar señales EEG mediante el cálculo del Coeficiente de Correlación de Pearson la precisión de clasificación entre clases continua variando entre $\pm 5\%$. Por lo tanto, los resultados siguen siendo favorables.
- Se presentaron sujetos con correlaciones menores a 0.4 en los canales centrales y temporales, dibujando una segmentación de electrodos. Esto permitió realizar una exploración de canales EEG que se expone en la prueba No. 4.
- En estos resultados también los sujetos S02, S05 y S09 presentaron un porcentaje por arriba del 80 % de precisión en la clasificación.

- Regresión Logística presentó una precisión de clasificación por debajo del 60 %, siendo un método poco robusto para los datos EEG con imaginación musical aunque se haya aplicado el cálculo de Coeficiente de Correlación de Pearson.
- Con los resultados de estas primeras pruebas, se comprueba que los 3 métodos utilizados para la eliminación y selección de canales EEG permiten identificar conjuntos de señales que no son aptas para los diferentes modelos que se entrenaron. Cualquier método puede aplicarse en este corpus recolectado sin afectar significativamente los resultados. Hay que destacar que es importante el uso de estos métodos para la eliminación y selección de canales EEG con el fin de remover señales que contengan artefactos.

5.2.4. Prueba No. 4: Clusterización de electrodos aplicando coeficiente de correlación de Pearson

En la prueba No. 3 se rechazaron señales de electrodos que no están correlacionadas con sus vecinos según el Coeficiente de Correlación de Pearson y basándonos en la red de canales EEG adyacentes que se muestra en la figura 4.9 . En algunos casos, las correlaciones que no cumplieron con los criterios del apartado 4.2.2.3 coincidieron justamente con los electrodos ubicados en la zona central y temporal del cerebro, marcándose una segmentación del área cerebral en dos partes. Algunos sujetos presentaron esta división muy particular, tal y como se muestra en las figuras 5.10.

La segmentación de electrodos coincide con dos partes: área frontal y occipital del cerebro. Debido a esta similitud en 3 sujetos, se decidió realizar una clusterización de electrodos según su ubicación.

Cluster 1: Electrodos ubicados mayormente en el área frontal del cerebro.

Cluster 2: Electrodos ubicados mayormente en el área occipital del cerebro.

Por lo tanto, tomando en cuenta lo anterior, se realizó una exploración con cada uno

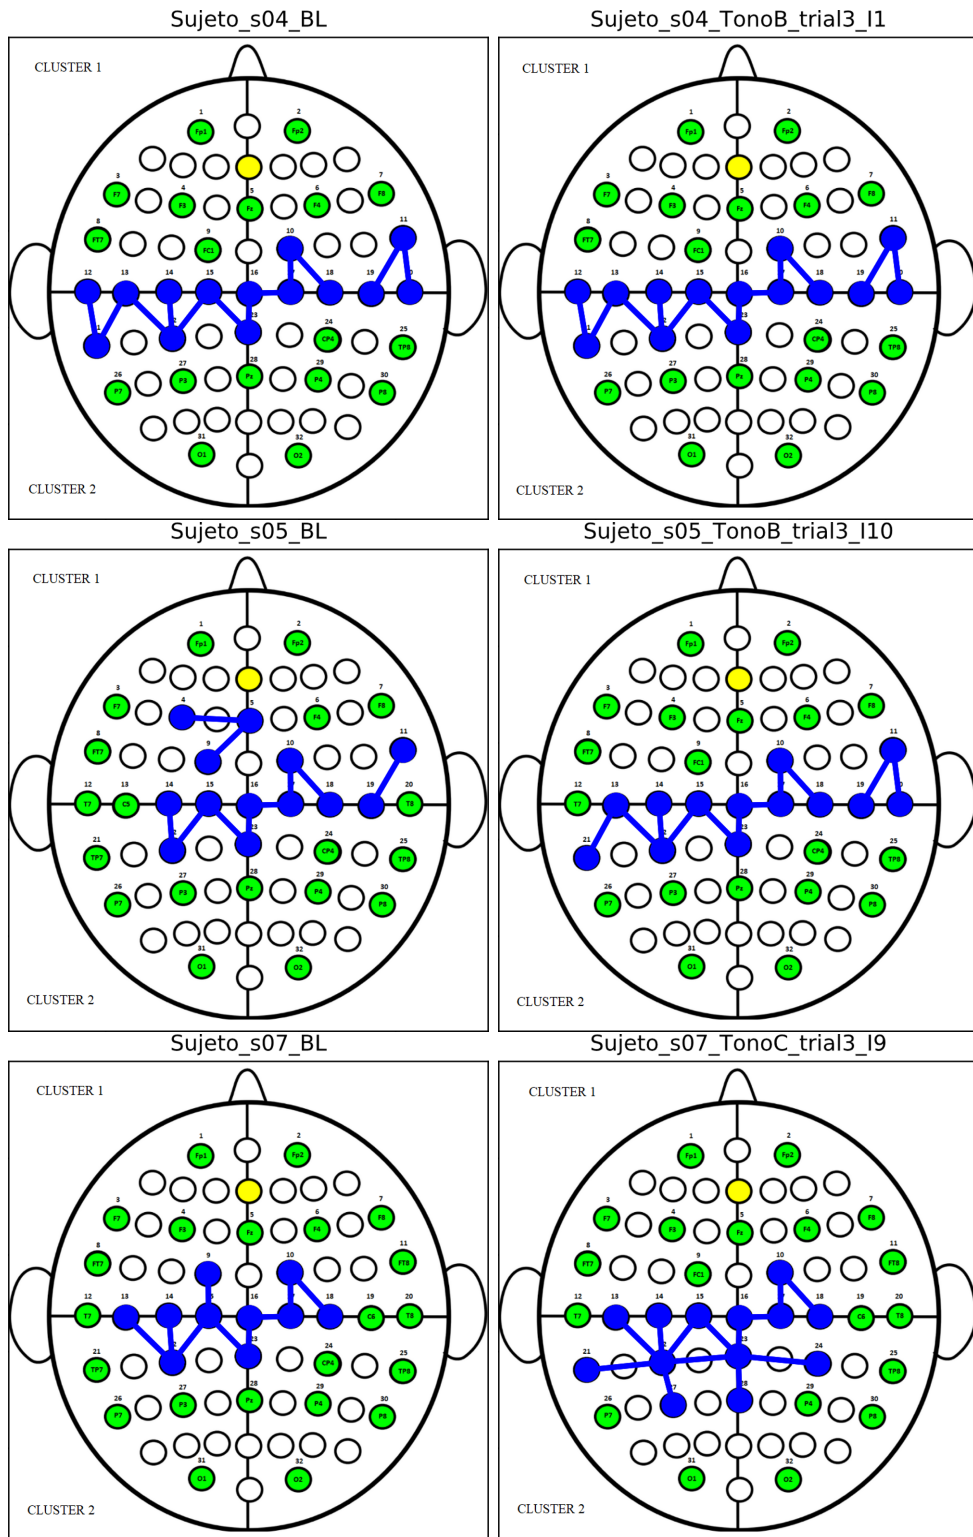


Figura 5.10: Segmentación de electrodos EEG para 3 sujetos (S04, S05 y S07) en dos clusters.

5. EVALUACIÓN Y RESULTADOS

de estos clústers para verificar si es posible identificar diferencias entre los fragmentos musicales imaginados y *Blank Mind* para cada uno de los sujetos. Es decir, se ejecutó un entrenamiento para cada uno de los clústers identificados según los siguientes parámetros de prueba:

- Número de sujetos: 3 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Coeficiente de Correlación de Pearson

Los resultados se muestran en las gráficas 5.11, 5.12 y 5.13, donde se compara el porcentaje de precisión de clasificación para cada uno de los sujetos, sus clases a diferenciar y su respectivo clúster. En esta prueba se aplicó Coeficiente de Correlación de Pearson para la eliminación de canales no correlacionados en cada uno de los registros, y principalmente segmentar el área cerebral en 2 secciones.




Figura 5.11: Comparación de 2 clústers según su precisión de clasificación para 2 clases utilizando 17 coeficientes MFCC.

5.2 Resultados: Clasificación de *Blank Mind* e imaginación musical




Figura 5.12: Comparación de 2 clústers según su precisión de clasificación para 2 clases utilizando 21 coeficientes MFCC.




Figura 5.13: Comparación de 2 clústers según su precisión de clasificación para 2 clases utilizando 25 coeficientes MFCC..

Observaciones para Prueba No. 4

- Se observa que para el clúster 1, Máquina de Soporte Vectorial y 21 coeficientes MFCC funciona adecuadamente para diferenciar entre *Blank Mind* y cualquier fragmento musical imaginado obteniendo entre 75% y 95% de precisión en la clasificación de las clases. Los valores obtenidos son muy similares con las pruebas No. 1 pero con una cantidad menor de electrodos EEG.
- Para 17 y 25 coeficientes MFCC la precisión de clasificación fue más baja en ambos clústers. Pero los porcentajes obtenidos son favorables para clasificar dos clases.
- En todos los casos, para el clúster 1 se obtuvieron mejores resultados que el clúster 2. Lo que significa que hay una mejor relación entre entre los electrodos EEG ubicados en la zona frontal con los fragmentos musicales imaginados.
- En esta prueba hay una aproximación de resultados muy similares a los de la prueba No. 1. Por tal motivo, existe la posibilidad de analizar los datos con una

cantidad menor de electrodos EEG.

5.2.5. Prueba No. 5: Clasificación de 5 clases por sujeto

En pruebas anteriores, se ha comprobado satisfactoriamente la clasificación entre *Blank Mind* y algún fragmento musical imaginado con una precisión arriba del 70 % para 12 sujetos. Por lo tanto, en esta prueba se decide realizar el entrenamiento de un modelo para clasificar 4 fragmentos musicales imaginados y *Blank Mind* para verificar si las técnicas usadas hasta el momento son capaces de diferenciar entre 5 clases. Los parámetros para esta prueba son los siguientes:

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 5 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Regresión Logística y Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

Los resultados se presentan en las gráficas [5.14](#), [5.15](#) y [5.16](#), donde se compara el porcentaje de precisión de clasificación para cada uno de los sujetos según dos algoritmos de clasificación.

5.2 Resultados: Clasificación de *Blank Mind* e imaginación musical




Figura 5.14: Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 17 coeficientes MFCC.




Figura 5.15: Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 21 coeficientes MFCC.

5. EVALUACIÓN Y RESULTADOS




Figura 5.16: Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 25 coeficientes MFCC.

Observaciones para Prueba No. 5

- En esta prueba se observa que los algoritmos de aprendizaje de máquina empleados no fueron totalmente capaces de clasificar 5 clases. Por lo tanto, como trabajo a futuro, se propone probar algoritmos de aprendizaje profundo con una mayor cantidad de datos EEG, así como experimentar otras características para la representación de las señales cerebrales.
- En esta prueba Máquina de Soporte de Vectorial sigue siendo más eficiente. Sin embargo, no se alcanzó como mínimo un 70 % de precisión en la clasificación de 5 clases.

5.2.6. Prueba No. 6: Clasificación de 5 clases para todos los sujetos

En la prueba No. 5 se experimentó clasificar 4 fragmentos musicales imaginados y *Blank Mind* pero los algoritmos no fueron lo suficientemente robustos para dicha tarea. No obstante, nos dimos a la tarea de homologar toda la información de los sujetos en un solo conjunto de datos, es decir, conocer únicamente la clase a la que pertenecen los datos y no al sujeto. Los parámetros de prueba que se aplicaron fueron:

- Número de sujetos: 12 sujetos (Información homologada)

- Número de clases a clasificar: 5 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Regresión Logística y Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

Los resultados se presentan en la gráficas 5.17, donde se compara el porcentaje de precisión de clasificación para los dos algoritmos de clasificación. Los resultados de esta prueba se predecían debido a la prueba No. 5, pero es importante presentar los datos generados en esta ejecución.




Figura 5.17: Gráfica representando la precisión de clasificación de 5 clases, 2 algoritmos y utilizando 17, 21 y 25 coeficientes MFCC con la información homologada de los 12 sujetos.

Observaciones para Prueba No. 6

- El conjunto de datos homologado que se conformó con toda la información EEG de los sujetos, proyectó una precisión baja para ambos algoritmos: Regresión Logística y Máquina de Soporte vectorial.

- Se comprueba hasta el momento que cada persona es diferente respecto a su actividad cerebral y aún no se puede generalizar. Aunque es necesario comprobar con algoritmos más sofisticados tales como redes neuronales, para comparar estos resultados.

5.2.7. Prueba No. 7: Clasificación de 4 clases para 3 sujetos

En la mayoría de pruebas realizadas se ha encontrado que los sujetos S02, S05 y S09 han tenido un mejor rendimiento en el entrenamiento de sus modelos para clasificar un fragmento musical imaginado y *Blank Mind*. Por lo tal motivo, se recurrió a homologar la información únicamente de estos 3 sujetos para clasificar 4 clases (fragmentos musicales imaginados). Es decir, disminuir la cantidad de sujetos para que no haya variabilidad de patrones tan relevante en los datos EEG. El objetivo de esta prueba es comprobar si es posible clasificar 4 clases con un solo conjunto de datos EEG. Los parámetros de prueba que se aplicaron son los siguientes:

- Número de sujetos: 3 sujetos (Información homologada)
- Número de clases a clasificar: 4 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Regresión Logística y Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

Los resultados se presentan en la gráfica [5.18](#), donde se compara el porcentaje de precisión de clasificación para los dos algoritmos de clasificación.

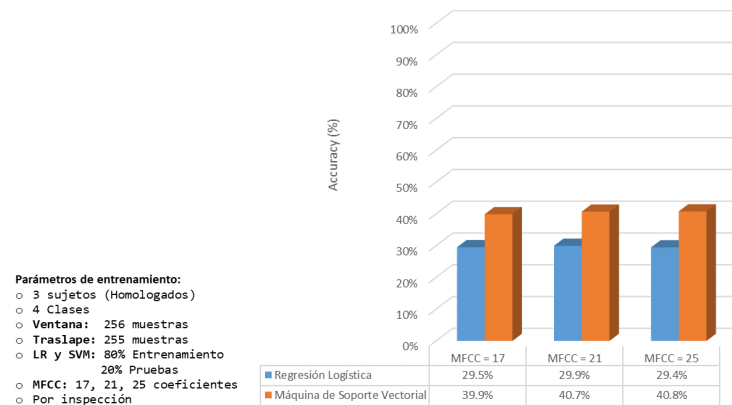


Figura 5.18: Gráfica representando la precisión de clasificación de 4 clases, 2 algoritmos y utilizando 17, 21 y 25 coeficientes MFCC con la información homologada de 3 sujetos.

Observaciones para Prueba No. 7

- El conjunto de datos homologado que se conformó con toda la información EEG de 3 sujetos con mejor rendimiento, arrojó un bajo porcentaje en la precisión de clasificación.
- Seguimos manteniendo el argumento que el desempeño de los clasificadores depende de cada sujeto.
- Buscar nuevos algoritmos, representación de los datos EEG y complementar las bases de datos posiblemente muestren resultados más prometedores.

5.3. Resultados: Clasificación de imaginación musical

Se ha comprobado que los modelos entrenados previamente saben discriminar correctamente entre *Blank Mind* y cualquier fragmento musical imaginado. Es importante saber que esta clasificación se ha logrado utilizando técnicas de aprendizaje de máquina y principalmente el uso de coeficientes MFCC para representar los datos EEG. Aún falta explorar nuevos algoritmos para mejorar la clasificación de clases, pero es necesario iniciar con una prueba que permita clasificar únicamente entre fragmentos musicales imaginados, es decir, eliminar el estado de relajación o *Blank Mind*. Para esta prueba se utilizaron los siguientes parámetros:

5. EVALUACIÓN Y RESULTADOS

- Número de sujetos: 12 sujetos
- Número de clases a clasificar: 2 clases
- Tamaño de ventana (con traslape): 256 muestras y un traslape de 255 muestras
- Extracción de características de la señal: Coeficientes Cepstrales en las Frecuencias de Mel (MFCC) con 17, 21 y 25 coeficientes
- Algoritmo de clasificación: Máquina de Soporte Vectorial (Entrenamiento 80 % y Pruebas 20 % de datos)
- Método de selección y eliminación de canales EEG: Por inspección

Los resultados se presentan en la gráficas 5.18, 5.20 y 5.21, donde se compara el porcentaje de precisión de clasificación para diferentes sujetos y coeficientes MFCC.




Figura 5.19: Gráfica representando la precisión de clasificación de 6 modelos separando dos clases y utilizando 17 coeficientes MFCC.

5.3 Resultados: Clasificación de imaginación musical




Figura 5.20: Gráfica representando la precisión de clasificación de 6 modelos separando dos clases y utilizando 21 coeficientes MFCC.




Figura 5.21: Gráfica representando la precisión de clasificación de 6 modelos separando dos clases y utilizando 25 coeficientes MFCC.

Observaciones

- Con esta prueba se comprobó que entre 2 segmentos musicales, es posible diferenciar hasta con un 78 % de precisión. Particularmente este resultado se obtuvo con Máquina de Soporte Vectorial y 21 coeficientes MFCC.
- Específicamente el fragmento musical en tono D es el más fácil de identificar en todos los modelos entrenados.

- Se comprueba que la precisión de clasificación disminuye aproximadamente un 20 % en comparación con los modelos que incluyen la clase *Blank Mind*. Por lo tanto, es importante explorar el uso de diferentes algoritmos más eficientes y robustos.
- La precisión de clasificación para todos los sujetos se mantuvo dentro de un margen del 70 % y 80 % en promedio. Lo que significa que los fragmentos musicales imaginados compartan características similares, haciendo que los modelos entrenados se confundan en la evaluación.

5.4. Resumen general de observaciones

A continuación se muestran las observaciones más importantes referentes a las pruebas realizadas:

- Para seleccionar parámetros iniciales de prueba (5.1.1), se ejecutaron dos pruebas preliminares donde se concluye que los modelos entrenados con ventanas de 256 muestras (sin traslape), coeficientes MFCC y utilizando Máquina de Soporte Vectorial arrojan un mayor desempeño en la separación de clases.
- Después de haber seleccionado los parámetros iniciales, en la prueba No. 1 (5.2.1) se comprueba que Máquina de Soporte Vectorial y 21 coeficientes MFCC es la mejor combinación para diferenciar entre *Blank Mind* y cualquier fragmento musical imaginado obteniendo entre 70 % y 95 % de precisión en la clasificación de las clases. Además, el solapamiento de las ventanas de información con 255 muestras permitió incrementar el conjunto de datos para el entrenamiento y pruebas de los modelos, ayudando a generar mejores resultados. Y por último, los sujetos S02, S05 y S09 presentaron un porcentaje por arriba del 85 % de precisión en la clasificación.
- En las pruebas No. 2 (5.2.2) y No. 3 (5.2.3) resultó que Máquina de Soporte Vectorial y 21 coeficientes MFCC es la mejor combinación para diferenciar entre

Blank Mind y cualquier fragmento musical imaginado obteniendo entre 70 % y 90 % de precisión en la clasificación de las clases. Ambas técnicas aplicadas para la selección y eliminación de canales EEG, revelaron un cambio de precisión entre \pm 5 % para la clasificación entre clases. Por lo tanto, los resultados no son afectados significativamente.

- Al generar clústers de electrodos en la prueba No. 4 (5.2.4), se observa que para el clúster 1, Máquina de Soporte Vectorial y 21 coeficientes MFCC funciona adecuadamente para diferenciar entre *Blank Mind* y cualquier fragmento musical imaginado obteniendo entre 75 % y 95 % de precisión en la clasificación de las clases. Por lo tanto, existe la posibilidad de analizar los datos con una cantidad menor de electrodos EEG.
- En la prueba No. 5 (5.2.5) se comprueba que los algoritmos de aprendizaje de máquina empleados no fueron totalmente capaces de clasificar 5 clases. Es necesario emplear algoritmos más potentes.
- En la prueba No. 6 (5.2.6) se realizó una homologación de datos EEG con la información de todos los sujetos, obteniendo una precisión baja para ambos algoritmos utilizados al separar 5 clases. Comprobando hasta el momento que cada persona es diferente respecto a su actividad cerebral y aún no se puede generalizar.
- Posteriormente, en la prueba No. 7 (5.2.7) se realizó la homologación de datos EEG únicamente con la información de 3 sujetos quienes presentaron un alto rendimiento en las pruebas, pero también mostró un bajo porcentaje para la clasificación de clases. Manteniendo el argumento referente a que el desempeño de los clasificadores depende de cada sujeto.
- En la última prueba (5.3) se experimentó únicamente la clasificación de fragmentos musicales imaginados. La prueba reveló que es posible diferenciar entre 2 segmentos musicales imaginados hasta con un 78 % de precisión, aplicando Máquina de Soporte Vectorial y 21 coeficientes MFCC. Específicamente el fragmento

5. EVALUACIÓN Y RESULTADOS

musical en tono D es el más fácil de identificar en todos los modelos entrenados

- En las gráficas 5.22 y 5.23 se muestran los modelos con mejor desempeño durante el desarrollo de este trabajo. La gráfica 5.22 muestra la precisión de clasificación para diferenciar entre un fragmento musical imaginado y un estado de relajación (*Blank Mind*). Por otro lado, la gráfica 5.23 presenta la precisión de clasificación para diferenciar únicamente entre 2 fragmentos musicales imaginados, observando que los sujetos S02, S05 y S12 imaginan con mayor facilidad tonos totalmente diferentes, por mencionar algunos casos. Es decir, no se muestra una tendencia a la imaginación de algún tono en específico para todos los sujetos. No obstante, la combinación de tonos C y G indica mayor complejidad de imaginación para los sujetos.
- Por último, en la tabla 5.8 se muestra un resumen comparativo de las investigaciones más representativas relacionadas al área de imaginación musical. Especificando métodos y condiciones de prueba, así como el desempeño de los diferentes modelos entrenados. Además, se incluyen los resultados generales obtenidos en este trabajo para resaltar el desempeño conseguido.




Figura 5.22: Gráfica lineal representando la precisión de clasificación entre un fragmento musical imaginado y un estado de relajación (*Blank Mind*).

5.4 Resumen general de observaciones




Figura 5.23: Gráfica lineal representando la precisión de clasificación entre 2 fragmentos musicales imaginados.

5. EVALUACIÓN Y RESULTADOS

Referencia	Enfoque	Paradigma BCI	Núm. de sujetos	Núm. de canales EEG	Filtro espectral	Características de la señal	Método de clasificación	Resultados (% de Precisión)
Curran E. (2004)	Clasificación de 4 tareas cognitivas	- Imaginación auditiva (Un tono familiar) - Imaginación motora (Movimiento de la mano derecha e izquierda) - Imaginación de navegación espacial (Navegación de un cuarto a otro)	10	7	Entre 0.1Hz y 100 Hz	Coefficientes de reflexión Modelo autorregresivo (AR)	Regresión Logística (LR)	Modelo con mejor desempeño: Imaginación de navegación espacial vs Imaginación auditiva (74%)
Schaefer R.S. (2009)	Clasificación de 4 frases musicales	- Percepción musical - Imaginación musical	6	N/A	N/A	Señal cruda	Regresión Logística (LR) Lineal	Percepción musical (90%) Imaginación musical (Entre 70% y 90%)
Schaefer R.S. (2010)	Clasificación de 7 segmentos musicales	- Percepción musical	10	64	Entre 1 Hz y 14 Hz	Señal cruda ERP	Regresión Logística (LR) Lineal regularizado con L2	Percepción musical (Entre 25% y 70%)
Vlak R.L. (2011)	Clasificación de 3 patrones métricos beats	- Percepción musical - Imaginación musical	10	64	Entre 0.5 y 15 Hz	Señal cruda ERP	Regresión Logística (LR) regularizado con L2	Modelo 1: Percepción (74.9%) Modelo 2: Imaginación (65.7%) Modelo 3: Percepción [Training data] Imaginación [Test data] (66.4%) Modelo 4: Imaginación [Training data] Percepción [Test data] (59.8%)
Soriano D. (2013)	Clasificación de 2 tareas cognitivas	- Imaginación musical (Una canción) - Imaginación motora (Movimiento de la mano izquierda)	9	64	N/A	PSD Método de Welch	Análisis Discriminante Lineal (LDA)	Imaginación musical (69%) Imaginación motora (89%)
Serrin A. (2016)	Clasificación de 12 estímulos musicales	- Percepción musical - Imaginación musical	10	64	Entre 0.5 y 30 Hz	Señal cruda ERP	Red neuronal convolucional (CNN)	Imaginación musical (28.7%) Percepción musical (7.41%)
Sistema propuesto (2018)	Clasificación de 2 tareas cognitivas	- Estado de relajación - Imaginación musical (4 fragmentos musicales)	12	32	Entre 1 Hz y 14 Hz	MFCPC	Máquina de Soporte Vectorial (SVM)	Estado de relajación vs Fragmento musical (95%) Modelo 2: Fragmentos musicales (78%)

ERP Potencial Relacionado con Eventos; PSD Densidad Espectral de Potencia.

Tabla 5.8: Comparación de resultados obtenidos en este proyecto respecto a las principales investigaciones relacionadas al área de imaginación musical.

Conclusiones

En este capítulo se presenta un resumen de los logros alcanzados en el desarrollo de esta tesis. Además, se discuten los puntos que podrían estudiarse como trabajo a futuro.

6.1. Resumen y contribuciones

Al inicio de esta tesis se planteó un objetivo general que consiste en implementar un sistema que permita discernir entre un conjunto acotado de actividades musicales imaginadas de manera intencional por un usuario (usando Imaginación Musical como paradigma BCI), extrayendo su actividad cerebral por medio de una BCI. Esta meta tiene como intención explorar la posibilidad de crear a largo plazo un sistema de composición musical básicamente orientado a personas que hayan perdido sus habilidades motoras. Por lo tanto, el uso de dispositivos BCI basados en un paradigma de imaginación musical es una combinación prometedora para la identificación de actividades musicales imaginadas por un usuario y, esto principalmente, reforzado con el uso de algoritmos basados en aprendizaje de máquina y técnicas para la extracción de características en las señales EEG.

Actualmente hay varias investigaciones donde se han realizado experimentos para hacer aproximaciones interesantes en el área, así como comprobar que la música imaginada es un paradigma funcional con BCI's. Estos experimentos son complicados de imple-

6. CONCLUSIONES

mentar, si no existen bases de datos conformadas por señales cerebrales que permitan el entrenamiento de modelos basados en inteligencia artificial. Y como se observa en el apartado 2.4, no hay suficientes bases de datos públicas con imaginación musical. Por tal motivo, fue necesario conformar una nueva base de datos EEG con imaginación musical de 12 participantes con experiencia en el área de música. Es un proceso largo y lento pero se espera que en un futuro se pueda compartir a la comunidad para realizar nuevas investigaciones que complementen y ayuden a generar nuevos descubrimientos en el área de imaginación musical como paradigma BCI.

El procedimiento para la clasificación de fragmentos musicales imaginados ha sido desarrollado con algoritmos de aprendizaje de máquina. Esto significa que es necesario una recolección importante de información para que los algoritmos cuenten con datos de entrenamiento relevantes, y así sean capaces de predecir el valor correspondiente según haya sido la entrada que reciba la función. Por lo tanto, como trabajo a futuro, se pueden explorar técnicas de aprendizaje profundo con esta base de datos EEG recolectada que complementen los resultados obtenidos en este proyecto.

Por otro lado, al analizar las diferentes pruebas ejecutadas se obtuvieron resultado similares entre sí. Es decir, se comprobó que la combinación con mejores resultados es el uso de Máquina de Soporte Vectorial y coeficientes MFCC para diferenciar entre *Blank Mind* y cualquier fragmento musical imaginado obteniendo entre un 70 % y 95 % de precisión en la clasificación. Anteriormente, los coeficientes MFCC no habían sido probados en imaginación musical, únicamente en imaginación motora. Por lo tanto, una aportación importante ha sido la comprobación del uso de coeficientes MFCC para la representación de señales EEG, debido a que han otorgado un alto desempeño en el entrenamiento de diferentes modelos evaluados.

Específicamente para esta colección de datos EEG, se comprobó que al aplicar un método estadístico para la selección de canales, el rendimiento en los modelos entre-

nados varía aproximadamente entre ± 5 de precisión. Es decir, los 3 métodos aplicados funcionan correctamente para discriminar canales EEG que no son de interés. Así también, aplicando Coeficiente de Correlación de Pearson en algunos sujetos, se mostró claramente una división de la cabeza en área frontal y occipital. Por lo tanto, se entrenaron modelos para verificar si existe una correlación entre estas áreas de la cabeza con la imaginación musical. Los resultados arrojaron una precisión similar a los modelos iniciales. Sin embargo, la información de la parte frontal ayudó a diferenciar mejor entre 2 clases. Indicando la posibilidad de usar menos electrodos en el análisis de datos EEG con imaginación musical.

Al entrenar modelos de aprendizaje de máquina supervisado para clasificar 5 clases para cada sujeto, se obtuvieron resultados poco favorables. Esto comprueba que hay mucha información que no es fácil diferenciar con los modelos de Regresión Logística y Máquina de Soporte Vectorial. Por tal razón, es necesario verificar con otras técnicas más robustas o añadir más datos de entrenamiento. Adicionalmente, se decidió homologar los datos EEG de todos los sujetos, con el fin de comprobar si Regresión Logística y/o Máquina de Soporte Vectorial permiten clasificar diferentes clases. Los resultados proyectaron una precisión baja. Demostrando que cada persona es diferente respecto a su actividad cerebral y es complicado aún generalizar. Incluso al homologar la información de los sujetos S02, S05 y S09 que obtuvieron individualmente un alto rendimiento, no fue posible clasificar eficientemente entre 4 clases.

Y por último, se comprobó que la mayoría de los modelos saben discriminar correctamente entre *Blank Mind* y algún fragmento musical imaginado. Además, se comprobó que la clasificación entre 2 fragmentos musicales imaginados es posible diferenciar hasta con un 78 % de precisión. Y particularmente, el fragmento musical en tono D es el más fácil para clasificar respecto a los demás. Esto da la pauta de seguir realizando nuevos experimentos pero únicamente con datos relacionados a la imaginación de fragmentos musicales imaginados.

6.2. Trabajo a futuro

A continuación se mencionan algunas actividades como trabajo a futuro que deberían desarrollarse para complementar y mejorar el proyecto relacionado a Interfaz Cerebro Computadora con imaginación musical.

- Se propone probar algoritmos más robustos capaces de clasificar únicamente fragmentos musicales imaginados. Por ejemplo, redes neuronales entrenadas con coeficientes MFCC y complementar con diferentes métricas de evaluación.
- El punto anterior debe ser complementado con el análisis y extracción de otras características para la representación de los datos EEG.
- Debido a la existencia en el mercado de diferentes dispositivos portátiles BCI, se recomienda iniciar la exploración de estos dispositivos, principalmente para acelerar el proceso de adquisición de datos EEG.
- En caso de generar una nueva base de datos con algún dispositivo BCI portátil, se propone probar otras tareas musicales imaginadas para verificar su desempeño. Por ejemplo, combinar imaginación motora con imaginación musical, tal como tocar las teclas de un piano. Así como incrementar la duración del ejercicio de imaginación para contar con mayor cantidad de información para alimentar una red neuronal.
- Iniciar el diseño y desarrollo del módulo de audición que se propone al inicio de este proyecto, con el fin de sonificar los fragmentos musicales imaginados que son identificados por el sistema.

6.3. Colaboraciones

Universidad Autónoma Metropolitana (UAM), Unidad Iztapalapa

Laboratorio de Neuroimagenología (LINI)

M. C. Miguel Ángel Porta García

Ing. Sául Pérez Velázquez

Facultad de Música, UNAM

Mtra. Gabriela Pérez Acosta

Alumnos de música (Participantes)

Fragmentos musicales

A.1. Partituras musicales

En esta sección se observa la representación gráfica de los 4 fragmentos musicales que escucharon los sujetos de prueba durante el experimento de imaginación musical. En las partituras se observa que las piezas musicales tienen el mismo ritmo armónico. Los audios están disponibles en *SoundCloud* [1].



Figura A.1: Partitura del fragmento musical en tono B



Figura A.2: Partitura del fragmento musical en tono C



Figura A.3: Partitura del fragmento musical en tono D

A. FRAGMENTOS MUSICALES



Figura A.4: Partitura del fragmento musical en tono G

Bibliografía

- [1] Playlist de fragmentos musicales. <https://soundcloud.com/jose-francisco-neri-gonzalez/sets/fragmentos-musicales>. Created: 2018. xvii, 23, 77
- [2] José Francisco Neri González. *Diseño y desarrollo de un sistema para el control mental de prótesis utilizando una Interfaz Cerebro-Computadora (BCI)*. Tesis, Universidad Nacional Autónoma de México, 2013. 1, 16
- [3] Jonathan R Wolpaw, Niels Birbaumer, Dennis J McFarland, Gert Pfurtscheller, and Theresa M Vaughan. Brain-computer interfaces for communication and control, jun 2002. 1
- [4] Minkyu Ahn, Mijin Lee, Jinyoung Choi, and Sung Chan Jun. A review of brain-computer interface games and an opinion survey from researchers, developers and users. *Sensors*, 14(8):14601–14633, 2014. 1
- [5] G. R. Muller-Putz and G. Pfurtscheller. Control of an electrical prosthesis with an ssvp-based bci. *IEEE Transactions on Biomedical Engineering*, 55(1):361–364, Jan 2008. 1
- [6] Christian J Bell, Pradeep Shenoy, Rawichote Chalodhorn, and Rajesh P N Rao. Control of a humanoid robot by a noninvasive brain–computer interface in humans. *Journal of Neural Engineering*, 5(2):214, 2008. 1
- [7] Karl LaFleur, Kaitlin Cassady, Alexander Doud, Kaleb Shades, Eitan Rogin, and

- Bin He. Quadcopter control in three-dimensional space using a noninvasive motor imagery based brain-computer interface. *J Neural Eng*, 10(4):10.1088/1741-2560/10/4/046003, Aug 2013. 23735712[pmid]. 1
- [8] Alvin Lucier. *Music for solo performer*. cd, 1965. 2
- [9] David Rosenboom. Method for producing sounds or light flashes with alpha brain waves for artistic purposes. *Leonardo*, 5(2):141–145, 1972. 2
- [10] Steve Mann, James Fung, and Ariel Garten. Deconcert : Bathing in the light, sound, and waters of the musical brainbaths. *International Computer Music Conference, ICMC*, pages 204–211, 2007. 2
- [11] Brahim Hamadicharef, Mufeng Xu, and Sheel Aditya. Brain-Computer Interface (BCI) based musical composition. *Proceedings - 2010 International Conference on Cyberworlds, CW 2010*, pages 282–286, 2010. 2
- [12] Takayuki Hamano, Tomasz M Rutkowski, Hiroko Terasawa, Kazuo Okanoya, and Kiyoshi Furukawa. Generating an Integrated Musical Expression with a Brain – Computer Interface. *Nime 2013 Proceedings of the International Conference on New Interfaces for Musical Expression*, 2013. 2, 5
- [13] Rebecca S Schaefer, Yvonne Blokland, Jason Farquhar, and Peter Desain. Single trial classification of perceived and imagined music from eeg. In *Berlin BCI Workshop*. Citeseer, 2009. 3, 9, 36
- [14] Sebastian Stober and Jessica Thompson. Music Imagery Information Retrieval Bringing the Song on Your Mind Back to Your Ears. *Ismir 2012*, 2012. 3
- [15] Avital Sternin. *Classifying music perception and imagination using EEG*. Thesis, The University of Western Ontario, 2016. 3, 11
- [16] Rebecca S. Schaefer, Jason Farquhar, Yvonne Blokland, Makiko Sadakata, and Peter Desain. Name that tune: Decoding music from the listening brain. *NeuroImage*, 56(2):843 – 849, 2011. Multivariate Decoding and Brain Reading. 4

- [17] R. J. Vlek, R. S. Schaefer, C. C.A.M. Gielen, J. D.R. Farquhar, and P. Desain. Shared mechanisms in perception and imagery of auditory accents. *Clinical Neurophysiology*, 122(8):1526–1532, 2011. [4](#), [10](#), [25](#), [36](#)
- [18] Sebastian Stober, Avital Sternin, Adrian M Owen, and Jessica A Grahn. Towards Music Imagery Information Retrieval: Introducing the OpenMIIR Dataset of EEG Recordings from Music Perception and Imagination. *16th International Society for Music Information Retrieval Conference (ISMIR'15)*, pages 763–769, 2015. [11](#), [14](#)
- [19] Gert Pfurtscheller and Christa Neuper. Motor imagery and direct brain- computer communication. *Proceedings of the IEEE*, 89(7):1123–1134, 2001. [11](#)
- [20] Diogo Soriano, Elvis L. Silva, Gabriel F. Slenes, Fabricio O. Lima, Luisa F S Uribe, Guilherme P. Coelho, Eric Rohmer, Thiago D. Venancio, Guilherme C. Beltramini, Brunno M. Campos, Carlos A S Anjos, Ricardo Suyama, Li M. Li, Gabriela Castellano, and Romis Attux. Music versus motor imagery for BCI systems a study using fMRI and EEG: Preliminary results. *ISSNIP Biosignals and Biorobotics Conference, BRC*, pages 2–7, 2013. [12](#)
- [21] Eleanor Curran, Peter Sykacek, Maria Stokes, Stephen J. Roberts, Will Penny, Ingrid Johnsrude, and Adrian M. Owen. Cognitive Tasks for Driving a Brain-Computer Interfacing System: A Pilot Study. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 12(1):48–54, 2004. [13](#), [36](#)
- [22] Aboul Ella Hassanien and Ahmad Taher Azar. *Brain-Computer Interfaces: Current Trends and Applications*. Springer Publishing Company, Incorporated, 2014. [15](#)
- [23] B. Graimann, B.Z. Allison, and G. Pfurtscheller. *Brain-Computer Interfaces: Revolutionizing Human-Computer Interaction*. The Frontiers Collection. Springer Berlin Heidelberg, 2010. [15](#), [16](#)
- [24] Matti Hämäläinen, Riitta Hari, Risto J. Ilmoniemi, Jukka Knuutila, and Olli V. Lounasmaa. Magnetoencephalography—theory, instrumentation, and applications

- to noninvasive studies of the working human brain. *Rev. Mod. Phys.*, 65:413–497, Apr 1993. [17](#)
- [25] Dale L Bailey, David W Townsend, Peter E Valk, and Michael N Maisey. *Positron emission tomography*. Springer, 2005. [17](#)
- [26] Gabor T Herman. *Fundamentals of computerized tomography: image reconstruction from projections*. Springer Science & Business Media, 2009. [17](#)
- [27] Richard B Buxton. *Introduction to functional magnetic resonance imaging: principles and techniques*. Cambridge university press, 2009. [17](#)
- [28] L Bokobza. Near infrared spectroscopy. *Journal of Near Infrared Spectroscopy*, 6(1):3–17, 1998. [17](#)
- [29] Andrea R Halpern, Robert J Zatorre, Marc Bouffard, and Jennifer A Johnson. Behavioral and neural correlates of perceived and imagined musical timbre. *Neuropsychologia*, 42(9):1281–1292, 2004. [18](#)
- [30] David JM Kraemer, C Neil Macrae, Adam E Green, and William M Kelley. Musical imagery: sound of silence activates auditory cortex. *Nature*, 434(7030):158, 2005. [18](#)
- [31] Sibylle C Herholz, Claudia Lappe, Arne Knief, and Christo Pantev. Neural basis of music imagery and the effect of musical expertise. *European Journal of Neuroscience*, 28(11):2352–2360, 2008. [18](#)
- [32] Sibylle C Herholz, Andrea R Halpern, and Robert J Zatorre. Neuronal correlates of perception, imagery, and memory for familiar tunes. *Journal of cognitive neuroscience*, 24(6):1382–1397, 2012. [18](#)
- [33] Robert J Zatorre and Andrea R Halpern. Mental concerts: musical imagery and auditory cortex. *Neuron*, 47(1):9–12, 2005. [18](#)

- [34] Rebecca S Schaefer, Jason Farquhar, Yvonne Blokland, Makiko Sadakata, and Peter Desain. Name that tune: decoding music from the listening brain. *neuroimage*, 56(2):843–849, 2011. 18
- [35] Avital Sternin, Sebastian Stober, JA Grahn, and AM Owen. Tempo estimation from the eeg signal during perception and imagination of music. In *1st International Workshop on Brain-Computer Music Interfacing/11th International Symposium on Computer Music Multidisciplinary Research (BCMI/CMMR'15)(Plymouth)*, 2015. 18
- [36] Kyung Myun Lee, Erika Skoe, Nina Kraus, and Richard Ashley. Selective subcortical enhancement of musical intervals in musicians. *Journal of Neuroscience*, 29(18):5832–5840, 2009. 19
- [37] g.Tec Medical Engineering. <http://www.gtec.at/Products/Hardware-and-Accessories/g.USBamp-Specs-Features>. Accessed: 2017. 20
- [38] F.M. Unturbe. *Neuroimagen: técnicas y procesos cognitivos*. Elsevier Doyma, 2007. 20
- [39] Schalk Lab, BCI2000. <http://www.schalklab.org/research/bci2000>. Accessed: 2017. 20
- [40] Yuuko Morita, Hung-Hsuan Huang, and Kyoji Kawagoe. Towards music information retrieval driven by eeg signals: Architecture and preliminary experiments. In *Computer and Information Science (ICIS), 2013 IEEE/ACIS 12th International Conference on*, pages 213–217. IEEE, 2013. 25
- [41] Viateur Tuyisenge, Lena Trebaul, Manik Bhattacharjee, Blandine Chanteloup-Forêt, Carole Saubat-Guigui, Ioana Mîndruță, Sylvain Rheims, Louis Maillard, Philippe Kahane, Delphine Taussig, et al. Automatic bad channel detection in intracranial electroencephalographic recordings using ensemble machine learning. *Clinical Neurophysiology*, 2017. 27, 28

- [42] Lawrence T DeCarlo. On the meaning and use of kurtosis. *Psychological methods*, 2(3):292, 1997. [27](#), [28](#)
- [43] Jacob Benesty, Jingdong Chen, Yiteng Huang, and Israel Cohen. Pearson correlation coefficient. In *Noise reduction in speech processing*, pages 1–4. Springer, 2009. [28](#)
- [44] Dean Cvetkovic, Elif Derya Übeyli, and Irena Cosic. Wavelet transform feature extraction from human ppg, ecg, and eeg signal responses to elf pemf exposures: A pilot study. *Digital signal processing*, 18(5):861–874, 2008. [33](#)
- [45] Abdul-Bary Raouf Suleiman, Toka Abdul-Hameed Fatehi, et al. Features extraction techniques of eeg signal for bci applications. *Faculty of Computer and Information Engineering Department College of Electronics Engineering, University of Mosul, Iraq*, 2007. [34](#)
- [46] Parthana Sarma, Prakash Tripathi, Manash Pratim Sarma, and Kandarpa Kumar Sarma. Pre-processing and feature extraction techniques for eeg-bci applications-a review of recent research. *ADBU Journal of Engineering Technology*, 5(1), 2016. [34](#)
- [47] Marcin Kołodziej, Andrzej Majkowski, and Remigiusz J Rak. Linear discriminant analysis as eeg features reduction technique for brain-computer interfaces. *Przegląd Elektrotechniczny (Electrical Review)*, 2012. [34](#)
- [48] Ilja Kuzovkin. Pattern recognition for non-invasive eeg-based bci. *Bachelor's thesis, University of Tartu Faculty of Mathematics and Computer Science Institute of Computer Science*, 2011. [34](#)
- [49] Gernot R Müller-Putz, Evelin Eder, Selina C Wriessnegger, and Gert Pfurtscheller. Comparison of dft and lock-in amplifier features and search for optimal electrode positions in ssvp-based bci. *Journal of neuroscience methods*, 168(1):174–181, 2008. [34](#)

- [50] Rebeca Corralejo, Roberto Hornero, and Daniel Alvarez. Feature selection using a genetic algorithm in a motor imagery-based brain computer interface. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, pages 7703–7706. IEEE, 2011. 34
- [51] Athena Akrami, Soroosh Solhjoo, Ali Motie-Nasrabadi, and M-R Hashemi-Golpayegani. Eeg-based mental task classification: Linear and nonlinear classification of movement imagery. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, pages 4626–4629. IEEE, 2006. 34
- [52] Lindasalwa Muda, Mumtaj Begam, and Irraivan Elamvazuthi. Voice recognition algorithms using mel frequency cepstral coefficient (mfcc) and dynamic time warping (dtw) techniques. *arXiv preprint arXiv:1003.4083*, 2010. 35
- [53] Jackie Teh and MP Paulraj. Motor-imagery task classification using mel-cepstral and fractal fusion based features. *Indian journal of science and technology*, 8(20), 2015. 35
- [54] W. Abdul and J. W. Wong. Cortical activities pattern recognition for the limbs motor action. In *2008 IET 4th International Conference on Intelligent Environments*, pages 1–7, July 2008. 35
- [55] Marini Othman, Abdul Wahab, and Reza Khosrowabadi. Mfcc for robust emotion detection using eeg. In *Communications (MICC), 2009 IEEE 9th Malaysia International Conference on*, pages 98–101. IEEE, 2009. 35
- [56] Nasrin Shourie. Cepstral analysis of eeg during visual perception and mental imagery reveals the influence of artistic expertise. *Journal of medical signals and sensors*, 6(4):203, 2016. 35
- [57] Python Speech Features’s documentation. <http://python-speech-features.readthedocs.io/en/latest/>. Accessed: 2017. 36

- [58] Hossein Bashashati, Rabab K Ward, Gary E Birch, and Ali Bashashati. Comparing different classifiers in sensory motor brain computer interfaces. *PloS one*, 10(6):e0129435, 2015. [36](#)
- [59] Yuan-Pin Lin, Chi-Hong Wang, Tien-Lin Wu, Shyh-Kang Jeng, and Jyh-Horng Chen. Support vector machine for eeg signal classification during listening to emotional music. In *Multimedia Signal Processing, 2008 IEEE 10th Workshop on*, pages 127–130. IEEE, 2008. [37](#)
- [60] Giovanni Costantini, Massimiliano Todisco, Daniele Casali, M Carota, Giovanni Saggio, Luigi Bianchi, M Abbafati, and L Quitadamo. Svm classification of eeg signals for brain computer interface. In *Proceedings of the 2009 conference on Neural Nets WIRN09: Proceedings of the 19th Italian Workshop on Neural Nets, Vietri sul Mare, Salerno, Italy, May 28–30 2009*, pages 229–233. IOS Press, 2009. [37](#)
- [61] Fabien Lotte, Marco Congedo, Anatole Lécuyer, Fabrice Lamarche, and Bruno Arnaldi. A review of classification algorithms for eeg-based brain–computer interfaces. *Journal of neural engineering*, 4(2):R1, 2007. [37](#)
- [62] A Criminisi, J Shotton, and E Konukoglu. Decision forests for classification, regression, density estimation, manifold learning and semi-supervised learning [internet]. *Microsoft Research*, 2011. [37](#)
- [63] Christopher M Bishop et al. Pattern recognition and machine learning (information science and statistics). 2006. [37](#)
- [64] Sergios Theodoridis, Konstantinos Koutroumbas, et al. Pattern recognition. *IEEE Transactions on Neural Networks*, 19(2):376, 2008. [37](#)
- [65] Hossein Bashashati, Rabab K Ward, Gary E Birch, and Ali Bashashati. Comparing different classifiers in sensory motor brain computer interfaces. *PloS one*, 10(6):e0129435, 2015. [38](#)

- [66] Chih-Wei Hsu and Chih-Jen Lin. A comparison of methods for multiclass support vector machines. *IEEE transactions on Neural Networks*, 13(2):415–425, 2002. [38](#)