

INSTITUTO TECNOLÓGICO DE CHIHUAHUA
DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

***“ANÁLISIS Y DISEÑO DE TÉCNICAS PARA
RECONOCIMIENTO DE
VISUALIZACIONES MOTORAS
PARA APLICACIONES EN TIEMPO REAL”***

TESIS

QUE PARA OBTENER EL GRADO DE

***MAESTRO EN CIENCIAS EN INGENIERÍA
ELECTRÓNICA***

PRESENTA:

ING. EDUARDO RIVAS POSADA

DIRECTOR DE LA TESIS:

DR. MARIO IGNACIO CHACÓN MURGUÍA

CHIHUAHUA, CHIH., ENERO 2020



SEP
SECRETARÍA DE
EDUCACIÓN PÚBLICA



TECNOLÓGICO NACIONAL DE MÉXICO





Chihuahua, Chih. 15 de enero de 2020

MTRO. LUIS CARDONA CHACÓN
JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
PRESENTE

Por medio de la presente notificamos a usted que en cumplimiento de los requerimientos para la obtención del grado de Maestro en Ciencias en Ingeniería Electrónica, el documento de tesis del **C. EDUARDO RIVAS POSADA**, ha sido aprobado y aceptado para su impresión. El título de la tesis es:

"Análisis y diseño de técnicas para reconocimiento de visualizaciones motoras para aplicaciones en tiempo real"

Por lo que proponemos, le sea concedida la autorización de impresión correspondiente.

Agradeciendo la atención a la presente, quedamos de usted:

ATENTAMENTE

Excelencia en Educación Tecnológica
"La técnica por el Engrandecimiento de México"


DR. MARIO IGNACIO CHACÓN MURGUÍA
DIRECTOR DE TESIS

Juan Ramírez

DR. JUAN ALBERTO RAMÍREZ QUINTANA
MIEMBRO DEL JURADO DE EXAMEN

DR. LUIS FRANCISCO CORRAL MARTÍNEZ
MIEMBRO DEL JURADO DE EXAMEN

MTRA. ALMA DELIA CORRAL SÁENZ
MIEMBRO DEL JURADO DE EXAMEN





Chihuahua, Chih. 15 de enero de 2020

**C. EDUARDO RIVAS POSADA
PRESENTE**

Por este conducto le comunico que a propuesta del Jurado de Examen, la División de Estudios de Posgrado e Investigación ha concedido autorización para la impresión de su tesis para obtener el grado de Maestro en Ciencias en Ingeniería Electrónica, cuyo título es:

"Análisis y diseño de técnicas para reconocimiento de visualizaciones motoras para aplicaciones en tiempo real"

La tesis presenta el siguiente contenido de capítulos:

- I Introducción
- II Antecedentes de la tesis
- III Metodologías de reconocimiento para 2 VM
- IV Metodología de reconocimiento para 4 VM
- V Metodología para toma de muestras
- VI Aplicación BCI en tiempo real
- VII Conclusiones y trabajo futuro

ATENTAMENTE

Excelencia en Educación Tecnológica.
"La técnica por el Engrandecimiento de México"

MTRO. LUIS CARDONA CHACÓN
JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN





CARTA CESIÓN DE DERECHOS

En la ciudad de Chihuahua el día **20 de enero de 2020**, el que suscribe **C. EDUARDO RIVAS POSADA** de la Maestría en Ciencias en Ingeniería Electrónica, con número de control **G18060028**, adscrito a la **DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN**, del Instituto Tecnológico de Chihuahua, manifiesta que es autor intelectual del presente trabajo de Tesis bajo la dirección del **Dr. Mario Ignacio Chacón Murguía** y cede los derechos del trabajo titulado ***"Análisis y diseño de técnicas para reconocimiento de visualizaciones motoras para aplicaciones en tiempo real"***, al Tecnológico Nacional de México y/o Instituto Tecnológico de Chihuahua para su difusión, divulgación, transmisión, reproducción, así como su digitalización con fines académicos y de investigación.

C. EDUARDO RIVAS POSADA



Chihuahua, Chihuahua a 20 de enero de 2020

Dra. María Elena Álvarez-Buylla Roces

Directora de CONACYT.

Presente.

Por este conducto aprovecho la ocasión para saludarla e informarle que a la fecha he obtenido el grado de **Maestría en Ciencias en Ingeniería Electrónica** en la División de Estudios de Posgrado e Investigación del Instituto Tecnológico de Chihuahua. Motivo por el cual agradezco todo el apoyo brindado por esta Institución que usted representa, el otorgamiento de esta beca permitió dedicarme de tiempo completo a la realización de mis estudios de Posgrado y de esta manera lograr el cumplimiento del objetivo principal del convenio establecido.

Sin otro particular por el momento, me es grato quedar de usted como su seguro servidor, no sin antes reiterar mi agradecimiento. Muchas Gracias.

A t e n t a m e n t e



Eduardo Rivas Posada

Exbecario CONACYT

Agradecimientos

Agradezco a la Sagrada Familia. A Jesús, mi Dios, por ser mi Fuerza, mi Amor, mi Esperanza, mi Luz en los momentos difíciles y mi mayor fuente de Alegría en el día a día. A María por ser mi fiel compañera y modelo de amor para llegar a Dios, por ser mi Mamá. A José, por ser un ejemplo a seguir para mí de confianza, abandono en Dios, de ser padre y hombre.

Agradezco a toda mi familia que tanto amo. A mi mamá, Refugio Posada y a mi hermana Gabriela Rivas. Gracias por estar conmigo en cada decisión, en cada momento de alegría y de dificultad, por enseñarme que el valor de la vida es amar a Dios. Gracias Ammá y Gaby por apoyarme y quererme tanto. A mi papá Jesús Rivas, te mando un abrazo enorme hasta el cielo.

A Mayra Silva, mi amor, mi compañera que Dios ha puesto a mi lado para complementarme y llegar más fácil, juntos en Santidad, hacia Él. Muchas gracias por tu apoyo incondicional, por hacerme sonreír, por cuidarme y compartir tu vida conmigo.

Agradezco a mi director de tesis, el doctor Mario Chacón. Gracias por ser un ejemplo a seguir para mí y permitirme aprender de usted en este proyecto de tesis de maestría, por brindarme herramientas y consejos para hacer un buen trabajo y más aún, para ser mejor persona.

A todos mis profesores y comité tutorial, Dr. Juan Ramírez, M.C. Alma Corral, Dr. Luis F. Corral quienes contribuyeron enormemente en mi formación académica y profesional durante esta maestría.

Agradezco a todos mis compañeros y amigos del laboratorio de Percepción Visual y Robótica y compañeros durante la maestría. A mi primo Daniel, Andrea, Abimael, Luis, Pepe, Soto, Rulo, Esquivel, Iván, Javier, Xavier, Alonso, Camacho, Miguel, Vicente, Elí, Adrián con quienes compartí momentos inolvidables e hicieron más alegre las actividades diarias y de quienes he aprendido mucho.

Agradezco al TecNM por el apoyo a este trabajo bajo el proyecto Clave 5684.16-P, Adquisición, procesamiento y análisis de señales EEG dirigida a generar nuevo conocimiento y tecnología para interfaz cerebro-computadora orientada a rehabilitación virtual.

RESUMEN

ANÁLISIS Y DISEÑO DE TÉCNICAS PARA RECONOCIMIENTO DE VISUALIZACIONES MOTORAS PARA APLICACIONES EN TIEMPO REAL

Ing. Eduardo Rivas Posada
Maestría en Ciencias en Ingeniería Electrónica
División de Estudios de Posgrado e Investigación
Tecnológico Nacional de México / I. T. Chihuahua
Chihuahua, Chih., 2020
Director de tesis: Dr. Mario Ignacio Chacón Murguía

En los últimos años se ha estudiado la implementación de sistemas basados en interfaz cerebro-computadora como medios alternativos de comunicación, utilizando la actividad cerebral del usuario y su reinterpretación en comandos. En esta tesis se utilizan los ritmos sensoriomotores para detectar visualizaciones motoras.

En el estado del arte se encuentran métodos para extraer características y clasificar visualizaciones motoras implementados en sistemas que trabajan fuera de línea. En este trabajo se tiene el objetivo de analizar y diseñar técnicas para reconocimiento de visualizaciones motoras y generar nuevos métodos para clasificarlas e implementar aplicaciones en tiempo real. Para ello, se evalúan 5 métodos para extraer características basados en patrones espaciales y transformaciones tiempo-frecuencia, así como la implementación de dos clasificadores: máquinas de vectores de soporte y redes neuronales convolucionales.

La metodología final se compone de patrones espaciales comunes en combinación con la transformada Wavelet continua y un clasificador basado en redes neuronales convolucionales y se evaluó en tres etapas: con dos bases de datos, con una base de datos propia evaluada fuera de línea y en tiempo real. Al evaluar las bases de datos el mejor desempeño fue del $97.25\% \pm 1.76\%$ al clasificar visualizaciones motoras de manos izquierda y derecha, y del $91.37\% \pm 03.29\%$ al clasificar visualizaciones motoras de las manos derecha, izquierda, pies y lengua con un tiempo de ejecución de 270 ms. Para evaluar la metodología fuera de línea, se realizó una base de datos propia con 15 sujetos y 4 visualizaciones motoras con un desempeño promedio del $86.48\% \pm 4.74\%$. Para la evaluación en tiempo real se diseñaron 4 escenarios

virtuales en los cuales participaron 8 de los 15 sujetos de la base de datos propia y se presentan resultados cuantitativos y cualitativos.

En conclusión, se presenta una metodología competente con el estado del arte con desempeños superiores e implementada en tiempo real, contribuyendo a la investigación de interfaces cerebro-computadora basadas en visualizaciones motoras.

Contenido

LISTA DE FIGURAS	xii
LISTA DE TABLAS	xv
CAPÍTULO 1	1
1. INTRODUCCIÓN	1
CAPÍTULO 2	4
2. ANTECEDENTES DE LA TESIS	4
2.1 Fundamentos teóricos	4
2.1.1 Neurotecnología	4
2.1.2 Interfaz cerebro-computadora	4
2.1.3 Visualización motora	6
2.2 Trabajos realizados	7
2.2.1 Métodos y protocolos para adquisición de señales cerebrales	8
2.2.2 Métodos de extracción de características	10
2.2.3 Algoritmos de clasificación.	14
2.2.4 Aplicaciones	16
CAPÍTULO 3	18
3. METODOLOGÍAS DE RECONOCIMIENTO PARA 2 VM	18
3.1 Aspectos generales de las metodologías	18
3.2 Bases de datos	18
3.2.1 <i>BCI Competition IV dataset 2a</i>	19
3.2.2 <i>EEGdataset</i>	20
3.3 Preprocesamiento	21
3.3.1 Extracción de épocas	22
3.3.2 Aumento de datos	22
3.4 Métodos de extracción de características	23
3.4.1 Método 1: <i>common spatial patterns</i>	23
3.4.2 Método 2: <i>continuous Wavelet transform</i>	25
3.4.3 Método 3: <i>Stockwell transform</i>	26
3.4.4 Método 4: <i>common spatial patterns + continuous Wavelet transform</i>	26
3.4.5 Método 5: <i>common spatial patterns + Stockwell transform</i>	28
3.5 Clasificadores	29
3.5.1 Clasificador 1: <i>support vector machine</i>	29

3.5.2 Clasificador 2: <i>convolutional neural network</i>	33
3.6 Resultados	44
3.6.1 Desempeños de la base de datos <i>BCI Competition IV dataset 2a</i>	45
3.6.2 Desempeños de la base de datos <i>EEGdataset</i>	46
3.7 CSP ₄ y CSP ₆	52
3.8 Conclusiones del capítulo	53
CAPÍTULO 4.	56
4. METODOLOGÍA DE RECONOCIMIENTO PARA 4 VM	56
4.1 Esquema monolítico.....	57
4.1.1 Resultados del esquema monolítico.....	59
4.2 Esquema modular.....	59
4.2.1 Clasificadores de 2 VM utilizando <i>cross-validation</i>	61
4.3 Comparación del método propuesto con otros en la literatura.....	64
4.4 Conclusiones del capítulo	69
CAPÍTULO 5.	71
5. METODOLOGÍA PARA TOMA DE MUESTRAS.....	71
5.1 Base de datos.....	71
5.2 Adquisición de datos.....	72
5.3 Preprocesamiento	75
5.4 Extracción de épocas y aumento de datos.....	77
5.5 Extracción de características mediante CSP ₆ +CWT.....	77
5.6 Implementación del esquema modular de red CNN	78
5.7 Conclusiones del capítulo	82
CAPÍTULO 6.	84
6. APLICACIÓN BCI EN TIEMPO REAL	84
6.1 Implementación de la metodología en tiempo real	84
6.2 Escenarios virtuales para evaluar la metodología en tiempo real	85
6.2.1 Escenario de entrenamiento	86
6.2.2 Escenario nivel 1: baño	87
6.2.3 Escenario nivel 2: autopista	91
6.2.4 Escenario nivel 3: carritos.....	92
6.3 Métricas de evaluación de la aplicación BCI en tiempo real	94
6.3.1 Resultados generales	94

6.3.2 Resultados individuales.....	96
6.3.3 Resultados cualitativos.....	100
6.4 Conclusiones del capítulo	108
CAPÍTULO 7.....	110
7. CONCLUSIONES Y TRABAJO FUTURO	110
REFERENCIAS.....	115
NOTACIÓN MATEMÁTICA.....	121
GLOSARIO	123
ANEXOS 1-15 Consentimientos informados de los sujetos para pruebas BCI	126

LISTA DE FIGURAS

Figura 2.1 Posicionamiento de electrodos de acuerdo con sistema Internacional 10-20 [5].	6
Figura 2.2 Ejemplo de actividad cerebral ante el efecto ERD y ERS [6].	7
Figura 2.3 Comparación entre el paradigma de Graz y su retroalimentación (del lado izquierdo) contra el paradigma propuesto por F. Škola y F. Liakopoulos en [8].	9
Figura 2.4 Sistema de entrenamiento con base en VR implementado en [8].	9
Figura 2.5 Ambiente virtual para la implementación del sistema embebido con VR para neurorrehabilitación elaborado en [9].	10
Figura 2.6 Ambiente virtual para manejo de automóvil [36].	17
Figura 2.7 Ejemplo de Máquina de estados presentada en [38].	17
Figura 3.1. Metodología utilizada en este proyecto para la clasificación de dos VM.	19
Figura 3.2. Esquema de tiempo del paradigma [39].	20
Figura 3.3. Esquema de tiempo del paradigma [29].	21
Figura 3.4. Wavelet Morlet	25
Figura 3.5. Ejemplo de ventana gaussiana para implementar transformada Stockwell.	26
Figura 3.6. Ejemplo de CWT de la VM de la mano izquierda.	27
Figura 3.7. Ejemplo de CWT de la VM de la mano derecha.	28
Figura 3.8. Ejemplo de ST de la VM de la mano izquierda.	28
Figura 3.9. Ejemplo de ST de la VM de la mano derecha.	29
Figura 3.10. Imagen de entrada a la CNN utilizando CWT de una VM de la mano izquierda.	35
Figura 3.11. Imagen de entrada a la CNN utilizando CWT de una VM de la mano derecha. ..	35
Figura 3.12. Imagen de entrada a la CNN utilizando ST de una VM de la mano izquierda.	36
Figura 3.13. Imagen de entrada a la CNN utilizando ST de una VM de la mano derecha.	37
Figura 3.14. Arquitectura de la red neuronal convolucional utilizada en [33].	37
Figura 3.15. Arquitectura de la red CNN para dos visualizaciones motoras.	38
Figura 3.16. Desempeños obtenidos al utilizar ST+CNN.	46
Figura 3.17. Desempeños obtenidos al utilizar CSP ₂ +CWT+CNN.	47
Figura 3.19. Desempeños obtenidos al utilizar CSP ₂ +ST+CNN	49
Figura 3.20. Desempeños generales obtenidos en <i>EEGdataset</i> por [29].	49
Figura 3.21. Matrices de confusión de etapa de entrenamiento y validación del sujeto 29.	50
Figura 3.22. Matrices de confusión de etapa de entrenamiento y validación del sujeto 34.	50

Figura 4.1. Ejemplos de I_{CSP_CWT} de cada VM obtenidas del sujeto 03 de <i>BCI Competition IV dataset 2a</i>	56
Figura 4.2. Diagrama del esquema monolítico.	57
Figura 4.3. Arquitectura CNN para 4 clases.	58
Figura 4.4. Resultados de entrenamiento y validación bajo el esquema monolítico para 4 clases.	59
Figura 4.5. Esquema modular utilizado en el clasificador de 4 VM.	60
Figura 4.6. Escala para evaluar desempeños, del más alto (verde o número 1) al más bajo (rojo o número 9).	62
Figura 4.7. Resultados al evaluar el conjunto de prueba bajo el esquema modular para clasificar 4 VM.	64
Figura 5.1. Posición de los electrodos en el casco Ultracortex Mark IV para la toma de muestras.	72
Figura 5.2. Protocolo para la toma de muestras que corresponde a un ensayo.	73
Figura 5.3. Ventana de reposo dentro de la interfaz para toma de muestras.	73
Figura 5.4. Pistas de cada VM dentro de la interfaz para toma de muestras.	74
Figura 5.5. Animaciones de cada VM dentro de la interfaz para toma de muestras.	75
Figura 5.6. Escala para evaluar desempeños, del más alto (verde o número 1) al más bajo (rojo o número 15).	80
Figura 6.1. Esquema para implementar metodología en tiempo real.	84
Figura 6.2. Escenario de entrenamiento dentro de la interfaz BCI para tiempo real en condiciones iniciales.	86
Figura 6.3. Ayudas visuales en el escenario de entrenamiento y detección de la mano izquierda en el escenario de entrenamiento.	87
Figura 6.4. Ventanas de ayuda visual (panel visual) para su uso en los diversos escenarios virtuales.	87
Figura 6.5. Escenario nivel 1: baño en condiciones iniciales.	88
Figura 6.6. Escenario nivel 1: baño, después de que el sujeto de prueba ejecutó 9 VM de la mano derecha.	89
Figura 6.7. Escenario nivel 1: baño, después de haber ejecutado 10 VM de la mano derecha y 8 VM de la mandíbula.	89
Figura 6.8. Escenario nivel 1: baño, después de haber ejecutado 10 VM de la mano derecha, 10 VM de la mandíbula y 8 VM de la mano izquierda.	90
Figura 6.9. Escenario nivel 1: baño, después de completar el escenario virtual.	90
Figura 6.10. Escenario nivel 2: autopista en condiciones iniciales.	91

Figura 6.11. Escenario nivel 2: autopista, ejemplificando que el usuario no necesita el panel de ayuda visual.....	92
Figura 6.12. Escenario nivel 3: carritos en condiciones iniciales cuando el sujeto seleccionado posee un clasificador de VM de mano izquierda contra VM de los pies.....	93
Figura 6.13. Escenario nivel 3: carritos, ejemplificando que el sujeto debe realizar VM de la mano izquierda para esquivar el auto que se aproxima.....	93
Figura 6.14. Escenario nivel 3: carritos, ejemplo de choque entre carritos cuando el sujeto realizó mal la VM o el sistema la detectó como errónea.	94

LISTA DE TABLAS

Tabla 2.1 Principales ondas cerebrales.	6
Tabla 2.2. Algunos trabajos reportados en el estado del arte.	16
Tabla 3.1. Hiperparámetros utilizados durante el entrenamiento de la CNN	44
Tabla 3.2. Desempeños obtenidos con SVM en <i>BCI Competition IV dataset 2a</i>	45
Tabla 3.3. Desempeños obtenidos con CNN en <i>BCI Competition IV dataset 2a</i>	45
Tabla 3.4. Desempeños obtenidos con SVM en <i>EEGdataset</i>	47
Tabla 3.5. Desempeños obtenidos con CNN en <i>EEGdataset</i>	47
Tabla 3.6. Desempeños promedios de ambas bases de datos utilizando VM de mano izquierda y VM de mano derecha.	51
Tabla 3.7. Desempeños de <i>BCI Competition IV dataset 2a</i> al utilizar CSP ₄ y CSP ₆	52
Tabla 3.8. Desempeños de <i>EEGdataset</i> al utilizar CSP ₄ y CSP ₆	52
Tabla 4.1 Resultados de los clasificadores de 2 VM de la etapa de entrenamiento bajo el esquema modular.	61
Tabla 4.2 Resultados de los clasificadores de 2 VM de la etapa de validación bajo el esquema modular.	62
Tabla 4.3 Resultados del esquema modular.	63
Tabla 4.4 Comparación del método propuesto con [20] al evaluar VM de la mano izquierda vs VM de la mano derecha.	64
Tabla 4.5 Comparación del método propuesto con [20] al evaluar VM de pies vs VM de lengua.	65
Tabla 4.6 Comparación del método propuesto con trabajos de la literatura al clasificar 4 VM en términos de desempeño.	66
Tabla 4.7 Comparación del método propuesto con trabajos de la literatura al clasificar 4 VM utilizando el coeficiente kappa.	67
Tabla 4.8 Comparación general del método propuesto con trabajos de la literatura.	68
Tabla 5.1. Distribución de las sesiones para toma de muestras realizadas por los sujetos de prueba.	76
Tabla 5.2. Resultados del entrenamiento de los clasificadores CNN de 2 VM por sujeto.	79
Tabla 5.3. Resultados de la validación los clasificadores CNN de 2 VM por sujeto.	79
Tabla 5.4. Resultados del esquema modular utilizando la moda, sgSM y coeficiente kappa.	81
Tabla 6.1. Características de los equipos de cómputo para pruebas de interfaz en tiempo real.	85
Tabla 6.2. Resultados del nivel 1 del sistema BCI en tiempo real.	95

Tabla 6.3. Resultados del nivel 2 del sistema BCI en tiempo real.....	95
Tabla 6.4. Resultados del nivel 3 del sistema BCI en tiempo real.....	96
Tabla 6.5. Resultados de los niveles 1 y 2 del sujeto s_{10}	97
Tabla 6.6. Resultados de los niveles 1 y 2 del sujeto s_8	97
Tabla 6.7. Resultados de los niveles 1 y 2 del sujeto s_1	97
Tabla 6.8. Resultados de los niveles 1 y 2 del sujeto s_{11}	97
Tabla 6.9. Resultados de los niveles 1 y 2 del sujeto s_{14}	98
Tabla 6.10. Resultados de los niveles 1 y 2 del sujeto s_{15}	98
Tabla 6.11. Resultados de los niveles 1 y 2 del sujeto s_6	98
Tabla 6.12. Resultados de los niveles 1 y 2 del sujeto s_5	98
Tabla 6.13a. Preguntas 1 y 2 del cuestionario para evaluar la métrica cualitativa.	101
Tabla 6.13b. Preguntas 3 y 4 del cuestionario para evaluar la métrica cualitativa.	102
Tabla 6.13c. Preguntas 5, 6 y 7 del cuestionario para evaluar la métrica cualitativa.	103
Tabla 6.13d. Preguntas 8 y 9 del cuestionario para evaluar la métrica cualitativa.	104
Tabla 6.13e. Pregunta 10 del cuestionario para evaluar la métrica cualitativa.	105

CAPÍTULO 1.

1. INTRODUCCIÓN

El cerebro humano es el órgano ubicado dentro del Sistema Nervioso Central que está encargado de procesar información sensorial, del razonamiento, de controlar los movimientos y de otras funciones más. Esto genera actividad eléctrica que puede ser registrada mediante diversas técnicas como el electroencefalograma o EEG, en que, a través del posicionamiento de electrodos en el cuero cabelludo, se obtienen las diferencias de voltaje producto de dicha actividad cerebral. Estos datos crudos pueden ser almacenados y sometidos a procesos de clasificación para interpretar la información obtenida. Con base en la información anterior y el avance tecnológico, han surgido diversas ideas acerca de cómo aprovechar la actividad eléctrica cerebral. Una de ellas son las interfaces cerebro-computadora o BCI (del inglés *Brain-Computer Interface*) que se muestran como un medio alternativo de comunicación, permitiendo que el usuario, a través del registro de la actividad cerebral y su reinterpretación en comandos, tenga interacción con un ambiente virtual o con elementos electromecánicos como una prótesis.

El diseño general de un sistema BCI abarca diferentes etapas como la adquisición de la señal cerebral, el preprocesamiento de los datos crudos obtenidos, la etapa de selección y extracción de características para la detección de los eventos y el reconocimiento del evento que se presenta en el registro de la actividad eléctrica cerebral. Para llevar a cabo estas etapas es necesario elegir el tipo de señal cerebral con la cual se quiere trabajar. Entre las señales más importantes debido a su factible implementación en sistemas basados en BCI están los ritmos sensoriomotores que se utilizan para detectar visualizaciones motoras (VM) las cuales representan la actividad cerebral que se produce al momento de imaginar una acción física sin la ejecución real de dicho movimiento

En la literatura se observan retos y oportunidades para detectar visualizaciones motoras al utilizar una interfaz BCI, ya que se pretende realizar un sistema en tiempo real basado en BCI, eficiente y amigable con los usuarios, que brinde desempeños altos de clasificación y que

implemente novedosos métodos y protocolos para la toma de muestras, extracción de características, clasificación y aplicaciones.

Por lo tanto, contribuyendo con el esfuerzo de diseñar e implementar metodologías de clasificación de VM en tiempo real, esta tesis tiene como objetivo analizar y diseñar técnicas para reconocimiento de visualizaciones motoras para aplicaciones en tiempo real. Para ello se desarrolla una metodología que abarca las etapas de clasificación:

- Preprocesamiento, donde se incluye la implementación de un filtro pasa-bandas que abarca los ritmos sensoriomotores correspondientes a la actividad cerebral de una visualización motora.
- Extracción de épocas y una técnica para aumento de datos.
- Etapa de extracción de características, donde se analizaron herramientas como patrones espaciales comunes o CSP (del inglés *Common Spatial Patterns*), transformada Wavelet continua o CWT (del inglés *Continuous Wavelet Transform*), transformada Stockwell o ST (del inglés *Stockwell Transform*), CSP+CWT y CSP+ST.
- Etapa de clasificación, donde se utilizaron dos clasificadores: uno basado en máquinas de vectores de soporte o SVM (del inglés *Support vector machine*) y otro basado en redes neuronales convolucionales o CNN (del inglés *Convolutional Neural Network*)
- Etapa de control virtual, donde se diseñó e implementó una aplicación BCI en tiempo real que incluye 4 escenarios virtuales.

Para analizar y evaluar las herramientas propuestas se utilizaron dos bases de datos: *BCI Competition IV dataset 2a* que incluye VM de la mano izquierda, derecha, pies y lengua de 9 sujetos de prueba y *EEGdataset* que contiene VM de la mano izquierda y de la mano derecha de 52 sujetos de prueba. La primera evaluación consistió en discriminar entre VM de la mano derecha contra VM de la mano izquierda. La segunda evaluación abarcó las 4 VM de la base de datos *BCI Competition IV dataset 2a* donde se proponen dos esquemas de clasificación: uno monolítico y otro modular.

Para concluir la evaluación de la metodología propuesta en tiempo real se realizó una base de datos propia que incluye VM de la mano izquierda, mano derecha, pies y mandíbula de 15 sujetos de prueba. Asimismo, se diseñaron 4 escenarios virtuales que utilizan dichas VM y se plantean dos métricas complementarias de evaluación: una cuantitativa y otra cualitativa.

El documento está organizado de la siguiente manera. En el capítulo 2: antecedentes de la tesis, se presentan trabajos relacionados y la tendencia de los sistemas basados en BCI que utilizan visualizaciones motoras. Luego, en el capítulo 3 se hace un análisis y diseño de métodos de reconocimiento para 2 VM y en el capítulo 4 se extiende el reconocimiento a 4 VM. En el capítulo 5 se muestra la metodología para la toma de muestras de la base de datos propia y en el capítulo 6 se define el desarrollo de la aplicación en tiempo real. Para concluir la tesis, en el capítulo 7 se presentan las conclusiones y el trabajo futuro.

CAPÍTULO 2.

2. ANTECEDENTES DE LA TESIS

En esta sección se muestran los fundamentos teóricos y un panorama de trabajos realizados en los últimos años para conformar la base de los antecedentes de esta tesis.

2.1 Fundamentos teóricos

Como primer punto, es necesario dar a conocer los conceptos teóricos que se utilizan dentro del área de la neurotecnología, especialmente en el enfoque de interfaces cerebro-computadora que utilizan VM, así como los algoritmos de procesamiento más reportados en la literatura referentes a dicha área.

2.1.1 Neurotecnología

La neurotecnología se define como el conjunto de métodos, instrumentos y herramientas que permiten una conexión directa entre el sistema nervioso humano y componentes tecnológicos, utilizando electrodos para adquisición de señales cerebrales, unidades de procesamiento de información y/o prótesis inteligentes o sistemas de control [1]. Mediante este tipo de comunicación es posible explorar el comportamiento de la actividad cerebral, dado algún estímulo externo, visualización motora o elementos específicos de las señales cerebrales. Así, uno de los campos más actuales donde se aplica neurotecnología es el referente a interfaces cerebro-computadora.

2.1.2 Interfaz cerebro-computadora

Un sistema interfaz cerebro-computadora o interfaz BCI (*Brain Computer Interface*, por sus siglas en inglés) tiene como fin controlar acciones virtuales o dispositivos electrónicos externos como una prótesis o un robot, utilizando como entrada al sistema, señales cerebrales [2].

Los sistemas BCI se pueden clasificar en síncronos o asíncronos, dependiendo del tipo de procesamiento de datos. Un sistema BCI sincrónico analiza las señales cerebrales durante tiempos de ventana predefinidos, por lo que al usuario se le permite realizar la actividad cerebral, en este caso una visualización motora que será convertida en un comando, durante un

período específico determinado por el sistema. En cambio, un sistema BCI asincrónico analiza continuamente las señales cerebrales, sin importar el instante en el que el usuario realice la visualización motora [3].

Al igual que cualquier sistema de clasificación, un sistema BCI incluye actividades de adquisición de las señales cerebrales [4]:

- Preprocesamiento
- Extracción de características
- Clasificación de los datos obtenidos
- Sistema de control

En la etapa de preprocesamiento, por lo general, se aplican filtros para reducir el ruido de la señal EEG. Después, se extraen características y se utilizan herramientas para reducir la dimensión de la señal sin perder información valiosa. En seguida, las características obtenidas alimentan un clasificador que, en conjunto con el sistema de control, permite llevar a cabo una acción física o virtual deseada o recibir retroalimentación del sistema.

Por otra parte, para la adquisición de las señales cerebrales se pueden aplicar diversos métodos que se clasifican en invasivos y no invasivos. En un sistema invasivo se colocan electrodos directamente en la corteza cerebral por medio de un proceso quirúrgico para registrar las señales cerebrales. En cambio, un sistema no invasivo permite capturar las señales cerebrales mediante técnicas que no requieren de cirugía. La más utilizada en BCI es el electroencefalograma o EEG, que permite obtener la actividad eléctrica cerebral mediante diferencias de voltaje que se producen en los electrodos ubicados en el cuero cabelludo y una referencia. Dichos electrodos se posicionan en zonas específicas definidas por el Sistema Internacional o sistema 10-20, como se observa en la figura 2.1.

En el caso de un BCI que utiliza señales EEG, se puede medir la actividad cerebral una vez que los electrodos se colocan en el cuero cabelludo. Las principales ondas cerebrales se muestran en la tabla 2.1, donde se proporciona información del rango de frecuencia y el estado correspondiente a analizar en cada una de ellas.




Figura 2.1 Posicionamiento de electrodos de acuerdo con sistema Internacional 10-20 [5].

Tabla 2.1 Principales ondas cerebrales.

Onda	Rango de frecuencia	Estado
<i>Beta</i>	12 – 30 Hz	Estado de vigilia normal de la conciencia, cognición, enfoque, alerta, concentración.
<i>Alfa</i>	7.5 – 12 Hz	Relajación profunda, creatividad, visualización, ligera meditación con los ojos cerrados.
<i>Mu</i>	7.5 – 12 Hz	Aparecen en el área sensoriomotora del cerebro cuando el cuerpo está físicamente relajado.
<i>Theta</i>	4 -7.5 Hz	Sueño ligero, imágenes vívidas en la imaginación, meditación profunda.
<i>Delta</i>	0.1 – 4 Hz	Sueño profundo.

Algunas de las señales comúnmente utilizadas para implementar una interfaz BCI son los potenciales evocados visuales de estado estable o SSVEP (por sus siglas en inglés de *Steady State Visually Evoked Potentials*), los potenciales relacionados a eventos o ERP (por sus siglas en inglés de *Event Related Potentials*) y los ritmos sensoriomotores (que comprenden las ondas Mu y Beta) para detectar visualizaciones motoras. Estas últimas señales basadas en ritmos sensoriomotores representan la base de este trabajo.

2.1.3 Visualización motora

Una visualización motora se puede ver como la ejecución mental de un acto motor sin la necesidad de una salida física que manifieste dicho movimiento. Está ampliamente aceptado que la visualización de movimientos involucra las mismas regiones/funciones cerebrales que se relacionan con la programación y preparación de dichos movimientos. De acuerdo con este

punto de vista, la diferencia principal entre la ejecución y la visualización es que en el último caso la ejecución se bloquearía en algún nivel corticoespinal [6].

Las señales generadas por este tipo de actividad cerebral son conocidas como ritmos sensoriomotores que abarcan, principalmente, los ritmos Mu y Beta (ver tabla 1). Estos ritmos poseen ciertas características en amplitud, debido a la conectividad funcional dentro de la corteza cerebral, lo que resulta en una supresión de amplitud mejor conocida como “desincronización de eventos relacionados” (ERD del inglés *Event-Related Desynchronization*) o en una mejora de amplitud conocido como “sincronización de eventos relacionados” (ERS del inglés *Event-Related Synchronization*) [6]. En la figura 2.2 se observa este comportamiento característico debido a la ejecución del movimiento de un dedo de la mano derecha. Algo similar sucedería en el caso de una visualización motora.




Figura 2.2 Ejemplo de actividad cerebral ante el efecto ERD y ERS [6].

Hasta este punto se han considerado los conceptos teóricos necesarios para comprender el área de investigación. Sin embargo, existen muchos trabajos que han contribuido al enriquecimiento de esta área, por lo que resulta importante mencionar los proyectos más recientes y cómo contribuyen dentro de la elaboración de la tesis.

2.2 Trabajos realizados

Dentro del amplio panorama que se encuentra hoy en día en referencia al paradigma de control basado en visualizaciones motoras, se han encontrado grandes retos que abarcan todas las etapas del sistema BCI: preprocesamiento, selección y extracción de características, entrenamiento, etapa de control y el tipo de aplicaciones, por lo que en los siguientes párrafos

se presentan trabajos que han contribuido a que este paradigma sea más estable, eficiente y brinde un mejor control al momento de detectar el tipo de visualización motora.

Dichos trabajos fueron categorizados en cuatro áreas: métodos y protocolos para adquisición de señales cerebrales, métodos de extracción de características, algoritmos de clasificación y aplicaciones.

2.2.1 Métodos y protocolos para adquisición de señales cerebrales

Uno de los mayores desafíos que se presenta en la implementación de un sistema BCI que se basa en VM es lograr que la adquisición del EEG corresponda a las señales cerebrales que pertenecen a cada una de las visualizaciones motoras que se busca representar. Es decir, que en el registro de la actividad cerebral realmente se vea reflejada la imaginación del movimiento de una mano, pie o lengua sin la acción motora. En otras palabras, que se estimule el cerebro de forma que sí se presente la visualización motora dentro de la etapa de adquisición de señales porque, en el caso contrario, no se podrá implementar un clasificador y el sistema no funcionará.

Se han creado diversos protocolos para la adquisición de las señales cerebrales, que permitan al usuario realizar la visualización motora de forma eficiente. El paradigma clásico es el entrenamiento de Graz [7] que muestra una cruz central, en una pantalla, y a partir de ella se generan flechas que indican el tipo de visualización motora (por ejemplo, una flecha a la derecha indicará que el usuario debe visualizar el movimiento de la mano derecha). Además, incluye tiempos de preparación para la siguiente visualización motora y tiempos de descanso. Sin embargo, este tipo de paradigma no estimula la imaginación de los sujetos de prueba para realizar las visualizaciones motoras, por lo que surge la necesidad de implementar otros que ayuden a mejorar la capacidad de visualización.

Con el avance tecnológico surge el uso de realidad virtual o VR (del inglés *Virtual Reality*) dentro de la etapa adquisición de señales para el entrenamiento. Por ejemplo, el trabajo presentado por F. Škola y F. Liarakapis en [8] muestra un nuevo paradigma donde el sujeto a prueba se ve inmerso en un ambiente virtual y observa, por medio de lentes VR, un avatar que puede ser controlado por él mismo. Para mostrar más detalladamente el paradigma se muestra

en la figura 2.3 una comparación entre el paradigma de Graz y el propuesto por F. Škola y F. Liarokapis.




Figura 2.3 Comparación entre el paradigma de Graz y su retroalimentación (del lado izquierdo) contra el paradigma propuesto por F. Škola y F. Liarokapis en [8].

Este tipo de entrenamiento se presenta como una nueva alternativa que permita estimular con mayor facilidad la imaginación del sujeto a prueba, utilizando, además, un sistema de visualización y retroalimentación más portable, ya que los lentes VR incluyen por sí mismos una pantalla, como se muestra en la figura 2.4. Así, si se logra una mejor visualización motora se tendrá un mejor entrenamiento, una mejor clasificación y, por lo tanto, un sistema BCI mucho más eficiente.



Figura 2.4 Sistema de entrenamiento con base en VR implementado en [8].

De igual manera, F. Parivash, L. Amuzadeh y A. Fallahi en [9] muestran un sistema embebido con VR para neurorrehabilitación. En dicho sistema se busca que el usuario se vea

inmerso en un mundo virtual (ver figura 2.5), a través del sistema BCI que detecta tres estados: movimiento del puño derecho, movimiento del puño izquierdo y estado de reposo. También en el trabajo presentado por S. Liang *et al.* en [10] se utiliza VR como un paradigma para perfeccionar las visualizaciones motoras. Es decir, se tiene por objetivo diseñar e implementar un modelo eficiente para producir mejor los patrones de ERD a través de un entorno virtual como guía visual sobre la modulación de los ritmos EEG sensoriomotores, lo que permite estimular la visualización motora de los sujetos a prueba.




Figura 2.5 Ambiente virtual para la implementación del sistema embebido con VR para neurorrehabilitación elaborado en [9].

Por otra parte, una vez que se han establecido el protocolo para toma de muestras y el ambiente para generar la visualización motora, se está en condiciones de extraer características que permitan resaltar la información de la señal. Por tal motivo, el siguiente apartado muestra los principales métodos para extraer características de acuerdo con un sistema BCI basado en visualizaciones motoras, donde se exponen también algunos trabajos.

2.2.2 Métodos de extracción de características

El objetivo de la extracción de características es describir las señales cerebrales adquiridas mediante algunos valores importantes o relevantes, llamados “características” o “vector de características” [4]. Además, las características deben marcar diferencias notables para poder tener una mejor clasificación de los patrones.

Existen diferentes métodos para extraer características, como la densidad espectral de potencia [11], por medio del análisis de componentes principales o PCA (del inglés *Principal*

Component Analysis) en [12], con la transformada corta de Fourier [13], transformada Wavelet continua [14] y la Transformada Stockwell [15].

Stockwell *et al.* propusieron en [16] un técnica de representación en tiempo y frecuencia de las señales conocida como transformada ST. Es una extensión de CWT que se basa en la localización móvil y escalable de una ventana gaussiana. A diferencia de CWT, que retiene sólo la información de amplitud de la señal, ST conserva tanto la información de amplitud como la de fase. Además, ofrece una buena localización en frecuencia para bajas frecuencias y una buena localización en tiempo para frecuencias más altas [16]. Dado que la ST supera algunas limitaciones de la transformada corta de Fourier y de la CWT, y el buen desempeño que presenta en [15], se seleccionó como uno de los métodos para extracción de características.

Para representar la transformada ST se parte de la transformada CWT. La CWT $W(\tau, d)$ de una señal $g(t)$, está dada por (2.1).

$$W(\tau, d) = \int_{-\infty}^{\infty} g(t) \omega(t - \tau, d) dt \quad (2.1)$$

donde $\omega(t, d)$ es una réplica escalada de la función wavelet madre fundamental, τ es el tiempo de localización espectral, d es el factor de dilatación y t es el tiempo. El factor de dilatación d es inverso a la frecuencia. De manera que la transformada S de una función $g(t)$ es definida como una CWT con una función wavelet madre específica multiplicada por un factor de fase, como se muestra en (2.2).

$$S(\tau, f) = e^{i2\pi f\tau} W(\tau, d) \quad (2.2)$$

donde se busca que la representación de la función wavelet madre sea Gaussiana y positiva, definida por (2.3)

$$\omega(t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{t^2 f^2}{2}} e^{-i2\pi ft} \quad (2.3)$$

donde f representa la frecuencia de la señal. Sin embargo, la función mostrada en la ecuación anterior no satisface la condición de media cero para que sea una wavelet formalmente, por lo que se representa como en (2.4), que corresponde a la transformada S en el dominio continuo.

$$S(\tau, f) = \int_{-\infty}^{\infty} g(t) \omega(\tau - t, f) e^{-i2\pi ft} dt \quad (2.4)$$

La versión discreta de la ST continua se obtiene partiendo de la Transformada Discreta de Fourier, como se presenta en (2.5). Donde $g(kT)$ es una señal en el dominio discreto del tiempo, desde $k=0, 1, \dots, N$ de la señal $g(t)$ muestreada en el intervalos T de tiempo y $G((m+n)/NT)$ es la señal transformada en el dominio discreto de Fourier.

$$S\left(\frac{n}{NT}, jT\right) = \sum_{m=1}^{N-1} G\left(\frac{m+n}{NT}\right) H(n, m) e^{\frac{i2\pi mj}{N}} \quad (2.5)$$

En la ecuación anterior se presenta la función Gaussiana $H(n, m) = \exp(-2\pi^2 m^2/n^2)$ que va de $j, m, n=0, 1, \dots, N-1$. Este produce una matriz de dimensión $N \times M$ conocida como la matriz ST. Cada renglón representa los componentes de frecuencia y cada columna el componente del tiempo.

Sin embargo, además de utilizar características como CWT y ST, en un sistema BCI en el que se realiza la interpretación de procesos oscilatorios, como en el caso de visualizaciones motoras, también se utiliza información espacial como característica en conjunto con la información espectral.

Para la información espacial se utilizan, comúnmente, los canales F3, F4, Tz, C3, Cz, C4, T8, Pz (aunque puede variar dependiendo de la aplicación o la intención de la investigación) del sistema internacional 10-20 y para la información espectral, generalmente, se utilizan las bandas de frecuencia Mu y Beta.

Con esta información es posible generar un clasificador, sin embargo, al tener una gran cantidad de canales e información, resulta ineficiente. Por lo que se puede implementar un filtrado espacial que reduzca la dimensión de la información. Así, se obtendría un número menor de nuevos canales como combinaciones lineales de los originales, basándose en el

comportamiento de los canales originales ante ciertas visualizaciones. Para que esto sea implementado, se recurre al algoritmo supervisado de *Common Spatial Pattern* [3], el cual encuentra los filtros espaciales Z que maximizan la varianza de la señal filtrada para una clase y la minimiza para la otra. La ecuación (2.1) muestra el resultado de aplicar el filtro espacial Z .

$$x_{CSP}(T) = Z^T x(t) \quad (2.6)$$

El análisis CSP se aplica a señales filtradas por un pasa bandas en el rango de frecuencias de los ritmos Mu y Beta, con el objetivo de obtener una discriminación efectiva de los estados mentales que se caracterizan por los efectos de ERD/ERS. Además, es el método más popular y más aplicado en la etapa de extracción de características de señales EEG para la clasificación de visualizaciones motoras dentro de aplicaciones BCI.

Por ejemplo en [17], T. Nguyen *et al.*, se utiliza CSP para extraer características de un sistema multiclase (visualizaciones de la mano derecha, izquierda, pies y lengua) en conjunto con un clasificador basado en lógica difusa, diseñado a partir del modelo *fuzzy standard additive* y el método *particle swarm optimization* (PSO). Este tipo de modelo, basado en lógica difusa, propone ayudar con la incertidumbre, el ruido y los valores atípicos que se presentan en señales EEG debido a una visualización motora dentro de un sistema BCI.

Se presentan proyectos donde se combina el método CSP con otras herramientas, produciendo diversas variaciones que involucran el espacio, el tiempo y/o la frecuencia. Por ejemplo, en [18] proponen el reconocimiento de visualizaciones motoras a través de la extracción de características mediante CSP y CSPO (del inglés *Chaotic Particle Swarm Optimization*) y un clasificador basado en una modificación a las máquinas de vectores de soporte, llamado TWSVM (del inglés *TWin Support Vector Machine*). Similarmente en [19], donde se utilizó una técnica para extraer características mediante CSP en conjunto con bandas de potencia de las señales para formar el vector de características, se implementó un sistema síncrono que controla un robot de navegación mediante cuatro comandos que permiten girar hacia la izquierda o derecha, detenerse o avanzar; con un desempeño de comandos correctos de casi el 80%, dentro de una simulación.

Sin embargo, la eficiencia del método CSP se ve muy afectada por la banda de frecuencias que se ha de seleccionar y la ventana temporal de los segmentos del EEG [20]. Es por tal motivo que se están implementando nuevos algoritmos que, en lugar de combinar varios métodos, modifican CSP incorporando otras características para aumentar el desempeño del sistema BCI y la clasificación de visualizaciones motoras, como en [20], donde se propone un algoritmo novedoso, llamado *Temporally Constrained Sparse Group Spatial Pattern* (TSGSP), que busca la optimización simultánea de las bandas de filtrado y las ventanas de tiempo del método CSP, aumentando la precisión de clasificación de las visualizaciones motoras. De igual manera, en [21], se expone *Filter bank common spatial pattern* (FBCSP), que permite al sistema elegir automáticamente el rango de frecuencias discriminativas para el sujeto a prueba, lo que hace más eficiente el entrenamiento y la aplicación en sí. Otra modificación es el método llamado *Separable Common Spatio-Spectral Patterns* (SCSSP), presentado en [22] donde se señala que aunque este método asume un problema de clasificación binaria al buscar las características espacio-espectrales cuya varianza es máxima para cierta visualización motora y mínima para la otra, también fue probado en múltiples clases. O el método presentado en [23] llamado “*Combined variable sized subband and temporal filter based stationary common spatial patterns*” o CVSTSCSP. Donde se busca generar una óptima extracción de características con base en información temporal, espectral y espacial obtenida de las visualizaciones motoras.

En resumen, se han hecho modificaciones al método CSP, resultando en TSGSP, FBCSP, SCSSP, CVSTSCSP. Esto con el objetivo de extraer mejor las características que alimentarán al clasificador. En el siguiente apartado se mencionan otros tipos de clasificadores, además de los utilizados en los trabajos previamente mencionados, que resultan interesantes y proponen otras alternativas para generar las clases.

2.2.3 Algoritmos de clasificación.

Los algoritmos de clasificación, conocidos como “clasificadores”, tienen el objetivo de interpretar las intenciones del usuario mediante los vectores de características obtenidos en la etapa de extracción. Cada clase generada corresponderá al tipo de patrón de actividad cerebral identificado [4].

Un buen desempeño de un sistema BCI se define esencialmente por la exactitud de la clasificación, es decir, entre mejor sea el clasificador, mejor será el rendimiento del sistema. Sin embargo, este desempeño se ve afectado por otros factores, como el adecuado preprocesamiento y selección de características, el tiempo de ejecución u otros elementos que afectan el comportamiento del sistema BCI ante alguna aplicación en tiempo real.

Por ejemplo, hay trabajos como en [24], que utilizan una Red Bayesiana Común o CBN (del inglés *Common Bayesian Network*) para analizar múltiples clases de visualizaciones motoras en un sistema BCI o el caso del proyecto realizado en [25], donde utilizan funciones discriminantes lineales o LDA (del inglés *Linear Discriminant Analysis*). También está el proyecto presentado en [12], donde se utilizan diferentes métodos, entre ellos *random forest* y *k-NN*, con el último se logra un desempeño promedio del 94.57% para los sujetos de prueba. En esta misma línea, en [11] se extraen características por medio de la densidad espectral de potencia y se utiliza *k-NN* como clasificador se obtuvo un 90% de desempeño, con un tiempo de 0.0531 segundos. Lo que da paso a futuras aplicaciones en tiempo real.

Otros métodos se enfocan en utilizar aprendizaje automático no supervisado. Es por eso que A. M. Eldeib y S. Member en [26], utilizaron un método no supervisado, aplicado a visualizaciones motoras, donde se ayudaron de la transformada Wavelet para lograr un desempeño del 82.14%. De igual manera, en [27] se compara el desempeño entre un clasificador semisupervisado o reforzado y otro no supervisado, utilizando *Extreme Learning Machine* (ELM) que es un método de aprendizaje cuyos principales beneficios son que los pesos de entrada de la red se asignan aleatoriamente y los pesos de salida se encuentran analíticamente.

Por otra parte, uno de los clasificadores más prometedores y con mayor impacto en los últimos años son las redes CNN [13], [14], [30]–[35]. En la tabla 2.2 se presentan algunos métodos para clasificar VM, en donde se puede observar que la mayoría utilizan redes neuronales convolucionales con otras herramientas para extraer características. Además, se reportan la base de datos y el desempeño obtenido al evaluar la metodología de cada uno de los trabajos.

Tabla 2.2. Algunos trabajos reportados en el estado del arte.

Extracción de características	Clasificador	# VM	Desempeño	Base de datos	Ref.	Año
FFT - WPD	Deep learning scheme based on RBM	2 VM	~ 80%	BCI competition IV data set 2b	[28]	2017
CSP	Discriminante lineal de Fisher	2 VM	67.46±13.17%	Propia (también utilizada en este proyecto)	[29]	2017
STFT	Deep CNN	2 VM	~ 90%	Propia	[13]	2017
CWT	CNN	2 VM	78.93 ± 6.83%	BCI competition IV data set 2b	[14]	2018
Wavelets	CNN	2/4 VM	90% / 0.766	BCI competition II dataset 3 / BCI competition IV dataset 2a	[30]	2018
FFT	CNN	4 VM	~ 70%	BCI competition IV dataset 2a	[31]	2018
Discriminative Filter Bank CSP (DFBCSP)	CNN	4 VM	~ 80%	BCI competition IV dataset 2a	[32]	2018
PSD	Deep CNN	4 VM	87.9%	BCI competition IV dataset 2a	[33]	2018
PSD	4 NN --> CNN	3 VM	62.1 ± 15%	Propia	[34]	2018
Filter-bank common spatial patterns	CNN	4 VM	78.78%	BCI competition IV dataset 2a	[35]	2018

Son muchas las maneras en las que se puede abordar la problemática de clasificación, sin embargo, el tipo de aplicación delimitará o ayudará a seleccionar adecuadamente un algoritmo clasificador y un buen método para extraer características, ya que, si se desea implementar un sistema BCI en una aplicación en concreto, ésta exigirá ciertas condiciones para el procesamiento de la información, por ejemplo, si se busca hacer en tiempo real.

2.2.4 Aplicaciones

Otro de los grandes retos, referentes a la implementación de un sistema BCI basado en visualizaciones motoras, es el de generar aplicaciones que utilicen la información del clasificador, convertida en comandos, para establecer una comunicación entre algún elemento electromecánico o herramientas virtuales de simulación.

Hay aplicaciones que se enfocan en el área de navegación como en [19], donde se implementó un robot de navegación que permite el uso de cuatro comandos para girar a hacia la izquierda o derecha, detenerse o avanzar. También se encuentra el trabajo realizado por H. Wang *et al.* en [36], donde buscan el control de un automóvil virtual. Para conseguir el objetivo diseñaron un sistema BCI que intenta clasificar múltiples patrones visuales: mano derecha, mano izquierda, pies y ambas manos. Esto permite, una vez hecha la clasificación, que se obtengan comandos para girar a la izquierda, a la derecha, acelerar o desacelerar. Para la extracción de características utilizaron CSP, mediante el método “uno contra el resto” (*one*

versus the rest common spatial patterns) y se obtuvo un desempeño promedio del 75%. La figura 2.6 muestra el ambiente virtual donde se implementó el automóvil comandado mediante visualización motora.




Figura 2.6 Ambiente virtual para manejo de automóvil [36].

Una aplicación más, que busca ayudar a personas con discapacidad mediante la implementación de un brazo robótico, es la que se expone en [37] a cargo de R. Bousseta *et al.* El sistema BCI se alimenta de visualizaciones motoras de las manos y los pies, clasificando entre mano derecha, izquierda, ambas manos y pies. Para extraer características se utilizó PCA en combinación con la transformada rápida de Fourier. Además, SVM basado en una función de base radial fue utilizado como clasificador.

Por otra parte, también existen aplicaciones relacionadas a casas inteligentes con BCI basado en VM. Es el caso del trabajo expuesto en [38] a cargo de K. Belwafi *et al.* utilizan CSP para extraer características y la distancia Mahalanobis como clasificador. Además, proponen un sistema embebido que, mediante máquinas de estado, permite el control de ciertos dispositivos en el hogar. En la figura 2.7 se muestra un ejemplo de máquina de estados para el control de dispositivos de acuerdo con la visualización motora detectada.




Figura 2.7 Ejemplo de Máquina de estados presentada en [38].

CAPÍTULO 3.

3. METODOLOGÍAS DE RECONOCIMIENTO PARA 2 VM

En esta sección se proponen metodologías para el reconocimiento de dos visualizaciones motoras en donde se han extraído características mediante CSP, transformada Wavelet, transformada Stockwell y combinaciones entre ellos, y dos clasificadores: SVM y CNN. Para ello, se presentan los elementos en común que poseen las metodologías, las dos bases de datos utilizadas, los métodos para extraer características y finalmente, la implementación de los clasificadores y resultados.

En el capítulo se manejarán los términos ensayo, época y sesión los cuales se definen en el glosario presentado al final del documento.

3.1 Aspectos generales de las metodologías

Para el desarrollo de las metodologías de reconocimiento de visualizaciones motoras se sigue el diagrama de flujo mostrado en la figura 3.1, donde se muestra que el esquema a seguir consta de las siguientes etapas: obtener las señales EEG mediante la base de datos, el preprocesamiento, la extracción de épocas, una técnica para aumento de datos, extracción de características y el clasificador. En las siguientes secciones se profundizará en cada una de estas etapas.

3.2 Bases de datos

Para la evaluación de las metodologías se utilizaron dos bases de datos: *BCI Competition IV dataset 2a* [39] y *EEG datasets for motor imagery brain-computer interface (EEGdataset)* [29].

En el diagrama de la figura 3.1 se define la variable entera p que representa el número de ensayos, y que bajo la metodología utilizada es igual al número de épocas extraídas después del preprocesamiento y difiere entre una base de datos y otra. En el caso de *BCI Competition IV dataset 2a* $p = 144$ y para *EEGdataset* $p = \{100, 120\}$, dependiendo del sujeto de prueba.




Figura 3.1. Metodología utilizada en este proyecto para la clasificación de dos VM.

3.2.1 BCI Competition IV dataset 2a

La base de datos *BCI Competition IV dataset 2a* fue seleccionada ya que es muy utilizada en los trabajos que se reportan en la literatura, lo que servirá como punto de comparación, y cuenta con las siguientes características:

- 4 visualizaciones motoras (mano izquierda, mano derecha, ambos pies y movimiento de la lengua).
- 9 sujetos realizaron una sesión de entrenamiento y una sesión de prueba, denominadas sesión *A1* y *B1*, respectivamente, en este documento.
- 288 ensayos por sesión, 72 ensayos por clase.
- Las señales de EEG de esta base de datos se registraron con 22 electrodos de Ag / AgCl, por lo tanto, $nCh=22$ que representa el número de canales.
- Frecuencia de muestreo $F_s = 250$ Hz.
- Se aplicó un filtro pasa bandas entre 0.5 Hz y 100 Hz.

Todos los sujetos estaban sentados en una silla cómoda frente a monitor de computadora. Al comienzo de cada prueba ($t = 0$ s), aparecía una cruz centrada en la pantalla con fondo negro y

se presentó un breve tono acústico de aviso. Después de 2 s ($t = 2$ s), aparecía una señal en forma de flecha que apuntaba hacia la izquierda, derecha, abajo o arriba (correspondiente a una de las cuatro clases de visualización motora de mano izquierda, mano derecha, pie o lengua) y permanecía en la pantalla durante 1.25s. No se proporcionó ninguna retroalimentación. Se instruyó a los sujetos para que realizaran la visualización motora hasta que la cruz central desapareciera de la pantalla en $t = 6$ s. Después, se les dio un breve descanso mostrando la pantalla con fondo negro. La figura 3.2 muestra el esquema de tiempo del paradigma.




Figura 3.2. Esquema de tiempo del paradigma [39].

3.2.2 EEGdataset

La base de datos *EEGdataset* se extrajo de *EEG datasets for motor imagery brain–computer interface* [29] y fue seleccionada debido a que es una base de datos que incluye un gran número de sujetos de prueba, es de las bases de datos más actuales (del año 2017) y tiene las siguientes características:

- 2 visualizaciones motoras (mano izquierda y mano derecha)
- 52 sujetos de prueba.
- Una sesión con 100 a 120 ensayos por cada clase, denominada sesión A2 en este documento.
- Las señales de EEG de esta base de datos se registraron con 64 electrodos activos de Ag/AgCl, por lo tanto, $nCh=64$.
- Frecuencia de muestreo $F_s = 512$ Hz.
- Datos crudos.

El diagrama de tiempo de la base de datos *EEGdataset* se muestra en la figura 3.3.




Figura 3.3. Esquema de tiempo del paradigma [29].

Cada ensayo comienza por mostrarle al sujeto de prueba una pantalla con una cruz central y una pista ($t=0$) que indicará qué tipo de VM debe realizar, ya sea de la mano izquierda o de la mano derecha. Esta VM se llevará a cabo por 3 segundos ($t=3$) después de los cuales el sujeto observará nuevamente una pantalla con una cruz central por un periodo de 2.1 a 2.8 segundos que corresponden al descanso de acuerdo con el protocolo propuesto en [29]. Al finalizar el descanso, se presentará una nueva pista que indica el inicio de un nuevo ensayo.

3.3 Preprocesamiento

Se define $X_{raw}^{Ch}(n) \in \mathbb{R}^{n \times N}$ como la señal discreta que contiene los N datos crudos del EEG de cada canal Ch , obtenidos a una frecuencia de muestreo F_s , de cada sujeto de cada una de las bases de datos. En el caso de *BCI Competition IV dataset 2a* se utilizaron sólo las señales correspondientes a las VM de la mano derecha y de la mano izquierda, que corresponden a las dos clases de VM a discriminar en esta etapa del desarrollo del proyecto.

La señal $X_{raw}^{Ch}(n)$ se filtró mediante un filtro digital tipo IIR Butterworth pasa-bandas de quinto orden, asignando las frecuencias de corte respectivas para mu y beta, de 8 a 30Hz. Este tipo de filtro permite una respuesta monótona en la banda de paso hasta la frecuencia de corte y no se modifican las magnitudes de los datos crudos. La ecuación en diferencias del filtro IIR Butterworth está dada por

$$X_{filt}^{Ch}(n) = \sum_{i=0}^5 b_i X_{raw}^{Ch}(n-i) - \sum_{i=1}^5 a_i X_{filt}^{Ch}(n-i) \quad (3.1)$$

donde a y b son los coeficientes constantes de la salida y de la entrada, respectivamente, del filtro y $Xfilt^{Ch}(n) \in \mathbb{R}^{n_{Ch} \times N}$ es la señal discreta filtrada que contiene la información de cada EEG de cada canal Ch por sujeto y base de datos.

3.3.1 Extracción de épocas

En esta etapa se realizó la extracción de p épocas por cada clase de VM de cada sesión para reducir dimensiones de datos y extraer información importante de la señal filtrada. Se define una época mediante

$$\begin{aligned} x_{ep}^{Ch}(k) &= Xfilt^{Ch}(q_{ep} + k + inc) \quad ep = 1, 2, \dots, p ; \quad k = 1, 2, \dots, 2Fs \\ x_{ep}^{Ch}(k) &\in \mathbb{R}^{n_{Ch} \times 2Fs \times p} \end{aligned} \quad (3.2)$$

donde k es el índice del dato de la época x_{ep}^{Ch} del canal Ch y q_{ep} hace referencia a la muestra de inicio de la VM de la época ep . De tal manera que se tienen p épocas de dos segundos de muestras ($2Fs$ muestras) de cada canal Ch de cada VM.

En primera instancia la variable inc es 45 (cantidad de muestras que corresponden a 180ms por $Fs=250\text{Hz}$), ya que se busca obtener una época que vaya desde 180ms después de que se inició la visualización motora ($q_{ep} + inc$) hasta 2180ms después ($q_{ep} + 2Fs + inc$). Este intervalo se seleccionó debido a que una visualización motora presenta eventos ERD de una duración de 1500ms a 2000ms [40] con los cuales se tiene la información adecuada para analizar el tipo de visualización.

3.3.2 Aumento de datos

Considerando que se buscará diseñar un esquema de aprendizaje profundo o *deep learning* mediante un clasificador como una red neuronal convolucional, es necesario aumentar la cantidad de información para representar mejor cada una de las clases [33]. Para ello, se propuso hacer un traslape entre ventanas de 80ms en 80ms que involucren la visualización motora, conservando la información más importante con ligeras modificaciones mediante la técnica de *data augmentation* [41]. De manera que en (3.2) inc toma diferentes valores

$$inc = 45 + (20)(l) \quad l = 0, 1, 2, \dots, 9 \quad (3.3)$$

que van desde 45 (180ms) hasta 225 (900ms), al incrementar 20 muestras cada vez (80ms). Esto da como resultado que, en lugar de obtener una época por ensayo, se obtengan 10. La primera será de los 180ms a los 2180ms de la información correspondiente a la VM de dicho ensayo, y la última será de los 900ms a los 2900ms. Esto generará un total de 10p épocas por cada VM.

Estos datos se dividieron en dos partes: 8p épocas de VM, que representan el 80%, se destinaron para la etapa de entrenamiento y el restante 20%, 2p épocas de VM, para la validación.

3.4 Métodos de extracción de características

En esta sección se presentan los 5 métodos utilizados en este trabajo para extraer características que se componen de: CSP, CWT, ST y combinación entre CSP+CWT y CSP+ST. Se explicará en qué consiste cada uno de ellos y posteriormente se presentará la sección de clasificadores, donde se utilizan estas características para distinguir entre VM.

3.4.1 Método 1: *common spatial patterns*

Mediante CSP se busca realizar una transformación lineal que proyecte los datos EEG de múltiples electrodos a un subespacio que consiste en una matriz de proyección de menor dimensión. Esto permite que se combine información de las clases y se elimine información redundante. Para generar los filtros espaciales se definen dos clases de VM: de mano izquierda y de mano derecha

$$C = \{c_{izq}, c_{der}\} \quad (3.4)$$

Después, se obtiene la matriz de covarianza normalizada de cada clase

$$\overline{Cov}_C = \sum_{ep=1}^{8p} \frac{x_{ep} x_{ep}^T}{\text{trace}\{x_{ep} x_{ep}^T\}} \quad (3.5)$$

$$\overline{Cov}_C \in \mathbb{R}^{nCh \times nCh}$$

donde $\text{trace}()$ es una función que suma los elementos de la diagonal de la matriz de entrada, utilizando 8p épocas de cada VM para obtener la covarianza normalizada de cada clase en la etapa de entrenamiento.

En seguida, se calcula la covarianza espacial que permitirá la mejor discriminación entre clases

$$Cov = \overline{Cov}_{der} + \overline{Cov}_{izq} = UDU^T \quad (3.6)$$

donde U es la matriz de vectores propios de Cov y D la matriz diagonal de valores propios de Cov , con sus elementos acomodados en orden descendente. Después, se calcula la matriz de transformación de blanqueamiento

$$P = D^{-1/2}U^T \quad (3.7).$$

Esto permite normalizar los valores propios de la matriz diagonal D a uno, para generar un espacio en el que las varianzas de los datos a los que se les aplique el filtro espacial se encuentren dentro de un intervalo de 0 a 1. Además, si $\overline{Cov}_{der}$ y $\overline{Cov}_{izq}$ se transforman como

$$\begin{aligned} G_{der} &= P\overline{Cov}_{der}P^T \\ G_{izq} &= P\overline{Cov}_{izq}P^T \end{aligned} \quad (3.8)$$

entonces, G_{der} y G_{izq} compartirán vectores propios comunes a través de los valores propios λ_1 y λ_2 correspondientes como en (3.9), cuya suma es igual a uno, la matriz identidad (3.10).

$$\begin{aligned} G_{der} &= U_G \lambda_1 U_G^T \\ G_{izq} &= U_G \lambda_2 U_G^T \end{aligned} \quad (3.9)$$

$$\lambda_1 + \lambda_2 = I \quad (3.10)$$

Como resultado (3.11), los vectores propios con los valores propios más grandes para G_{der} corresponden a los valores propios más pequeños para G_{izq} , y viceversa. De tal manera que se define la matriz de filtro espacial mediante

$$W_{CSP} = U_G^T P, \quad W_{CSP} \in \mathbb{R}^{nCh \times nCh} \quad (3.11)$$

En filtro espacial resultante las filas representan la información combinada que pertenece a ambas clases, de cada uno de los canales utilizados para obtener el EEG, y están acomodadas

de tal forma que la primera fila tiene mayor varianza contra la última. Utilizando la fila 1 y la fila nCh del filtro espacial, se hace la transformación para cada época

$$\mathbf{Z}_{CSP}^{fil}(k) = [\mathbf{W}_{CSP}^{fil}]^T [x_{ep}(k)], \quad \mathbf{Z}_{CSP}^{fil}(k) \in \mathbb{R}^{2 \times 2Fs \times 8p} \quad (3.12)$$

donde fil representa cada fila utilizada en la transformación. Esto permite reducir la dimensión de los datos y concatenar las dos filas con mayor varianza para generar matrices, $\mathbf{Z}_{CSP}^{fil}(k)$.

3.4.2 Método 2: *continuous Wavelet transform*

En este análisis se implementó la transformada Wavelet continua utilizando la wavelet Morlet mostrada en la figura 3.4 y se define en la ecuación (3.13).




Figura 3.4. Wavelet Morlet

Se obtuvo la CWT de los canales C3 y C4 de cada una de las $8p$ épocas

$$\mathbf{Z}_{CWT}^{Ch,Es}(k) = \text{abs}\left(\text{CWT}\{x_{ep}^{Ch}(k)\}\right), \quad Ch = \{C3, C4\} \quad (3.13)$$

donde $\mathbf{Z}_{CWT}^{Ch,Es}(k) \in \mathbb{R}^{Es \times 2Fs \times 8p}$. La transformada utilizada es continua por definición. Sin embargo, dado que se maneja dentro de un sistema de cómputo con operaciones y valores finitos, se muestrean las escalas y se genera un conjunto finito de ellas. Tanto la escala mínima como la máxima de la CWT se determinan automáticamente en función de la dispersión de energía de la wavelet en frecuencia y tiempo, representadas en una escala logarítmica [42]. De manera que Es es el número de escalas de frecuencia resultantes de la transformación, de las cuales se seleccionó la banda de frecuencias aproximada de 7.5 a 28 Hz, que incluyen los ritmos sensoriomotores.

3.4.3 Método 3: *Stockwell transform*

En este tercer análisis se implementó la transformada Stockwell utilizando ventanas gaussianas variables como se describió en la sección 2.2.2 y en la ecuación (2.5). La figura 3.5 muestra un ejemplo de una ventana gaussiana utilizada para generar la transformada Stockwell para señales con frecuencias de 60 Hz.




Figura 3.5. Ejemplo de ventana gaussiana para implementar transformada Stockwell.

Se obtuvo la ST de los canales C3 y C4 de cada una de las épocas

$$\mathbf{Z}_{ST}^{Ch,F}(k) = \text{abs}\left(\text{ST}\left\{x_{ep}^{Ch}(k)\right\}\right), \quad Ch = \{C3, C4\} \quad (3.14)$$

donde $\mathbf{Z}_{ST}^{Ch,F}(k) \in \mathbb{C}^{F \times 2Fs \times 8p}$ y F son las frecuencias (de 1 a F_s Hz) resultantes de la transformación, representadas con una resolución de 1Hz, de las cuales se seleccionó la banda de frecuencias 8 a 28 Hz que incluyen los ritmos sensoriomotores. En comparación con CWT, en este caso se utilizó el rango de frecuencias de 8 a 28 Hz en lugar de 7.5 a 28 Hz, ya que con ST sí se tiene una resolución de 1 Hz cuando con CWT está en función de las escalas resultantes de la transformación.

3.4.4 Método 4: *common spatial patterns + continuous Wavelet transform*

Para realizar este análisis se combinaron dos herramientas para extracción de características: CSP y CWT. Patrones espaciales comunes se utilizó para seleccionar automáticamente las dos filas del filtro W_{CSP} que portan información de ambas clases, de mayor varianza y a las cuales

se les aplicó la CWT, que permite hacer un análisis en tiempo-frecuencia. Por lo cual, se obtuvo la CWT de la matriz generada por CSP

$$\mathbf{Z}_{CSP_CWT}^{fil,Es}(k) = abs\left(CWT\left\{\mathbf{Z}_{CSP}^{fil}(k)\right\}\right) \quad (3.15)$$

donde $\mathbf{Z}_{CSP_CWT}^{fil,Es}(k) \in \mathbb{R}^{Es \times 2Fs \times 8p}$ y es el valor absoluto de la transformación resultante de seleccionar la información combinada de ambas clases a través de los canales elegidos por CSP para mayor varianza y obtener su transformada wavelet.

La teoría señala que una VM de una extremidad, mano derecha, por ejemplo, presentará mayor energía en la parte contralateral de la zona cerebral, los canales izquierdos en este caso; y viceversa para el caso de la otra extremidad.

En la figura 3.6 se muestra la CWT obtenida de la base de datos *EEGdataset* del sujeto 14, los canales fueron seleccionados mediante el método de CSP donde el canal 1 pertenece al lado izquierdo y el canal 2 al lado derecho, en el rango de frecuencias que comprenden los ritmos sensoriomotores (7.5Hz a 30Hz) y dos segundos de muestras. Se observa el comportamiento de la energía presente en la CWT de una VM de la mano izquierda, siendo el segundo canal el que presenta mayor magnitud y constancia en frecuencias indicando una correcta presencia de dicha visualización.




Figura 3.6. Ejemplo de CWT de la VM de la mano izquierda.

De igual manera, en la figura 3.7 se muestra un ejemplo de la CWT de la VM de la mano derecha, comparando los dos canales y presentándose mayor energía en el canal 1, demostrando una correcta presencia de la visualización.




Figura 3.7. Ejemplo de CWT de la VM de la mano derecha.

3.4.5 Método 5: *common spatial patterns + Stockwell transform*

De manera similar al análisis anterior (CSP+CWT), en esta ocasión se utilizó CSP para la selección de los canales con mayor varianza y con las señales obtenidas se calculó la ST como herramienta de análisis y selección de características en el espacio tiempo-frecuencia

$$\mathbf{Z}_{CSP_ST}^{fil,F}(k) = abs\left(ST\left\{\mathbf{Z}_{CSP}^{fil}(k)\right\}\right) \quad (3.16)$$

donde $\mathbf{Z}_{CSP_ST}^{fil,F}(k) \in \mathbb{R}^{F \times 2Fs \times 8p}$ y es el valor absoluto de la transformación resultante de seleccionar la información combinada de ambas clases a través de los canales elegidos por CSP para mayor varianza, y obtener su transformada wavelet.

En la figura 3.8 se muestra la VM de la mano izquierda obtenida del sujeto 14, de la misma época presentada en la figura 3.6, sólo que en esta ocasión se utilizó la transformada Stockwell.




Figura 3.8. Ejemplo de ST de la VM de la mano izquierda.

En la figura 3.9 se muestra la VM de la mano derecha obtenida del sujeto 14, de la misma época presentada en la figura 3.7, sólo que en esta ocasión se utilizó la transformada Stockwell.




Figura 3.9. Ejemplo de ST de la VM de la mano derecha.

La transformada CSP+ST es el último método utilizado para la extracción de características que da paso a la sección de clasificadores, donde se presentan resultados y comparaciones con desempeños del estado del arte.

3.5 Clasificadores

En esta sección se analizan dos algoritmos para clasificar las visualizaciones motoras, el primero basado en SVM y el segundo en redes neuronales convolucionales.

3.5.1 Clasificador 1: *support vector machine*

Las máquinas de vectores de soporte o SVM permiten encontrar un hiperplano de discriminación o clasificación al maximizar los márgenes entre dos clases para identificarlas o etiquetarlas. El hiperplano que se genera se puede representar mediante

$$G(\Gamma) = W_{SVM}^T \Gamma + W_{0_SVM} \quad (3.17)$$

donde W_{SVM} es llamado el vector de pesos, Γ son los datos de entrada y W_{0_SVM} es un escalar que permite ajustar el *off-set* del hiperplano. Los datos de entrenamiento más cercanos al hiperplano se denominan vectores de soporte, de tal manera que el objetivo de SVM es encontrar el hiperplano óptimo. El problema de optimización viene dado por

$$\min L(W_{SVM}, \xi) = \frac{1}{2} \|W_{SVM}\|^2 + \sum_{i=1}^n \iota_i \xi_i \quad w \in W_{SVM}, \quad \iota \geq 0 \quad (3.18)$$

tal que $\Upsilon_i [W_{SVM}^T \Gamma_i + W_{0_SVM}] \geq 1 - \xi_i$ para $\xi_i \geq 0$, $i = (1, \dots, n)$. Donde $\Upsilon \in \{+1, -1\}$ denota la etiqueta de la clase, ξ es una variable tipo *slack* que permite que la restricción de desigualdad

sea transformada en una igualdad y l es el factor de Lagrange. Para todas las metodologías implementadas se utilizó un *kernel* de base radial

$$\Phi(y_j, y_k) = \exp\left(-\|y_j - y_k\|^2\right) \quad y_j, y_k \in \Gamma \quad (3.19)$$

donde y_j, y_k son vectores n dimensionales que representan las observaciones j y k en Γ . Lo que modifica la representación de la ecuación (3.17)

$$G(\Phi) = W_{SVM}^T \Phi + W_{0_SVM} \quad (3.20)$$

De manera que sustituyendo (3.19) en (3.20) se obtiene la función para clasificar mediante SVM y el *kernel* de base radial

$$G(\Gamma) = W_{SVM}^T \exp\left(-\|y_j - y_k\|^2\right) + W_{0_SVM} \quad (3.21)$$

En (3.21) se observa que se utilizan solo dos características. Este modelo se propuso y probó experimentalmente debido a que se trató de generar un clasificador sencillo que no exigiera alto tiempo de procesamiento, pensando en la aplicación BCI en tiempo real.

En los siguientes puntos se presenta la metodología específica de extracción de características para el clasificador SVM, utilizando cada una de las herramientas: CSP, CWT, ST, CSP+CWT, CSP+ST. Una vez que se extrae la información, se utiliza SVM para evaluar la discriminación entre VM de la mano derecha y VM de la mano izquierda.

- *CSP+SVM*

Para utilizar el método CSP para extraer características y SVM para clasificar, se calcula el logaritmo de la varianza, lo que permite que la variación en valores grandes pueda reducirse para obtener una distribución gaussiana [43], de cada fila fil de $Z_{CSP}^{fil}(k)$ para cada una de las épocas

$$\begin{aligned} y_{CSP}^1 &= \log\left\{\text{var}\left[Z_{CSP}^1\right]\right\}_1^{8p} \\ y_{CSP}^2 &= \log\left\{\text{var}\left[Z_{CSP}^2\right]\right\}_1^{8p} \end{aligned} \quad (3.22)$$

donde y_{CSP}^1 y y_{CSP}^2 representan las dos características que se extraen por cada una de las 8p VM, es decir, $\Gamma_{CSP}^{fil} = (y_{CSP}^1, y_{CSP}^2)$, $\Gamma_{CSP}^{fil} \in \mathbb{R}^{2 \times 8p}$ que son los vectores de características de entrada para el clasificador basado en SVM.

- *CWT+SVM*

Para extraer características mediante el método CWT, se propone utilizar el promedio de los logaritmos naturales de la suma de los valores absolutos de $Z_{CWT}^{Ch,Es}(k)$ para cada canal

$$\begin{aligned} y_{CWT}^{C3} &= \frac{1}{Es} \ln \sum_{Es} \left\| Z_{CWT}^{C3,Es} \right\|_1^{8p} \\ y_{CWT}^{C4} &= \frac{1}{Es} \ln \sum_{Es} \left\| Z_{CWT}^{C4,Es} \right\|_1^{8p} \end{aligned} \quad (3.23)$$

donde y_{CWT}^{C3} y y_{CWT}^{C4} representan las dos características que se extraen por cada VM, es decir, $\Gamma_{CWT}^{Ch} = (y_{CWT}^{C3}, y_{CWT}^{C4})$, $\Gamma_{CWT}^{Ch} \in \mathbb{R}^{2 \times 8p}$ son los vectores de características de entrada para el clasificador basado en SVM. En este caso y en los siguientes métodos se utilizó logaritmo natural en lugar de logaritmo base 10 ya que experimentalmente se observó mayor discriminación entre la dispersión de los datos, debido a que al utilizar logaritmo base 10 las diferencias entre las características son menores que cuando se utilizó logaritmo natural, lo que benefició en el desempeño del clasificador en estos casos.

- *ST+SVM*

Para utilizar el método ST se obtiene el promedio de los logaritmos naturales de la suma de los valores absolutos de $Z_{ST}^{Ch,F}(k)$, para cada canal

$$\begin{aligned} y_{ST}^{C3} &= \frac{1}{F} \ln \sum_F \left\| Z_{CWT}^{C3,F} \right\|_1^{8p} \\ y_{ST}^{C4} &= \frac{1}{F} \ln \sum_F \left\| Z_{CWT}^{C4,F} \right\|_1^{8p} \end{aligned} \quad (3.24)$$

donde y_{ST}^{C3} y y_{ST}^{C4} representan las dos características que se extraen por cada visualización motora, es decir, $\Gamma_{ST}^{Ch} = (y_{ST}^{C3}, y_{ST}^{C4})$, $\Gamma_{ST}^{Ch} \in \mathbb{R}^{2 \times 8p}$ que son los vectores de características de entrada para el clasificador basado en SVM.

- *CSP+CWT+SVM*

En el caso del método CSP+CWT se obtiene el promedio de los logaritmos naturales de la suma de los valores absolutos de $Z_{CSP_CWT}^{fil,Es}(k)$, para cada fila

$$\begin{aligned} y_{CSP_CWT}^1 &= \frac{1}{Es} \ln \sum_{Es} \left| Z_{CSP_CWT}^{1,Es} \right|_1^{8p} \\ y_{CSP_CWT}^2 &= \frac{1}{Es} \ln \sum_{Es} \left| Z_{CSP_CWT}^{2,Es} \right|_1^{8p} \end{aligned} \quad (3.25)$$

donde $y_{CSP_CWT}^1$ y $y_{CSP_CWT}^2$ representan las dos características que se extraen por cada visualización motora, es decir, $\Gamma_{CSP_CWT}^{fil} = (y_{CSP_CWT}^1, y_{CSP_CWT}^2)$, $\Gamma_{CSP_CWT}^{fil} \in \mathbb{R}^{2 \times 8p}$ que son los vectores de características de entrada para el clasificador basado en SVM.

- *CSP+ST+SVM*

En el último método CSP+ST para extraer características se obtiene el promedio de los logaritmos naturales de la suma de los valores absolutos de $Z_{CSP_ST}^{fil,F}(k)$, para cada fila

$$\begin{aligned} y_{CSP_ST}^1 &= \frac{1}{F} \ln \sum_F \left| Z_{CSP_ST}^{1,F} \right|_1^{8p} \\ y_{CSP_ST}^2 &= \frac{1}{F} \ln \sum_F \left| Z_{CSP_ST}^{2,F} \right|_1^{8p} \end{aligned} \quad (3.26)$$

donde $y_{CSP_ST}^1$ y $y_{CSP_ST}^2$ representan las dos características que se extraen por cada visualización motora, es decir, $\Gamma_{CSP_ST}^{fil} = (y_{CSP_ST}^1, y_{CSP_ST}^2)$, $\Gamma_{CSP_ST}^{fil} \in \mathbb{R}^{2 \times 8p}$ que son los vectores de características de entrada para el clasificador basado en SVM.

Hasta este punto termina la metodología que utiliza las herramientas de patrones espaciales comunes y transformaciones en tiempo-frecuencia para extraer características y el clasificador SVM, lo que da paso a detallar el segundo clasificador: CNN.

3.5.2 Clasificador 2: *convolutional neural network*

En esta sección se abordará el segundo tipo de clasificador que está basado en redes neuronales convolucionales o CNN. Para ello se utilizarán las mismas metodologías generales para extracción de características abordadas en la sección 3.1, pero en este caso se les aplica un procesamiento o tratamiento adicional para acondicionar la información que será la entrada de la CNN.

- *CSP+CNN*

Como la arquitectura del clasificador fue tomada de un modelo previo [33], se redimensiona la matriz $Z_{CSP}^{fil}(k)$ mediante el método de interpolación bicúbica, en que el valor de píxel de salida es un promedio ponderado de píxeles en el vecindario de 4 por 4 más cercano [44]. En este documento, para el caso de la matriz resultante del método CSP, se define el operador de interpolación bicúbica

$$\text{INT}[Z_{CSP}] \rightarrow I_{CSP} \in \mathbb{R}^{22 \times 100} \quad (3.27)$$

donde I_{CSP} es la imagen de entrada a la CNN, con información procedente del método CSP, resultando en una matriz de 22x100.

- *CWT+CNN*

En el caso del método 2 es necesario concatenar las matrices resultantes de la CWT de cada canal {C3, C4}

$$\mathbf{Q}_{CWT}(i, k) = \begin{cases} \mathbf{Z}_{CWT}^{C4, (i-Es)}(k) & i > Es \\ \mathbf{Z}_{CWT}^{C3, i}(k) & i \leq Es \end{cases} \quad \mathbf{Q}_{CWT} \in \mathbb{R}^{2Es \times 2Fs \times 8p} \quad (3.28)$$

$$i = 1, 2, \dots, 2Es$$

donde cada i -ésima fila de la CWT corresponde a una escala Es de frecuencia de cada una de las matrices $\mathbf{Z}_{CWT}^{Ch, Es}$ de cada época k y de cada canal Ch .

Sin embargo, también es necesario utilizar la herramienta de interpolación bicúbica para cambiar la dimensión de la matriz que es la imagen de entrada a la CNN

$$\text{INT}[\mathbf{Q}_{\text{CWT}}] \rightarrow I_{\text{CWT}} \in \mathbb{R}^{22 \times 100} \quad (3.29)$$

donde I_{CWT} es la imagen de entrada a la CNN, con información procedente del método CWT, resultando en una matriz de 22x100.

- *ST+CNN*

De manera similar al caso anterior, es necesario concatenar las matrices resultantes de la ST de cada canal {C3, C4}

$$\mathbf{Q}_{\text{ST}}(i, k) = \begin{cases} \mathbf{Z}_{\text{ST}}^{C4, (i-F)}(k) & i > F \\ \mathbf{Z}_{\text{ST}}^{C3, i}(k) & i \leq F \end{cases} \quad \mathbf{Q}_{\text{ST}} \in \mathbb{R}^{2F \times 2Fs \times 8p} \quad (3.30)$$

$$i = 1, 2, \dots, 2F$$

donde cada i -ésima fila de la ST corresponde a una frecuencia F de cada una de las matrices $\mathbf{Z}_{\text{ST}}^{Ch, F}$ de cada época k y de cada canal Ch .

Sin embargo, también es necesario utilizar la herramienta de interpolación bicúbica para reducir la dimensión de la matriz que es la imagen de entrada a la CNN

$$\text{INT}[\mathbf{Q}_{\text{ST}}] \rightarrow I_{\text{ST}} \in \mathbb{R}^{22 \times 100} \quad (3.31)$$

donde I_{ST} es la imagen de entrada a la CNN, con información procedente del método ST, resultando en una matriz de 22x100.

- *CSP+CWT+CNN*

Al utilizar el método 4 para extracción de características, es necesario concatenar las matrices resultantes de la CWT de cada canal fila, obtenidas de CSP

$$\mathbf{Q}_{\text{CSP_CWT}}(i, k) = \begin{cases} \mathbf{Z}_{\text{CSP_CWT}}^{2, (i-Es)}(k) & i > Es \\ \mathbf{Z}_{\text{CSP_CWT}}^{1, i}(k) & i \leq Es \end{cases} \quad \mathbf{Q}_{\text{CSP_CWT}} \in \mathbb{R}^{2Es \times 2Fs \times 8p} \quad (3.32)$$

$$i = 1, 2, \dots, 2Es$$

De igual manera que en los casos anteriores, también es necesario utilizar la herramienta de interpolación bicúbica para reducir la dimensión de la matriz que es la imagen de entrada a la CNN

$$\text{INT}[\mathbf{Q}_{\text{CSP_CWT}}] \rightarrow I_{\text{CSP_CWT}} \in \mathbb{R}^{22 \times 100} \quad (3.33)$$

donde $I_{\text{CSP_CWT}}$ es la imagen de entrada a la CNN, con información procedente del método CSP+CWT, resultando en una matriz de 22x100.

Para ejemplificar las imágenes de entrada a la red CNN se muestra la figura 3.10, donde se concatenaron las CWT de las VM de la mano izquierda presentadas en la figura 3.6 y aplicando interpolación bicúbica para generar la imagen de 22x100 píxeles.




Figura 3.10. Imagen de entrada a la CNN utilizando CWT de una VM de la mano izquierda.

En la figura 3.11 se muestra la matriz de entrada a la CNN, después de concatenar y redimensionar las matrices mostradas en la figura 3.7.




Figura 3.11. Imagen de entrada a la CNN utilizando CWT de una VM de la mano derecha.

- $CSP+ST+CNN$

El último método es similar al anterior, donde se parte de la información generada en la extracción de características y se concatenan las matrices resultantes de la CWT de cada canal fila, obtenidas de CSP

$$\mathbf{Q}_{CSP_ST}(i, k) = \begin{cases} \mathbf{Z}_{CSP_ST}^{2, (i-F)}(k) & i > F \\ \mathbf{Z}_{CSP_ST}^{1, i}(k) & i \leq F \end{cases} \quad \mathbf{Q}_{CSP_ST} \in \mathbb{R}^{2F \times 2Fs \times 8p} \quad (3.34)$$

$$i = 1, 2, \dots, 2F$$

También es necesario utilizar la herramienta de interpolación bicúbica para reducir la dimensión de la matriz que es la imagen de entrada a la CNN

$$\text{INT}[\mathbf{Q}_{CSP_ST}] \rightarrow I_{CSP_ST} \in \mathbb{R}^{22 \times 100} \quad (3.35)$$

donde I_{CSP_ST} es la imagen de entrada a la CNN, con información procedente del método CSP+ST, resultando en una matriz de 22x100.

En la figura 3.12 se muestra la imagen de entrada a la red CNN después de concatenar las matrices de la figura 3.8 e implementar el algoritmo de interpolación bicúbica.




Figura 3.12. Imagen de entrada a la CNN utilizando ST de una VM de la mano izquierda.

Finalmente, en la figura 3.13 se presenta la imagen con las matrices de la figura 3.9 concatenadas y la interpolación bicúbica.

Una vez que se tienen las imágenes de entrada, se procedió al diseño de la arquitectura de la red CNN para clasificar dos VM.




Figura 3.13. Imagen de entrada a la CNN utilizando ST de una VM de la mano derecha.

El diseño de la red neuronal convolucional se basó en la arquitectura presentada en [33] donde se utilizaron datos que fueron preprocesados y a los cuales se les calculó la densidad espectral de energía o PSD (del inglés *Power Spectral Density*) y la transformada Welch para alimentar una CNN que permitiera la clasificación de 4 visualizaciones motoras de la base de datos *BCI Competition IV dataset 2a* [39]. La arquitectura de la CNN utilizada en [33] se presenta en la figura 3.14.




Figura 3.14. Arquitectura de la red neuronal convolucional utilizada en [33].

En [33] se menciona que se utilizaron 9 filtros convolucionales justificando que encontraron que la falta de capas de convolución puede dar lugar a un bajo rendimiento de clasificación. También se menciona que se utilizó una capa de *dropout* hasta el final de las capas convolucionales y que las últimas 5 sólo extraen características mediante filtros de convolución sin hacer agrupamientos o submuestreo.

Sin embargo, en este proyecto de tesis se propone utilizar una arquitectura que elimina las últimas 5 capas e implementa una capa de *dropout* después de las primeras dos capas convolucionales, que permite que la CNN generalice y no memorice [45]. Además, se propuso reducir el número de capas y aumentar el número de filtros por cada capa convolucional. Esto se realizó debido a que entre más capas ocultas posea una CNN, las características obtenidas serán más específicas [46], por ejemplo, en clasificación de imágenes para discriminar entre rostros humanos, texturas o animales. En este caso se trata de imágenes que provienen de una matriz tiempo-frecuencia, por lo que se espera obtener mejores resultados si es mayor en número de características (más filtros convolucionales) pero sin ser tan detalladas (menos capas ocultas), ya que se perdería la información de la magnitud en las bandas de frecuencia de los ritmos sensoriomotores al ser demasiado específicos, lo que da como resultado la arquitectura de la CNN mostrada en la figura 3.15.




Figura 3.15. Arquitectura de la red CNN para dos visualizaciones motoras.

Todas las capas convolucionales están compuestas por 128 filtros convolucionales de dimensión 3x3. Después de cada capa de convolución, se implementó un agrupamiento tipo *max-pooling* con regiones de 2x2 y tamaño del paso (*stride*) de 1, así como una función de activación tipo ReLU (del inglés *Rectified Linear Unit*). De manera similar que en [33], los pesos se inicializaron mediante el *kernel inicializador uniforme Glorot*. Al final de las capas convolucionales se utilizó una capa *totalmente conectada* o *fully-connected* y una función exponencial normalizada *softmax* para la clasificación de dos visualizaciones motoras: mano izquierda y mano derecha. Para el entrenamiento de la CNN, se utilizó el algoritmo de optimización *Adaptive Moment Estimation* (Adam) que está basado en estimaciones adaptativas de momentos de orden inferior debido a su eficiencia computacional y capacidad para trabajar

con elementos no estacionarios [47]. La tasa de aprendizaje inicial se ajustó a 0.0005 y se utilizaron 60 épocas para el entrenamiento de cada sujeto, parámetros obtenidos experimentalmente como parte del ajuste al mejor modelo de red.

Una vez seleccionados los métodos para extraer características y configurados los hiperparámetros de la CNN y su arquitectura, se procedió a la implementación.

Para analizar el funcionamiento de la red se hace una propagación “hacia adelante” o *feedforward*. A la entrada de la CNN se tiene una imagen que se generalizará mediante

$$I_{method} \in \mathbb{R}^{22 \times 100 \times 1} \quad (3.36)$$

donde $method = \{CSP, CWT, ST, CSP_CWT, CSP_ST\}$ representando cada uno de los métodos utilizados en este proyecto para extracción de características. Esta imagen entra a una primera capa de convolución

$$\begin{aligned} CONV1_{i,j}^{nFiltro} &= I_{method} * Fil_1 + \beta_1 \\ CONV1_{i,j}^{nFiltro} &= \sum_{i=1}^{20} \sum_{j=1}^{98} \sum_{x=1}^3 \sum_{y=1}^3 I_{method}(i+x-1, j+y-1) Fil_1^{nFiltro}(x, y) + \beta_1 \\ nFiltro &= 1, 2, \dots, 128 \end{aligned} \quad (3.37)$$

donde $Fil_1^{nFiltro} \in \mathbb{R}^{3 \times 3 \times 1 \times 128}$ son los filtros de convolución de la primera capa, β_1 es el *bias* y el tamaño de salida de cada mapa de características de esta capa de convolución se obtiene mediante

$$\begin{aligned} L_{CONV1} &= \frac{L_{I_{method}} + 2L_{padding} - L_{F_1}}{L_{Stride}} + [1 \quad 1] \\ L_{CONV1} &= \frac{[22 \quad 100] + 2[0 \quad 0] - [3 \quad 3]}{[1 \quad 1]} + [1 \quad 1] \\ L_{CONV1} &= [20 \quad 98] \end{aligned} \quad (3.38)$$

De manera que

$$CONV1_{i,j}^{nFiltro} \in \mathbb{R}^{20 \times 98 \times 128} \quad (3.39)$$

Después, se aplica un agrupamiento tipo max-pooling de 2x2

$$M1_{i,j}^{nFiltro} = \max \left[CONV1_{i,j}^{nFiltro}, CONV1_{i+1,j}^{nFiltro}, CONV1_{i,j+1}^{nFiltro}, CONV1_{i+1,j+1}^{nFiltro} \right] \quad (3.40)$$

$$i = 1, 2, \dots, 19; \quad j = 1, 2, \dots, 97$$

resultando un mapa

$$M1_{i,j}^{nFiltro} \in \mathbb{R}^{19 \times 97 \times 128} \quad (3.41)$$

el cual se evalúa mediante la función ReLU de activación

$$M1_{i,j}^{nFiltro} = \max(0, M1_{i,j}^{nFiltro}) = 0.5(M1_{i,j}^{nFiltro} + |M1_{i,j}^{nFiltro}|) \quad (3.42)$$

donde $||$ representa el valor absoluto, dejando sólo valores reales positivos, que corresponden a la entrada de la segunda capa de convolución

$$CONV2_{i,j}^{nFiltro} = M1 * Fil_2 + \beta_2 \quad (3.43)$$

$$CONV2_{i,j}^{nFiltro} = \sum_{deep=1}^{128} \sum_{i=1}^{17} \sum_{j=1}^{95} \sum_{x=1}^3 \sum_{y=1}^3 M1_{i,j}^{deep} (i+x-1, j+y-1) Fil_2^{deep, nFiltro}(x, y) + \beta_2$$

donde $Fil_2^{deep, nFiltro} \in \mathbb{R}^{3 \times 3 \times 128 \times 128}$ son los filtros de convolución de la segunda capa y el tamaño de salida de cada mapa de características de esta capa de convolución se obtiene mediante

$$L_{CONV2} = \frac{L_{M1} + 2L_{Padding} - L_{F_2}}{L_{Stride}} + [1 \ 1]$$

$$L_{CONV2} = \frac{[19 \ 97] + 2[0 \ 0] - [3 \ 3]}{[1 \ 1]} + [1 \ 1] \quad (3.44)$$

$$L_{CONV2} = [17 \ 95]$$

De manera que

$$CONV2_{i,j}^{nFiltro} \in \mathbb{R}^{17 \times 95 \times 128} \quad (3.45)$$

Después, se aplica un agrupamiento tipo *max-pooling* de 2x2

$$M2_{i,j}^{nFiltro} = \max \left[CONV2_{i,j}^{nFiltro}, CONV2_{i+1,j}^{nFiltro}, CONV2_{i,j+1}^{nFiltro}, CONV2_{i+1,j+1}^{nFiltro} \right] \\ i = 1, 2, \dots, 16; \quad j = 1, 2, \dots, 94 \quad (3.46)$$

Resultando un mapa

$$M2_{i,j}^{nFiltro} \in \mathbb{R}^{16 \times 94 \times 128} \quad (3.47)$$

El cual se evalúa mediante la función ReLU de activación

$$M2_{i,j}^{nFiltro} = \max(0, M2_{i,j}^{nFiltro}) = 0.5(M2_{i,j}^{nFiltro} + |M2_{i,j}^{nFiltro}|) \quad (3.48)$$

La salida de esta función de activación está conectada a una capa que implementa la función de *dropout*, que ayuda a prevenir el sobre-entrenamiento y proporciona una manera de combinar aproximadamente arquitecturas de redes neuronales diferentes de manera eficiente [45]. De manera que se recurre a [45] para definir la capa de *dropout*

$$r^{nFiltro} \sim \text{Bernoulli}(\rho) \\ M2^{nFiltro} = \frac{1}{1-\rho} r^{nFiltro} \otimes M2^{nFiltro} \quad (3.49)$$

donde $r^{nFiltro}$ es un vector de variables aleatorias independientes de Bernoulli, donde cada una toman valor 1 para la probabilidad de éxito (ρ) y valor cero para la probabilidad de fracaso ($1-\rho$). Este vector, escalado por $1/(1-\rho)$, se recorre y multiplica elemento a elemento, expresado mediante $\otimes$, con $M2^{nFiltro}$ al ser la entrada a esta capa para generar una salida “adelgazada” o “disminuida”.

Para definir el valor de ρ se realizaron pruebas que consistieron en variar su rango de 0 a 1 y dejar constantes los demás hiperparámetros y la misma arquitectura de red CNN, esto con el fin de alcanzar el desempeño de clasificación más alto. Se encontró que con $\rho = 0.93$ se obtenían los mejores resultados. Además, es importante señalar que esta capa sólo es considerada en la etapa de entrenamiento de la red CNN, por lo que en la etapa de predicción la salida de esta capa es igual a su entrada.

A la salida de la capa de *dropout* se tiene la tercera capa de convolución

$$\begin{aligned}
 CONV3_{i,j}^{nFiltro} &= M2 * Fil_3 + \beta_3 \\
 CONV3_{i,j}^{nFiltro} &= \sum_{deep=1}^{128} \sum_{i=1}^{14} \sum_{j=1}^{92} \sum_{x=1}^3 \sum_{y=1}^3 M2_{i,j}^{deep} (i+x-1, j+y-1) Fil_3^{deep, nFiltro}(x, y) + \beta_3
 \end{aligned} \tag{3.50}$$

donde $Fil_3^{deep, nFiltro} \in \mathbb{R}^{3 \times 3 \times 128 \times 128}$ son los filtros de convolución de la tercera capa y el tamaño de salida de cada mapa de características de esta capa de convolución se obtiene mediante

$$\begin{aligned}
 L_{CONV3} &= \frac{L_{M2} + 2L_{Padding} - L_{F3}}{L_{Stride}} + [1 \quad 1] \\
 L_{CONV3} &= \frac{[16 \quad 94] + 2[0 \quad 0] - [3 \quad 3]}{[1 \quad 1]} + [1 \quad 1] \\
 L_{CONV3} &= [14 \quad 92]
 \end{aligned} \tag{3.51}$$

De manera que

$$CONV3_{i,j}^{nFiltro} \in \mathbb{R}^{14 \times 92 \times 128} \tag{3.52}$$

Después, se aplica un agrupamiento tipo *max-pooling* de 2x2

$$\begin{aligned}
 M3_{i,j}^{nFiltro} &= \max [CONV3_{i,j}^{nFiltro}, CONV3_{i+1,j}^{nFiltro}, CONV3_{i,j+1}^{nFiltro}, CONV3_{i+1,j+1}^{nFiltro}] \\
 i &= 1, 2, \dots, 13; \quad j = 1, 2, \dots, 91
 \end{aligned} \tag{3.53}$$

Resultando un mapa

$$M3_{i,j}^{nFiltro} \in \mathbb{R}^{13 \times 91 \times 128} \tag{3.54}$$

El cual se evalúa mediante la función ReLU de activación

$$M3_{i,j}^{nFiltro} = \max(0, M3_{i,j}^{nFiltro}) = 0.5(M3_{i,j}^{nFiltro} + |M3_{i,j}^{nFiltro}|) \tag{3.55}$$

Con esto terminan las capas de convolución, agrupamiento y funciones ReLU de activación, dando paso a la capa “totalmente conectada” o *fully-connected* definida para dos clases C de VM

$$FC^{C, nFiltro}(i, j) = M3_{i,j}^{nFiltro} * Fil_4^{C, nFiltro}(i, j) + \beta_4^C \tag{3.56}$$

donde $Fil_4^{C,nFiltro}(i, j) \in \mathbb{R}^{2 \times 13 \times 91 \times 128}$ representa los pesos de la capa totalmente conectada para cada clase. De manera que para generar la entrada a la función *softmax* para la etapa de clasificación, se define

$$a^C = \sum_{nFiltro=1}^{128} \sum_{i=1}^{13} \sum_{j=1}^{19} FC_{i,j}^{C,nFiltro} \quad (3.57)$$

La función exponencial normalizada o *softmax* está dada por

$$SM^C = \frac{\exp(a^C)}{\sum_{clase=1}^{nClases} \exp(a^{clase})} = \frac{\exp(a^C)}{\exp(a^{c_{izq}}) + \exp(a^{c_{der}})} \quad (3.58)$$

donde $nClases$ es el número de clases que se busca reconocer y como

$$\sum_{clase=1}^{nClases} SM^{clase} = SM^{c_{izq}} + SM^{c_{der}} = 1 \quad (3.59)$$

para asignar a qué clase de VM se asocia la imagen de entrada, se tiene

$$output = \begin{cases} c_{der} & \text{si } SM^{c_{der}} \geq Th \\ c_{izq} & \text{de otra manera} \end{cases} \quad (3.60)$$

En este caso se asignó $Th=0.5$ ya que se observó una buena discriminación entre las clases VM de la mano derecha y VM de la mano izquierda al considerar la salida de la función SM . Sin embargo, en la metodología presentada en el capítulo 4 para discriminar entre 4 VM sí se hicieron modificaciones para determinar la case ganadora.

Este procedimiento, desde la ecuación (3.36) hasta la (3.60) se implementa para cada una de las épocas, teniendo un total de $8p$ imágenes de entrenamiento y $2p$ imágenes de validación.

Para finalizar esta sección, se presenta la tabla 3.1 con los valores de los hiperparámetros y características utilizadas durante el entrenamiento de la red CNN propuesta, obtenidos experimentalmente.

Tabla 3.1. Hiperparámetros utilizados durante el entrenamiento de la CNN

Hiperparámetro	Valor
<i>Solver for training network</i>	ADAM
<i>Gradient Decay Factor</i>	0.1900
<i>Squared Gradient Decay Factor</i>	0.9000
<i>Epsilon</i>	1.0e-8
<i>Initial Learn Rate</i>	5.0e-4
<i>L₂ regularization</i>	1.0e-4
<i>Learn Rate Drop Factor</i>	0.99
<i>Learn Rate Drop Period</i>	3
<i>Learn Rate Schedule</i>	Piecewise
<i>Max Epochs</i>	60
<i>Mini Batch Size</i>	128
<i>Shuffle</i>	Once
<i>Execution environment</i>	GPU

3.6 Resultados

En esta sección se presentan los resultados obtenidos de cada uno de los métodos, las gráficas de evaluación y algunas matrices de confusión para la validación de la metodología utilizada.

Para la evaluación de los desempeños se comparan los *Ground Truth* generados contra la salida de la red CNN

$$SS_{ep} = \begin{cases} 1 & \text{iff } GT_{ep} = output_{ep} \\ 0 & \text{iff } GT_{ep} \neq output_{ep} \end{cases} \quad (3.61)$$

donde SS_{ep} es una variable binaria que toma el valor 1 cuando sí se clasificó correctamente, es decir, que el *Ground Truth* GT_{ep} es igual a la salida $output_{ep}$ que arrojó la CNN para la época ep ; y SS_{ep} toma valor 0 cuando fue una clasificación incorrecta.

Después, se calcula el promedio de muestras clasificadas correctamente para obtener desempeños de entrenamiento y de validación

$$dE = \frac{100}{8p} \sum_{k=1}^{8p} SS_{ep} \quad dV = \frac{100}{2p} \sum_{k=8p+1}^{10p} SS_{ep} \quad (3.62)$$

A continuación, se presentan los desempeños obtenidos para cada una de las bases de datos utilizadas en este proyecto.

3.6.1 Desempeños de la base de datos *BCI Competition IV dataset 2a*

La tabla 3.2 muestra los desempeños obtenidos en la etapa de entrenamiento y de validación con los diferentes métodos para extraer características (se designa CSP₂ para indicar el uso de 2 filas de la matriz de proyección al implementar este método) y SVM como clasificador.

Tabla 3.2. Desempeños obtenidos con SVM en *BCI Competition IV dataset 2a*.

Método \Evaluación	Entrenamiento	Validación	Promedio
CSP₂+SVM	80.16% ± 10.56%	79.57% ± 10.89%	79.87% ± 10.73%
CWT+SVM	64.39% ± 07.46%	64.43% ± 07.32%	64.41% ± 07.39%
ST+SVM	64.46% ± 07.91%	62.50% ± 07.75%	63.48% ± 07.83%
CSP ₂ +CWT+SVM	79.82% ± 11.27%	77.93% ± 12.88%	78.87% ± 12.08%
CSP ₂ +ST+SVM	78.07% ± 11.36%	76.93% ± 13.08%	77.50% ± 12.22%

De igual manera, la tabla 3.3 muestra los desempeños al utilizar la CNN como clasificador para cada uno de los métodos sin modificar ningún hiperparámetro de la red. Se observa que existen varianzas que van desde 7.32% hasta el 13.08% las cuales se deben a que, entre los sujetos de la base de datos *BCI Competition IV dataset 2a*, el sujeto 05 se mantuvo bajo en desempeño en todas las metodologías, mientras que el sujeto 03 obtenía desempeños cercanos al 100%. Por ejemplo, en el caso de CSP₂+ST+SVM el sujeto 05 tuvo un desempeño del 62.5% y el sujeto 03 del 96.88%, lo que hace que la varianza entre los resultados sea elevada.

Tabla 3.3. Desempeños obtenidos con CNN en *BCI Competition IV dataset 2a*.

Método \Evaluación	Entrenamiento	Validación	Promedio
CSP ₂ +CNN	84.70% ± 12.45%	80.30% ± 13.72%	82.50% ± 13.09%
CWT+CNN	86.41% ± 04.78%	76.41% ± 06.78%	81.41% ± 05.78%
ST+CNN	76.12% ± 08.01%	69.77% ± 07.15%	72.95% ± 07.58%
CSP₂+CWT+CNN	87.69% ± 09.66%	81.81% ± 11.34%	84.75% ± 10.50%
CSP ₂ +ST+CNN	84.99% ± 10.02%	79.19% ± 12.50%	82.09% ± 11.26%

Al comparar los desempeños de ambos clasificadores, SVM y CNN, se observa que CSP₂ es el mejor método para extraer características cuando se utiliza SVM y CSP₂+CWT al momento de utilizar la red neuronal, superándolo en casi 5% de mayor desempeño. Otra

observación es que solamente el método ST+CNN queda por debajo del 80% en comparación con los demás métodos al implementar CNN y es el único método al que le gana CSP₂+SVM, que fue el ganador del clasificador SVM.

Por otra parte, al utilizar CSP₂+CWT+CNN y CSP₂+ST+CNN se tienen mejores desempeños que sólo utilizando CWT+CNN y ST+CNN, esto resalta la importancia de combinar ambos métodos para extraer características.

En la figura 3.16 se presentan las gráficas de entrenamiento y de validación obtenidas de los desempeños de cada sujeto al utilizar el método ST+CNN que fue el de menor desempeño con el clasificador CNN; y de igual forma, en la figura 3.17 se muestran los desempeños de entrenamiento y validación al utilizar CSP₂+CWT+CNN, que combina patrones espaciales comunes con la transformada continua wavelet, que es el método que arrojó el desempeño más alto.




Figura 3.16. Desempeños obtenidos al utilizar ST+CNN.

En las gráficas de la figura 3.16 se muestra una línea punteada verde, que muestra el promedio de todos los sujetos obtenido en cada etapa; para el entrenamiento es de 76.12% y para la validación de 69.77%, con un promedio general del 72.95% en el caso de ST+CNN.

3.6.2 Desempeños de la base de datos *EEGdataset*

La tabla 3.4 muestra los desempeños obtenidos en la etapa de entrenamiento y de validación al utilizar los diferentes métodos para extraer características y utilizar SVM como clasificador, con la base de datos *EEGdataset*.




Figura 3.17. Desempeños obtenidos al utilizar CSP₂+CWT+CNN.

Tabla 3.4. Desempeños obtenidos con SVM en *EEGdataset*.

Método \ Evaluación	Entrenamiento	Validación	Promedio
CSP₂+SVM	73.66% ± 7.60%	72.83% ± 8.48%	73.25% ± 8.04%
CWT+SVM	66.94% ± 5.31%	65.56% ± 5.97%	66.25% ± 5.64%
ST+SVM	65.94% ± 5.76%	64.42% ± 7.22%	65.18% ± 6.49%
CSP ₂ +CWT+SVM	73.87% ± 7.65%	72.49% ± 7.97%	73.18% ± 7.81%
CSP ₂ +ST+SVM	72.53% ± 7.37%	70.89% ± 7.93%	71.71% ± 7.65%

De igual manera, la tabla 3.5 muestra los desempeños al utilizar la CNN como clasificador para cada uno de los métodos, sin modificar hiperparámetros de la red con la base de datos *EEGdataset*.

Tabla 3.5. Desempeños obtenidos con CNN en *EEGdataset*.

Método \ Evaluación	Entrenamiento	Validación	Promedio
CSP ₂ +CNN	85.87% ± 6.68%	80.61% ± 7.08%	83.24% ± 6.88%
CWT+CNN	89.14% ± 8.12%	85.06% ± 8.36%	87.10% ± 8.24%
ST+CNN	91.83% ± 6.49%	87.91% ± 6.58%	89.87% ± 6.53%
CSP ₂ +CWT+CNN	94.57% ± 4.20%	91.59% ± 4.56%	93.08% ± 4.38%
CSP₂+ST+CNN	95.30% ± 3.66%	91.82% ± 3.96%	93.56% ± 3.81%

Al comparar los desempeños de ambos clasificadores, SVM y CNN, se observa que CSP₂ es el mejor método para extraer características cuando se utiliza SVM (al igual que con la base de datos *BCI Competition IV dataset 2a*) y CSP₂+ST al momento de utilizar la red neuronal, superándolo en casi 20% de mayor desempeño.

Al evaluar esta base de datos se observa que ningún método de extracción de características combinado con SVM supera a los clasificadores obtenidos al implementar la CNN.

Por otra parte, al igual que la base de datos *BCI Competition IV dataset 2a*, al utilizar $CSP_2+CWT+CNN$ y $CSP_2+ST+CNN$ se tienen mejores desempeños que sólo utilizando $CWT+CNN$ y $ST+CNN$, esto resalta la importancia de combinar ambos métodos para extraer características.

En la figura 3.18 se presentan las gráficas de entrenamiento y de validación obtenidas de los desempeños de cada sujeto al utilizar el método CSP_2+CNN que fue el de menor desempeño con el clasificador CNN. De igual forma, en la figura 3.19 se muestran los desempeños de entrenamiento y validación al utilizar $CSP_2+ST+CNN$, que combina patrones espaciales comunes con la transformada Stockwell, que es el método que arrojó el desempeño más alto.




Figura 3.18. Desempeños obtenidos al utilizar CSP_2+CNN .

Los desempeños obtenidos en esta sección se pueden comparar directamente con el trabajo del artículo [29], de donde se obtuvo la base de datos *EEGdataset* y se utilizan VM de la mano derecha y de la mano izquierda y reflejan un desempeño promedio del $67.46\% \pm 13.17\%$.

En [29] se utilizó CSP como herramienta para extracción de características y discriminante lineal de Fisher como clasificador.




Figura 3.19. Desempeños obtenidos al utilizar $CSP_2+ST+CNN$

Esta metodología no se profundizó, pues el aporte principal de su artículo fue el proporcionar la base de datos que consta de 52 sujetos y 2 VM, sin embargo, buscaban aproximar un primer acercamiento a una correcta clasificación generando la gráfica de la figura 3.20. Además, se menciona en [29] que los sujetos 29 y 34 fueron descartados en el análisis posterior debido a que mostraron que más del 90% de sus ensayos se correlacionaron con electromiografía, produciendo una mayor potencia de alta frecuencia (50–250 Hz) en el período relacionado con la VM.




Figura 3.20. Desempeños generales obtenidos en *EEGdataset* por [29].

En este proyecto sí se consideraron los sujetos 29 y 34 por que el análisis realizado es mediante patrones espaciales comunes y en tiempo-frecuencia, lo que permite que aun cuando haya correlación con otras señales eléctricas, los patrones de la actividad cerebral se presentarán y en el caso de la red CNN será capaz de determinar características que permiten la discriminación entre VM de la mano izquierda y la mano derecha. De tal manera que el sujeto

29 obtuvo un desempeño del 91.8% y el sujeto 34 del 94%. Esto permite observar que la metodología funciona incluso para sujetos que la literatura ha determinado como descartados para un sistema BCI.

En la figura 3.21 se muestran las matrices de confusión obtenidas de las etapas de entrenamiento y validación del sujeto 29. Esto ayuda a observar que la metodología implementada, las herramientas para extracción de características y la CNN, sí permiten la clasificación de las visualizaciones motoras de dichos sujetos, aún con la presencia de altas frecuencias debidas a la electromiografía.




Figura 3.21. Matrices de confusión de etapa de entrenamiento y validación del sujeto 29.

De igual manera, en la figura 3.22 se muestran las matrices de confusión obtenidas de las etapas de entrenamiento y validación del sujeto 34.




Figura 3.22. Matrices de confusión de etapa de entrenamiento y validación del sujeto 34.

Es importante señalar que, aunque se ha dicho que las redes CNN fueron pensadas para que extrajeran características por sí mismas, el desempeño sí varía en función de la imagen de entrada a la red. Esto se comprueba con los resultados de los clasificadores. Cuando se utilizaron herramientas simples como CSP, CWT y ST los resultados fueron más bajos a cuando se utilizaron herramientas compuestas como CSP+CWT y CSP+ST. Ya que la información de entrada a la red CNN es más discriminante y es más sencillo que la misma arquitectura de red CNN, sin ninguna modificación, presente desempeños más altos. En otras palabras, ante un mismo esquema de red, entre más clara y discrimínate se una imagen de una clase respecto a la otra, los resultados serán mejores a que si las imágenes presentan características difíciles de percibir.

De tal manera que, al evaluar ambas bases de datos se observó que la red CNN es el mejor clasificador con los métodos propuestos para extraer características (CSP, CWT, ST, CSP+CWT, CSP+ST), por lo que se elaboró la tabla 3.6 donde se muestran los resultados promedios de ambas bases de datos (tabla 3.3 y tabla 3.5) y acomodados de mayor a menor desempeño. Además, se observa que las herramientas compuestas de patrones espaciales y tiempo-frecuencia, son las que mejores desempeños obtuvieron ya que la información es más discriminante.

Tabla 3.6. Desempeños promedios de ambas bases de datos utilizando VM de mano izquierda y VM de mano derecha.

Método \Evaluación	Entrenamiento	Validación	Promedio
CSP₂+CWT+CNN	91.13% ± 6.93%	86.70% ± 7.95%	88.91% ± 7.44%
CSP ₂ +ST+CNN	90.14% ± 6.84%	85.50% ± 8.23%	87.82% ± 7.53%
CWT+CNN	87.77% ± 6.45%	80.73% ± 7.57%	84.25% ± 7.01%
CSP ₂ +CNN	85.28% ± 9.56%	80.45% ± 10.4%	82.87% ± 9.98%
ST+CNN	83.97% ± 7.25%	78.84% ± 6.86%	81.41% ± 7.05%

Con base en esta esta información, se tiene que CSP₂+CWT+CNN y CSP₂+ST+CNN son los dos mejores métodos para clasificar entre VM de la mano izquierda y VM de la mano derecha, de acuerdo con la metodología propuesta. Sin embargo, como se observó que la combinación de patrones espaciales con una transformada que involucre frecuencia-tiempo da buenos resultados, se propuso utilizar una mayor cantidad de filas en CSP, para tener más

información sobre cada clase de VM y determinar si esto aumenta el desempeño del sistema. Por tales motivos, en la siguiente sección se presentan los resultados al evaluar la metodología propuesta, pero utilizando 4 y 6 filas de la matriz de proyección de CSP.

3.7 CSP₄ y CSP₆

Para extraer características mediante CSP utilizando 4 y 6 filas, se sigue el procedimiento mostrado en 3.4.1, pero ahora $fil = \{1, 2, nCh-1, nCh\}$ en el caso de CSP₄ y $fil = \{1, 2, 3, nCh-2, nCh-1, nCh\}$ en el caso de CSP₆.

De igual manera, se concatenan las matrices frecuencia-tiempo de cada transformada como en 3.5.2 en los apartados CSP+CWT+CNN y CSP+ST+CNN y se aplica la interpolación bicúbica para generar las imágenes de 22x100 de entrada a la CNN.

La arquitectura de la CNN permanece con los mismos hiperparámetros, no hay ninguna modificación. De tal manera que los resultados cuando se utilizó la base de datos *BCI Competition IV dataset 2a* se presentan en la tabla 3.7 y cuando se utilizó la base de datos *EEGdataset*, se observan en la tabla 3.8.

Tabla 3.7. Desempeños de *BCI Competition IV dataset 2a* al utilizar CSP₄ y CSP₆.

Método \Evaluación	Entrenamiento	Validación	Promedio
CSP ₄ +CWT+CNN	92.16% ± 04.59%	86.55% ± 05.92%	89.36% ± 05.26%
CSP ₄ +ST+CNN	89.23% ± 05.08%	83.87% ± 6.32%	86.55% ± 05.70%
CSP₆+CWT+CNN	98.08% ± 01.40%	94.44% ± 02.18%	96.26% ± 01.79%
CSP ₆ +ST+CNN	95.54% ± 02.99%	90.88% ± 05.14%	93.21% ± 04.06%

Tabla 3.8. Desempeños de *EEGdataset* al utilizar CSP₄ y CSP₆.

Método \Evaluación	Entrenamiento	Validación	Promedio
CSP ₄ +CWT+CNN	98.56% ± 1.88%	97.26% ± 2.42%	97.91% ± 2.15%
CSP ₄ +ST+CNN	95.81% ± 4.80%	93.87% ± 4.66%	94.84% ± 4.73%
CSP₆+CWT+CNN	98.83% ± 1.40%	97.67% ± 2.06%	98.25% ± 1.73%
CSP ₆ +ST+CNN	98.65% ± 1.93%	97.62% ± 2.31%	98.14% ± 2.12%

Con esto se demuestra que CSP₆+CWT es el mejor método para extraer características con ambas bases de datos y que la propuesta de utilizar mayor cantidad de filas de la matriz de

proyección de patrones espaciales sí resultó de provecho para el desempeño del sistema de clasificación, aumentando de $88.91\% \pm 7.44\%$ a $97.25\% \pm 1.76\%$ al promediar los desempeños de ambas bases de datos.

Estos desempeños de la metodología propuesta se pueden comparar con los obtenidos en los trabajos [13], [29] y [30], en donde utilizan una transformada STFT, CSP y Wavelet, que son herramientas que se manejan en este proyecto, a excepción de STFT, pero sigue siendo una transformación tiempo-frecuencia como la utilizada con CWT. Ellos obtuvieron desempeños del 92.73%, 67.46% y 92.75%, respectivamente, cuando en este proyecto al utilizar CSP₆+CWT+CNN se obtuvo un desempeño del 98% al clasificar 2 VM: mano izquierda y mano derecha, tal como en el caso de los artículos. Aquí se percibe con claridad cómo es que, al utilizar herramientas sencillas como una transformación en tiempo-frecuencia o patrones espaciales, los resultados son menores que al combinar las herramientas. En cambio, en la metodología propuesta se hace la combinación de ambos métodos, lo que representa una aportación que no se ha observado en otras metodologías de la literatura, ya que se utilizaba uno de los dos métodos, pero no en conjunto. Además, se resalta la importancia de que con esta metodología sí se han discriminado VM en sujetos que se habían considerado como descartados y se han obtenido desempeños arriba del 90%.

3.8 Conclusiones del capítulo

En esta sección se implementaron dos clasificadores: uno basado en SVM y otro en una red neuronal convolucional con 3 capas intermedias de convolución para identificar visualizaciones motoras de la mano izquierda y la mano derecha. Para ello, se utilizó una metodología donde se compararon diferentes herramientas para la extracción de características como CSP, CWT, ST, CSP+CWT y CSP+ST. Para determinar cuál método daba un mejor desempeño en la clasificación, se evaluaron dos bases de datos que contienen información referente a VM de la mano derecha y VM de la mano izquierda y se obtuvieron desempeños mayores al 95% en ambas, al utilizar CSP₆+CWT.

Así, los principales logros y aportaciones de este trabajo capítulo en: determinar una metodología basada en una combinación de patrones espaciales, una transformada tiempo-frecuencia y un clasificador basado en redes neuronales convolucionales; el análisis realizado

para determinar la cantidad de filas utilizadas en el método CSP en combinación con CWT; los resultados obtenidos de la arquitectura de red CNN propuesta señalan que es un modelo que puede ser utilizado para entrenarse con VM de diferentes sujetos de prueba, incluyendo algunos sujetos que se han descartado por considerarse que sus señales no eran aptas para tener discriminación entre VM; y un bajo costo computacional debido al modelo de red CNN propuesto.

Al analizar los diferentes métodos para extraer características se concluyó que el método CSP₆+CWT fue el mejor debido a que, aun cuando ST y CWT son transformadas muy parecidas y ST es conocida en la literatura por implementar una corrección de fase y brindar mayor resolución o detalles en la matriz tiempo-frecuencia, esto se ve directamente perjudicado al momento de hacer el ajuste para generar las imágenes de entrada a la CNN. Es decir, se tiene que acotar las bandas de frecuencia de las matrices de transformadas de cada canal y después, redimensionar la imagen resultante, perdiendo más información ya que la proporción de reducción es mayor que al hacer el ajuste con la transformada CWT. De tal manera que la red CNN no aprende tan rápido o memoriza información que repercute en el desempeño de la clasificación de VM.

Se evaluó la cantidad de filas utilizadas en la matriz de proyección de CSP para obtener el mejor desempeño, asignándose valores de 2, 4 y 6 filas. El motivo de que sea esa cantidad de filas es que, en primer lugar, debe ser un número par para que incluya información balanceada para cada tipo de VM (recordando que se está trabajando con VM de la mano derecha y VM de la mano izquierda). En segundo lugar, la cantidad de filas está limitada por la cantidad de electrodos utilizados en la etapa de toma de muestras. En este caso particular se debe realizar una aplicación BCI en tiempo real, por lo que se hará uso del dispositivo OpenBCI que cuenta con 8 canales. Entonces, si la cantidad de filas va de dos en dos (una por canal), se pueden seleccionar filas desde 2, 4, 6, 8 y así sucesivamente, pero como también se depende de la cantidad de electrodos, si se eligen 8 filas ya no tendrá tanto sentido haber aplicado CSP pues una de las ventajas que ofrece este método es la reducción de información y con 8 filas no se habría disminuido. En consecuencia, sólo se evaluaron 2, 4 y 6 filas que sí aprovechan la ventaja

de CSP y que generan información balanceada al tener 2 tipos de VM y elegir una cantidad par de filas.

Por otra parte, la arquitectura de la CNN utilizada se ve prometedora, debido a que permitió clasificar VM de la mano izquierda y VM de la mano derecha de sujetos que el estado del arte señalaba como no aptos para el análisis. Estos sujetos obtuvieron un desempeño mayor al 90% de clasificación al implementar la metodología que maneja patrones espaciales comunes, la transformada tiempo-frecuencia y el clasificador basado en CNN. Estas herramientas han hecho posible que la actividad cerebral presente en sujetos de prueba sea evaluada correctamente, a diferencia de otras herramientas que se han presentado en el estado del arte y que no son capaces de discriminar correctamente entre algunas VM, catalogando deliberadamente a sujetos como no aptos para utilizar un sistema BCI. No obstante, la metodología propuesta sí los declara como aptos para un sistema BCI y aún más, con excelente nivel de desempeño.

En unión con lo la información del párrafo anterior, la arquitectura diseñada tiene un costo computacional más bajo que otras redes CNN profundas que involucran una gran cantidad de capas ocultas y filtros convolucionales para extracción de características, pues sólo tiene 3 capas intermedias con 128 filtros convolucionales en cada una.

Por consecuencia, en el siguiente capítulo se expone la expansión de esta metodología CSP₆+CWT+CNN para discriminar entre otras clases de VM, como movimiento de pies o de lengua.

CAPÍTULO 4.

4. METODOLOGÍA DE RECONOCIMIENTO PARA 4 VM

En esta sección se muestra la metodología para el reconocimiento de cuatro visualizaciones motoras: VM de mano derecha, VM de mano izquierda, VM de pies y VM de lengua que provienen de la base de datos *BCI Competition IV dataset 2a* [39]. Se plantea extraer características utilizando CSP_6 y la transformada Wavelet continua, y se proponen dos esquemas de clasificación, ambos basados en CNN, uno monolítico y otro modular.

En esta sección sólo se utilizan las muestras de los sujetos de la base de datos *BCI Competition IV dataset 2a* debido a que incluye 4 visualizaciones motoras, a diferencia de la base de datos *EEGdataset*, que sólo presenta señales de VM de la mano izquierda y la mano derecha.

Previo a la implementación de los esquemas de clasificación se observó el comportamiento de las imágenes I_{CSP_CWT} correspondientes a cada una de las visualizaciones motoras para determinar su consistencia en el comportamiento a lo largo del tiempo y la frecuencia de acuerdo con cada clase. Un ejemplo de 4 imágenes por clase se presenta en la figura 4.1.




Figura 4.1. Ejemplos de I_{CSP_CWT} de cada VM obtenidas del sujeto 03 de *BCI Competition IV dataset 2a*.

El análisis realizado fue puramente subjetivo, observando que en el caso de las VM de la mano izquierda se presentaba mayor magnitud de la señal en frecuencias bajas a lo largo del tiempo. En el caso de la VM de la mano derecha y la VM de los pies la energía está dispersa, es decir, hay magnitudes altas en muchas frecuencias, sin embargo, para la VM de la mano derecha se presenta mayor magnitud en altas frecuencias y la VM de los pies en bajas frecuencias. Finalmente, en el caso de la VM de la lengua se observa que casi no hay magnitud pronunciada a lo largo del análisis en frecuencia, pero es constante en altas frecuencias. Estas características subjetivas dan un indicio de la posibilidad de clasificación entre clases, pero no aseguran un comportamiento consistente y permanente a lo largo de todas las VM. Es por eso la importancia de obtener resultados objetivos mediante un análisis cuantitativo utilizando algún algoritmo para clasificación.

Una vez hecho el análisis visual, se procedió a la implementación de los esquemas monolítico y modular.

4.1 Esquema monolítico

El esquema monolítico ofrece características importantes para ser implementado en un sistema en tiempo real. Por ejemplo, el tiempo de procesamiento: para arrojar la clase ganadora, una vez que se ha entrenado el modelo, sólo es necesario propagar la información de entrada por la red CNN sin necesidad de módulos externos. Además, sólo se necesita un módulo que contiene todas las capas de la CNN y que corresponde al sistema en sí mismo. En la figura 4.2 se presenta el diagrama del esquema monolítico el cual es simple, pues sólo se necesita la imagen de entrada a la CNN y la red que clasificará entre 4 tipos de VM.



Figura 4.2. Diagrama del esquema monolítico.

En este esquema monolítico se utilizó la arquitectura de red CNN mostrada en la figura 4.3 que está basada en la arquitectura de la CNN de clasificación de 2 clases (ver figura 3.15), pero con una capa FC de 4 clases.




Figura 4.3. Arquitectura CNN para 4 clases.

De tal manera que, en lugar de utilizar la expresión (3.53) se tiene una capa *fully-connected* definida para cuatro clases C de VM

$$FC^{C,nFiltro}(i, j) = M 3^{nFiltro}(i, j) * F_4^{C,nFiltro}(i, j) + \beta_4^C \quad (4.1)$$

donde, en este caso de cuatro clases, $F_4^{C,nFiltro}(i, j) \in \mathbb{R}^{4 \times 13 \times 91 \times 128}$ representa los pesos de la capa totalmente conectada para cada clase y la sumatoria de los valores resultantes de la función *softmax* quedará expresada como

$$\sum_{clase=1}^{nClases} SM^{clase} = SM^{c_{izq}} + SM^{c_{der}} + SM^{c_{pies}} + SM^{c_{lengua}} = 1 \quad (4.2)$$

Dando paso a la salida de la clasificación

$$output = \begin{cases} c_{izq} & \text{si } \max(SM^{c_{izq}}, SM^{c_{der}}, SM^{c_{pies}}, SM^{c_{lengua}}) = SM^{c_{izq}} \\ c_{der} & \text{si } \max(SM^{c_{izq}}, SM^{c_{der}}, SM^{c_{pies}}, SM^{c_{lengua}}) = SM^{c_{der}} \\ c_{pies} & \text{si } \max(SM^{c_{izq}}, SM^{c_{der}}, SM^{c_{pies}}, SM^{c_{lengua}}) = SM^{c_{pies}} \\ c_{lengua} & \text{si } \max(SM^{c_{izq}}, SM^{c_{der}}, SM^{c_{pies}}, SM^{c_{lengua}}) = SM^{c_{lengua}} \end{cases} \quad (4.3)$$

Es importante aclarar que la salida de la función SM es un número real de punto flotante tipo *double* de 8 bytes para cada clase, lo que hace prácticamente imposible que una salida sea igual a otra, por lo que se omite el caso en el que las salidas sean iguales.

4.1.1 Resultados del esquema monolítico

Utilizando la red monolítica para clasificar 4 visualizaciones motoras se obtuvo un desempeño del $90.03\% \pm 08.06\%$ en la etapa de entrenamiento y $71.98\% \pm 13.33\%$ en la etapa de validación, como se muestra en la figura 4.4, y un desempeño promedio del $81.01\% \pm 10.70\%$.




Figura 4.4. Resultados de entrenamiento y validación bajo el esquema monolítico para 4 clases.

Se puede observar que hay una gran varianza entre los resultados de validación. Esto se debe a que hay sujetos, como el sujeto 05, que tienen desempeños bajos de validación a diferencia de otros, como el sujeto 03, cuyos desempeños son altos, lo que genera que el desempeño promedio de toda la base de datos tenga una varianza más alta.

4.2 Esquema modular

Otro esquema que se plantea utilizar es el modular. En este caso el tiempo de procesamiento para arrojar la clase ganadora será mayor en comparación con el esquema monolítico, pues se tienen varios módulos que corresponden a redes CNN. Sin embargo, lo más importante de un esquema modular es que se rige bajo la premisa *divide y vencerás* que sigue el principio de atacar un problema dividiéndolo en varias situaciones que es más fácil resolver por separado. En este caso se plantea obtener mejores desempeños al clasificar entre 2 VM, que tengan características discriminantes entre ellas, a diferencia de clasificar 4 VM al mismo tiempo. Esto afectará el tiempo de respuesta, pero el problema se solucionará de manera más estructurada.

De manera que se implementó la arquitectura de red CNN (ver figura 3.15) para todas las combinaciones entre dos clases, como se muestra en la figura 4.5.




Figura 4.5. Esquema modular utilizado en el clasificador de 4 VM.

Para ello, se entrenó cada una de las CNN de dos clases y después se implementaron dos clasificadores: uno basado en la moda que determina cuál es la clase que más se repite al evaluar cada una de las CNN y otro en un algoritmo propuesto al que se denominó sgSM (salida ganadora al evaluar función *softmax*). El algoritmo sgSM surge de observar que en ocasiones empate entre clases y el esquema modular elegirá la clase a la cual se le ha asignado un número de etiqueta menor. Es decir, la clase VM Mano izquierda tiene etiqueta “1”, la clase VM Mano derecha tiene etiqueta “2”, la clase VM pies tiene etiqueta “3” y la clase VM Lengua tiene etiqueta “4” (las etiquetas fueron asignadas por la base de datos *BCI Competition IV data set 2a* [39]) y si, por ejemplo, empatan las clases 3 y 4 automáticamente se elige la clase 3 al tener etiqueta con valor menor. Esto ocasiona errores en la clasificación disminuyendo el desempeño del sistema, por lo cual se implementó el algoritmo sgSM en que se evalúa si hay empate entre clases y de ser así, se utilizan los valores obtenidos de la función *softmax*

$$\begin{aligned}
 mIzq &= (\Psi_{CNN_1}^{izq})(SM_{CNN_1}^{izq}) + (\Psi_{CNN_2}^{izq})(SM_{CNN_2}^{izq}) + (\Psi_{CNN_3}^{izq})(SM_{CNN_3}^{izq}) \\
 mDer &= (\Psi_{CNN_1}^{der})(SM_{CNN_1}^{der}) + (\Psi_{CNN_4}^{der})(SM_{CNN_4}^{der}) + (\Psi_{CNN_5}^{der})(SM_{CNN_5}^{der}) \\
 mPie &= (\Psi_{CNN_2}^{pie})(SM_{CNN_2}^{pie}) + (\Psi_{CNN_4}^{pie})(SM_{CNN_4}^{pie}) + (\Psi_{CNN_6}^{pie})(SM_{CNN_6}^{pie}) \\
 mLen &= (\Psi_{CNN_3}^{len})(SM_{CNN_3}^{len}) + (\Psi_{CNN_5}^{len})(SM_{CNN_5}^{len}) + (\Psi_{CNN_6}^{len})(SM_{CNN_6}^{len})
 \end{aligned} \tag{4.4}$$

$$\Psi_{CNN}^C = \{0: \text{clase perdedora}, 1: \text{clase ganadora}\}$$

$$CNN = \{CNN_1, CNN_2, CNN_3, CNN_4, CNN_5, CNN_6\}$$

donde Ψ_{CNN}^C toma el valor 1 cuando fue clase ganadora de cada clasificador de 2 VM para las clases *izq*, *der*, *pie* o *len* y cada red *CNN*; y 0 caso contrario. Después se determina la salida de todo el esquema modular mediante

$$output = \max(mIzq, mDer, mPie, mLen) \quad (4.5)$$

En otras palabras, se hace la sumatoria de todas las salidas de la función *softmax* SM^c en las cuales la clase *c* fue la ganadora y se comparan los valores obtenidos, determinando que aquella clase que tiene mayor valor en la sumatoria será la salida *output* de todo el esquema modular.

4.2.1 Clasificadores de 2 VM utilizando *cross-validation*

Para el entrenamiento y validación de los clasificadores se utilizó *cross-validation* con 5 conjuntos que dividen el conjunto de datos destinando 80% para entrenamiento, y 20% para validación.

En la tabla 4.1 se presentan los resultados de los clasificadores de 2 VM de la etapa de entrenamiento, acomodados de mayor a menor desempeño promedio de todos los clasificadores de 2 VM y con un promedio general de todos los sujetos de prueba del $97.62\% \pm 01.18\%$.

Tabla 4.1 Resultados de los clasificadores de 2 VM de la etapa de entrenamiento bajo el esquema modular.

Sujeto / VM	Izq vs Der	Izq vs Pie	Izq vs Len	Der vs Pie	Der vs Len	Pie vs Len	Promedio	STD	Mejor clasificador por sujeto
03	99.77%	99.84%	99.67%	99.76%	97.28%	97.00%	98.89%	1.36%	Izq vs Pie
05	98.42%	98.62%	98.34%	98.65%	99.07%	99.04%	98.69%	0.31%	Der vs Len
01	98.52%	96.36%	99.80%	99.75%	99.89%	97.37%	98.62%	1.48%	Der vs Len
07	96.74%	99.21%	98.01%	99.32%	98.32%	94.58%	97.70%	1.79%	Der vs Pie
09	97.00%	98.40%	99.01%	98.06%	96.57%	97.05%	97.68%	0.95%	Izq vs Len
02	96.38%	97.48%	96.60%	98.57%	96.30%	99.08%	97.40%	1.19%	Pie vs Len
04	97.43%	97.74%	97.07%	97.02%	98.45%	96.69%	97.40%	0.63%	Der vs Pie
08	97.07%	97.48%	99.47%	97.26%	95.30%	97.04%	97.27%	1.33%	Izq vs Len
06	97.28%	97.02%	93.85%	92.30%	95.97%	93.32%	94.96%	2.08%	Izq vs Der
Promedio	97.62%	98.02%	97.98%	97.85%	97.46%	96.80%	97.62%	1.18%	Der vs Len
STD	1.07%	1.10%	1.92%	2.30%	1.55%	1.86%			

De manera similar, en la tabla 4.2 se presentan los resultados de los clasificadores de 2 VM de la etapa de validación, con un promedio general de todos los sujetos de prueba del 94.76% $\pm$ 02.11%.

Tabla 4.2 Resultados de los clasificadores de 2 VM de la etapa de validación bajo el esquema modular.

Sujeto / VM	Izq vs Der	Izq vs Pie	Izq vs Len	Der vs Pie	Der vs Len	Pie vs Len	Promedio	STD	Mejor clasificador por sujeto
03	98.61%	98.47%	98.19%	98.75%	95.90%	93.82%	97.29%	2.00%	Der vs Pie
01	96.01%	94.51%	98.96%	99.20%	99.86%	93.65%	97.03%	2.66%	Der vs Len
07	92.43%	98.61%	96.98%	98.61%	97.53%	91.67%	95.97%	3.11%	Izq vs Pie
05	94.58%	94.76%	95.90%	93.02%	95.17%	96.60%	95.01%	1.23%	Pie vs Len
08	94.69%	94.10%	98.16%	94.55%	93.13%	95.03%	94.94%	1.71%	Izq vs Len
09	93.75%	96.01%	97.67%	93.51%	93.65%	92.71%	94.55%	1.89%	Izq vs Len
04	94.90%	95.45%	95.10%	93.89%	94.38%	92.74%	94.41%	0.99%	Izq vs Pie
02	90.00%	94.06%	91.60%	95.42%	92.43%	96.98%	93.41%	2.57%	Pie vs Len
06	93.72%	92.05%	87.78%	87.64%	91.46%	88.85%	90.25%	2.51%	Izq vs Der
Promedio	94.30%	95.34%	95.59%	94.95%	94.83%	93.56%	94.76%	2.11%	Der vs Pie
STD	2.36%	2.12%	3.68%	3.65%	2.63%	2.51%			

En las tablas anteriores se utilizan dos códigos de colores. El primero corresponde al tipo de clasificador entre dos VM: amarillo para el clasificador “Izq vs Der”, rojo para el clasificador “Izq vs Pie”, morado para el clasificador “Izq vs Len”, verde para el clasificador “Der vs Pie”, azul para el clasificador “Der vs Len” y gris para el clasificador “Pie vs Len”. El segundo código de color representa una escala que va de verde-amarillo-rojo, donde el color verde indica que es el mejor desempeño (en escala de 0 a 1), amarillo es promedio y rojo fue el peor, como se muestra en la escala de la figura 4.6



Figura 4.6. Escala para evaluar desempeños, del más alto (verde o número 1) al más bajo (rojo o número 9).

De tal manera que el código de colores de la figura anterior se implementó por columna (abarcando las 9 filas que incluyen todos los sujetos de prueba) en los diferentes tipos de clasificadores de 2 VM para indicar cuál sujeto fue el que obtuvo mejor desempeño en dicho clasificador y quién fue el que salió con más bajo desempeño. Por ejemplo, en el caso de los desempeños obtenidos para el clasificador “Izq vs Der” en la etapa de validación, el sujeto 02 obtuvo el menor desempeño con 90% y el sujeto 03 obtuvo el desempeño más alto con 98.61%.

Además, se presenta en la última columna de cada tabla el clasificador de 2 VM con mayor desempeño por sujeto. Por ejemplo, para el caso del sujeto 01, al evaluar todos sus clasificadores de dos clases se obtuvo que el mejor desempeño se presentó con la red CNN que discrimina entre VM de mano derecha y VM de lengua.

Utilizando los clasificadores de 2 VM ya entrenados se seleccionaron los parámetros de las validaciones cuyos desempeños fueron más altos para integrar el esquema modular, y mediante la moda y sgSM para determinar la clase ganadora se evaluó la base de datos *BCI Competition IV dataset 2a* con un conjunto de prueba que contiene 864 muestras, como se presenta en la tabla 4.3.

La evaluación del esquema modular se realizó utilizando las ecuaciones (3.59) y (3.60) para obtener el desempeño y, además, se calculó el coeficiente kappa.

El coeficiente kappa mide el rendimiento de la clasificación sin el efecto de la precisión de la clasificación arbitraria, SS_{ar} [48].

$$kappa_{ep} = \frac{SS_{ep} - SS_{ar}}{1 - SS_{ar}} \quad (4.6)$$

De manera que los resultados se presentan en la tabla 4.3 y en la figura 4.7, con un desempeño promedio del esquema modular del 91.37%%±03.29%.

Tabla 4.3 Resultados del esquema modular.

Resultados al implementar esquema modular con 4 VM			
Sujeto	Moda	sgSM	Kappa de sgSM
01	95.25%	95.14%	0.9352
02	88.31%	89.93%	0.8657
03	94.44%	94.79%	0.9306
04	88.43%	90.86%	0.8781
05	88.54%	90.63%	0.8750
06	82.87%	85.76%	0.8102
07	91.55%	92.48%	0.8997
08	93.52%	94.91%	0.9321
09	85.42%	87.85%	0.8380
Promedio	89.81%	91.37%	0.8850
STD	4.20%	3.29%	0.0438




Figura 4.7. Resultados al evaluar el conjunto de prueba bajo el esquema modular para clasificar 4 VM.

4.3 Comparación del método propuesto con otros en la literatura

En esta sección se presentan trabajos reportados en la literatura en donde se han utilizado diversas metodologías para extraer características y clasificar las VM.

Como primera comparación se tiene el [20] en donde se utilizó *temporally constrained sparse group spatial* o TSGSP para extraer características y SVM como clasificador. También evaluaron la base de datos *BCI Competition IV dataset 2a*, pero generando dos clasificadores de 2 VM. El primer clasificador se muestra en la tabla 4.4 que consiste en discriminar entre VM de la mano derecha y VM de la mano izquierda.

Tabla 4.4 Comparación del método propuesto con [20] al evaluar VM de la mano izquierda vs VM de la mano derecha.

VM de mano izquierda vs VM de mano derecha		
Sujeto	TSGSP+SVM [20]	CSP ₆ +CWT+CNN
01	87.00%	96.01%
02	64.70%	90.00%
03	93.80%	98.61%
04	74.30%	94.90%
05	90.40%	94.58%
06	63.90%	93.72%
07	91.40%	92.43%
08	95.80%	94.68%
09	81.30%	93.75%
Promedio	82.51%	94.30%
STD	12.24%	2.36%

Los resultados del segundo clasificador que se evaluó en [20] se muestran en la tabla 4.5, comprándolos con los obtenidos con el método propuesto.

Tabla 4.5 Comparación del método propuesto con [20] al evaluar VM de pies vs VM de lengua.

Sujeto	VM de pies vs VM de lengua	
	TSGSP+SVM [20]	CSP ₆ +CWT+CNN
01	85.00%	93.65%
02	92.40%	96.98%
03	89.70%	93.82%
04	75.80%	92.74%
05	73.90%	96.60%
06	75.10%	88.85%
07	88.30%	91.67%
08	93.00%	95.03%
09	82.50%	92.71%
Promedio	83.97%	93.56%
STD	7.54%	2.51%

En color verde se presentan aquellos desempeños en los que fue mayor el resultado, por cada uno de los 9 sujetos evaluados, mientras que en rojo se presenta el desempeño promedio más alto. Se observa que el único desempeño mayor, considerando ambos clasificadores de 2 VM, fue el del sujeto 08 cuando se evalúa VM de la mano izquierda vs VM de la mano derecha, superando el método propuesto en más de 1%. Sin embargo, en los promedios generales se observa que CSP₆+CWT+CNN supera en 10% de desempeño al compararlo con [20]. Aunado a eso, el tiempo de procesamiento computacional es un punto importante, ya que al trabajo presentado en [20] le toma aproximadamente 17 segundos en generar la salida del sistema, cuando en esta metodología que se propone le toma menos de un segundo, con solo 270 ms se pudo tener a la salida el tipo de VM que se ha realizado por el sujeto de prueba. Además, en su trabajo están analizando diferentes momentos en los que se puede haber presentado una VM y en diferentes bandas de frecuencia, los cuales han sido escogidos por procedimientos subjetivos. A diferencia de [20], en esta metodología se utilizó una técnica de aumento de datos que ya considera este desplazamiento de ventanas a lo largo de la señal EEG para encontrar la VM y una combinación de herramientas CSP+CWT con las cuales no es necesario especificar las bandas de frecuencia, ya que son analizadas mediante CSP y CNN. Esto permite dejar de lado

la parte subjetiva en donde se asignan las bandas de frecuencia a utilizar y la varianza entre las ventanas que producen las épocas.

En la tabla 4.6 se muestra la comparación de la metodología propuesta con los trabajos [17], [18], [30], [32], [33], [35] y [49] reportados en la literatura, en donde se utiliza la base de datos *BCI Competition IV dataset 2a* clasificando 4 VM de cada uno de los 9 sujetos que incluye la base de datos.

Tabla 4.6 Comparación del método propuesto con trabajos de la literatura al clasificar 4 VM en términos de desempeño.

4 VM de la base de datos <i>BCI Competition IV dataset 2a</i> .								
Sujeto	CSP + FLS + PSO [17]	CSP + CPSO + TWSVM [18]	FBCSP + CNN [35]	Wavelet + CNN [30]	AR-CSP + SRS- G- FasArt [49]	PSD (Welch) + CNN [33]	FBS + CSP + BO + CNN [32]	CSP₆+CWT + CNN
01	81.40%	85.42%	85.23%	87.51%	95.14%	86.00%	84.91%	95.14%
02	67.50%	56.94%	69.73%	78.57%	68.75%	87.00%	66.38%	89.93%
03	88.20%	88.89%	90.15%	92.15%	98.61%	93.00%	84.74%	94.79%
04	48.60%	70.14%	65.57%	95.67%	81.25%	85.00%	81.36%	90.86%
05	52.90%	53.47%	77.42%	89.20%	72.22%	84.00%	79.22%	90.63%
06	55.70%	66.67%	52.41%	85.12%	75.00%	86.00%	70.67%	85.76%
07	84.30%	74.31%	93.68%	79.23%	86.11%	88.00%	86.12%	92.48%
08	89.30%	97.21%	90.04%	81.28%	97.92%	89.00%	83.81%	94.91%
09	85.70%	90.28%	84.75%	80.67%	94.44%	92.00%	83.04%	87.85%
Prom.	72.62%	75.93%	78.78%	85.49%	85.49%	87.78%	80.03%	91.37%
STD	6.80%	15.43%	13.73%	6.06%	11.64%	3.07%	6.92%	3.29%

En la tabla 4.6 se puede ver que, considerando el desempeño por sujeto, la metodología propuesta es superada por algunos de los métodos mostrados. Sin embargo, el desempeño general fue superior a todos los trabajos reportados y con una desviación estándar bastante baja de sólo el 3.29%, en donde el desempeño más cercano fue superado por casi un 4%. Esto confirma el buen desempeño del sistema basado en un esquema modular y lo posiciona en primer lugar ante los trabajos relacionados en la literatura que utilizan y evalúan la misma base de datos y con la misma cantidad de VM.

De igual manera, en la tabla 4.7 también se presenta una comparación entre los trabajos [24], [32], [49], [50] y [51] de la literatura y el propuesto, pero ahora utilizando el coeficiente kappa como herramienta para evaluar la metodología.

Tabla 4.7 Comparación del método propuesto con trabajos de la literatura al clasificar 4 VM utilizando el coeficiente kappa.

Sujeto	FBCSP + OVR [50]	CSP + PWKNN [51]	FBS + CSP + BO + CNN [32]	AR-CSP + SRSG-FasArt [49]	CBN + SVM [24]	CSP ₆ +CWT + CNN
01	0.68	0.88	0.68	0.79	0.69	0.9352
02	0.42	0.22	0.36	0.42	0.51	0.8657
03	0.75	0.88	0.69	0.79	0.87	0.9306
04	0.48	0.39	0.62	0.63	0.85	0.8781
05	0.40	0.53	0.6	0.42	0.78	0.8750
06	0.27	0.33	0.45	0.34	0.42	0.8102
07	0.77	0.38	0.71	0.84	0.54	0.8997
08	0.75	0.85	0.72	0.65	0.97	0.9321
09	0.61	0.81	0.66	0.78	0.45	0.8380
Prom.	0.57	0.59	0.61	0.63	0.68	0.88
STD	0.18	0.27	0.12	0.19	0.20	0.04

En la tabla 4.7 se observa que el trabajo reportado en [49], también analizado en la tabla 4.6, no supera a CSP₆+CWT+CNN en términos del coeficiente kappa y [24] lo supera sólo en un sujeto, pero en términos generales del coeficiente kappa la metodología propuesta está por encima 0.2 más que el trabajo con coeficiente kappa más cercano. Además, cabe señalar que [50] es el trabajo ganador de *BCI Competition IV dataset 2a*, que es la base de datos utilizada, y el cual fue superado por más de 0.3.

De tal manera que, para concluir esta sección, se presenta la tabla 4.8 con elementos importantes de comparación: año de publicación, número de VM clasificadas, tipos de VM, cantidad de sujetos de prueba, número de electrodos o de canales, base de datos utilizada, metodología, tiempo de procesamiento aproximado en el cual el sistema determina la clase de VM y el desempeño. Los resultados se presentan ordenados de mayor a menor desempeño.

Se observa que la mayoría de los trabajos están implementando redes neuronales, algunos SVM y otros sistemas difusos y con la misma base de datos que incluye 9 sujetos de prueba.

Tabla 4.8 Comparación general del método propuesto con trabajos de la literatura.

Ref.	Año	# VM	Tipos de VM	Sujetos de prueba	nCh	Base de datos	Metodología	Tiempo de proces. aprox. (seg)	Desempeño
	2019	4	Izq Der, Pie, Len	9	22	BCI Competition IV Data Set 2a	CSP ₆ + CWT + CNN	0.270	91.37%
[33]	2018						PSD (Welch) + CNN	-	87.78%
[30]	2019						Wavelet + CNN	-	85.49%
[49]	2018						AR-CSP + SRSG-FasAr	-	85.49%
[52]		2	Izq vs Der	1	3	BCI Competition II dataset III	RCT + ANN	5.25	84.40%
[20]	2019		Izq vs Der / Pie vs Len	9	22	BCI Competition IV Data Set 2a	TSGSP + SVM	17	84.00%
[32]	2018	4 + IS	Izq, Der, Pie, Len				25	FBS + CSP + BO + CNN	1.04
[35]		4			FBCSP + CNN			-	78.78%
[18]	2017				CSP + CPSO + TWSVM		0.0296	75.93%	
[17]	2018				CSP + FLS + PSO		65	72.62%	
[31]					FFT + CNN		-	69.00%	
[53]	2019						22	Renyi Entropy + LDA + Multi-class	0.1559

Solo [52] utiliza una base de datos diferente a la propuesta, en donde se evalúa solamente un sujeto de prueba. Sin embargo, se incluyó en esta tabla comparativa debido a que muestra el tiempo de procesamiento de su metodología de clasificación, aun cuando se sabe que el desempeño del sistema no puede tener una significancia estadística importante pues sólo se considera un sujeto de prueba, pero servirá como referencia a una medida del tiempo de procesamiento de la metodología que ellos utilizan.

El menor tiempo de clasificación lo tiene el trabajo [18] con 29.6 ms, el cual utiliza patrones espaciales y SVM con un desempeño del 75.93%. El desempeño obtenido es similar al que se obtuvo en este proyecto al utilizar el clasificador SVM (ver tabla 3.2). Además, este tipo de clasificadores tiene la ventaja de asignar una clase a un vector de características en un tiempo relativamente corto. Pero el desempeño obtenido está alrededor del 15% más abajo que el que se obtuvo con CSP₆ + CWT + CNN, el cual consume solamente 270 ms para determinar la clase

de salida del esquema modular, que es un tiempo bastante corto y que le permite ser implementando en un sistema BCI en tiempo real. Por otra parte, el trabajo [32] discrimina entre 5 clases, en donde IS representa el estado de relajación, pero su desempeño queda por debajo del 11% con respecto a la metodología ganadora, que es la propuesta en esta tesis.

En este caso, como las ventanas utilizadas para determinar la clase de una VM son de 2 segundos, al tener un tiempo de respuesta de 270 ms no se pierde ninguna VM y el sistema se puede considerar en tiempo real al no perder muestras completas para determinar una clase. Por ejemplo, [17], [20] y [52], tienen tiempos de procesamiento mayores a los 2 segundos, por lo que no podrían ser considerados en tiempo real; y [18], [32] y [53] sí están dentro del rango.

4.4 Conclusiones del capítulo

En este capítulo se plantearon y evaluaron dos esquemas para reconocer 4 clases de VM: uno modular y otro monolítico. En ambos esquemas se mantuvieron constantes todos los parámetros e hiperparámetros de la arquitectura de la red, a excepción de la clasificación de 4 clases en la salida de la red monolítica y de 2 clases en cada una de las redes del esquema modular.

Dentro del esquema modular se plantearon dos clasificadores que discriminaran entre las salidas de las redes de 2 clases. Uno de los clasificadores se basa en la moda, donde se determina cuál es la clase que más se repite y se asigna como la ganadora. El otro esquema se denominó sgSM y en él se evalúa, además de la clase que más se repite, los casos en los que hay empates entre clases y se asigna como ganadora aquella cuya magnitud en las salidas de la función *softmax* de cada red CNN es mayor.

De tal manera que los desempeños generales de cada esquema resultaron en $81.01\% \pm 10.70\%$ en el caso de la red monolítica y del $91.37\% \pm 3.29\%$ cuando se utilizó la red modular utilizando sgSM.

Una vez que se tuvieron los resultados de clasificación de 4 VM se hizo una comparación de los obtenidos en este proyecto bajo el esquema modular y sgSM contra los reportados en la literatura. El más cercano fue [33] con un desempeño promedio del $87.78\% \pm 6.92\%$, quedando por debajo por casi el 4% con respecto al método propuesto. Además, el tiempo de ejecución

de esta metodología es de 270 ms lo que lo posiciona como competitivo comparado contra los trabajos reportados y en condiciones aceptables para ser implementado en un sistema BCI en tiempo real.

Se concluye que $CSP_6+CWT+CNN$ bajo el esquema modular y en combinación con el algoritmo sgSM es la metodología que dio mejores resultados, por lo que se evaluará en una base de datos propia. De esto se habla en los siguientes capítulos.

CAPÍTULO 5.

5. METODOLOGÍA PARA TOMA DE MUESTRAS

En este capítulo se presenta la base de datos obtenida mediante el registro de la actividad cerebral de 15 sujetos de prueba, la adquisición de los datos, el protocolo utilizado para la toma de muestras y el análisis realizado sobre los resultados. De igual manera, se incluye la metodología implementada para la organización de la información de la base de datos.

5.1 Base de datos

Para evaluación de la metodología propuesta en esta tesis se diseñó y elaboró una base de datos de 15 sujetos de prueba, registrando su actividad cerebral a través de un EEG. La cantidad de sujetos se debe a la disponibilidad de los mismos.

De los 15 sujetos de prueba seleccionados para la elaboración de la base de datos 14 son hombres y 1 es mujer en un rango de edades que va de los 22 a los 27 años. Entre ellos, 2 hombres son zurdos (s_{14} y s_{15}), 2 hombres son ambidiestros (s_9 y s_{12}), la mujer es diestra (s_4) y el resto de los hombres son diestros también.

Para la elaboración de la base de datos los sujetos de prueba firmaron un consentimiento (ver sección de Anexos) en el cual se les explicó en qué consistía el protocolo para la toma de muestras y se les informó acerca del posicionamiento de los electrodos y el manejo confidencial de la información obtenida de sus señales cerebrales. Una vez que se aceptó continuar con la toma de muestras, se diseñó una bitácora que incluye las condiciones físicas y mentales en las que se encontraba el sujeto de prueba cada uno de los días en los que realizó las sesiones para la toma de muestras, así como su estado de ánimo. De igual manera, durante la toma de muestras se registraron todos los inconvenientes presentados por cualquier tipo de anomalía, ya sea por parte de la tarjeta de adquisición de datos, por el sujeto de prueba u otro tipo de factores.

5.2 Adquisición de datos.

Para el registro de la actividad cerebral mediante un método no invasivo de señales EEG a una frecuencia de muestreo $F_s=250$ Hz, se utilizaron los dispositivos de OpenBCI© *cyton board* y *USB-dongle*, así como el casco Ultracortex Mark IV para colocar 8 electrodos secos de AgCl en el cuero cabelludo de cada sujeto de prueba mostrados en la figura 5.1 (encerrados en círculos rojos), los cuales corresponden a

$$Ch = \{Cz, P3, C3, F3, AFz, F4, C4, P4\} \quad (5.1)$$

de acuerdo con el sistema internacional 10-20 y se utilizó A1 (círculo azul) como electrodo de referencia [54], y A2 (círculo verde) como electrodo de tierra [54].




Figura 5.1. Posición de los electrodos en el casco Ultracortex Mark IV para la toma de muestras.

Esta posición de los electrodos se eligió de acuerdo con las áreas de Brodmann que incluyen funciones ejecutivas ($F3$, AFz y $F4$), funciones motoras (Cz), funciones somatosensoriales ($C3$ y $C4$) y área de atención ($P3$ y $P4$) que prometen un conjunto equilibrado para determinar visualizaciones motoras, lo cual se analizará con los resultados obtenidos.

Una vez que el equipo para toma de muestras estaba configurado, se diseñó e implementó el protocolo para la toma de muestras, el cual se observa en la figura 5.2 y corresponde a un ensayo.




Figura 5.2. Protocolo para la toma de muestras que corresponde a un ensayo.

El protocolo está basado en el paradigma de Graz [7], en el que se presenta un esquema de tiempo para la adquisición de las señales cerebrales y localización de las muestras en las cuales la visualización motora está presente. Para ello se comienza con una ventana de reposo o descanso ($t=0$) y se escucha una alarma (*beep*) para indicar al sujeto de prueba que el ensayo ha iniciado; esta ventana (ver figura 5.3) aparece por 2 segundos.




Figura 5.3. Ventana de reposo dentro de la interfaz para toma de muestras.

Después ($t=2$), se presenta una pista sobre la VM que se debe realizar

$$VM = \{Izq, Der, Pie, Len\} \quad (5.2)$$

ya sea de la mano izquierda, mano derecha, movimiento de pies o apretón de mandíbula / movimiento de lengua. Esta pista sobre la VM es elegida por el sistema de forma aleatoria, una a la vez, y consiste en una imagen inanimada y opaca que hace alusión a la VM. En la figura 5.4 se presentan todas las pistas que se utilizaron dentro de la interfaz de toma de muestras.




Figura 5.4. Pistas de cada VM dentro de la interfaz para toma de muestras.

En seguida ($t=3.6$), la pista correspondiente a la VM toma animación y muestra un patrón que guía al sujeto de prueba a realizar la acción mental. Por ejemplo, en el caso de la mano izquierda y mano derecha se utilizó el proceso de VM como en [29], donde el sujeto de prueba debe visualizar que su dedo pulgar toca individualmente cada uno de los dedos de la mano correspondiente, comenzando con el dedo meñique, luego anular, medio, índice; todo dentro de un lapso de 3.4 segundos. Para ello se grabó un pequeño video realizando el movimiento sugerido, se editó y se convirtió en formato gif. En el caso del apretón de mandíbula / movimiento de lengua se utilizó una animación que muestra el movimiento de mandíbula, un proceso similar al que se realiza al masticar. El último caso de VM son los pies, para los cuales se utilizó otra animación donde se observa una persona en bicicleta y se pretende que el sujeto de prueba relacione dicho movimiento (pedaleo) con la visualización a llevar a cabo. En la figura 5.5 se observa una captura de las VM que el sujeto de prueba debe llevar a cabo.




Figura 5.5. Animaciones de cada VM dentro de la interfaz para toma de muestras.

Después de registrar 850 muestras correspondientes a cada VM, en ($t=7$), se da un segundo de descanso mostrando la pantalla de la figura 5.3, la cual se concatena con los dos segundos del siguiente ensayo para tomar muestras para la nueva VM. Como se mencionó anteriormente, cada sesión consta de 12 VM de cada clase las cuales aparecen aleatoriamente en la toma de muestras dando un total de 48 ensayos.

De tal manera que cada sesión se compone de 111,001 muestras, de las cuales 96,000 corresponden a los 48 ensayos (2,000 muestras por ensayo) y el resto (15,001 muestras) corresponde a 60.004 segundos de actividad cerebral cuando el sujeto ya no estaba concentrado ni realizando visualizaciones motoras.

Al concluir el registro de la actividad cerebral se completa la base de datos y se está en condiciones de implementar las etapas de clasificación propuestas en la metodología de CSP+CWT+CNN. Esta metodología comienza con la preparación de los datos, acondicionándolos a la extracción de características mediante el preprocesamiento, extracción de épocas y aumento de datos.

5.3 Preprocesamiento

Cada sujeto de prueba realizó las sesiones en diferentes días, de acuerdo con su disponibilidad, como se muestra en la tabla 5.1.

Tabla 5.1. Distribución de las sesiones para toma de muestras realizadas por los sujetos de prueba.

Sujeto(s) / Día (D)	D ₁	D ₂	D ₃	D ₄	D ₅	D ₆	Total de sesiones
S ₁	6	6					12
S ₂	6	3	3				12
S ₃	4	4	4				12
S ₄	6	6					12
S ₅	4	4	4				12
S ₆	6		6				12
S ₇	3	3	3	3			12
S ₈	2	6	4				12
S ₉	1	2	2	3	2	2	12
S ₁₀	2	4	3	1	1	1	12
S ₁₁	3	2	4	3			12
S ₁₂	4	1	2	2	2	1	12
S ₁₃	6	6					12
S ₁₄		3	2	3	4		12
S ₁₅	4	4	4				12

Para hacer referencia a una muestra en específico (n) se selecciona el sujeto Φ , la sesión Δ , el ensayo Ξ y el canal (Ch) o electrodo utilizado

$$STR_{\Phi, \Delta, \Xi}^{Ch}(n) \quad \Phi = 1, 2, \dots, 15, \quad \Delta = 1, 2, \dots, 12, \quad \Xi = 1, 2, \dots, 48 \quad n = 1, 2, \dots, 2000 \quad (5.3)$$

De los 48 ensayos por sesión, 12 corresponden a VM de la mano izquierda, 12 a VM de la mano derecha, 12 a VM de los pies y 12 a VM de apretón de mandíbula.

Todos los ensayos de cada una de las sesiones se concatenaron acomodándolos cronológicamente para formar una sola señal, desde el primer ensayo de la primera sesión hasta el último ensayo de la última sesión

$$Xraw_{\Phi}^{Ch}(n_{nueva}) = STR_{\Phi, \Delta, \Xi}^{Ch}(n) \quad (5.4)$$

$$n_{nueva} = (n)(\Xi) + (\Delta - 1)(96,000), \quad n_{nueva} \in \square^{1 \times N_{nueva}}$$

donde $N_{nueva}=1,152,000$ y $Xraw_{\Phi}^{Ch}(n_{nueva}) \in \mathbb{R}^{Ch \times N_{nueva}}$ que es la señal discreta que contiene los N_{nueva} datos crudos del EEG de cada canal Ch , obtenidos a una frecuencia de muestreo de 250 Hz de cada sujeto Φ .

La señal $Xraw_{\Phi}^{Ch}(n_{nueva})$ se filtró mediante un filtro digital pasa-bandas tipo IIR Butterworth de quinto orden, asignando las frecuencias de corte respectivas para mu y beta, de 8 a 30Hz

$$H(\omega): Xraw_{\Phi}^{Ch}(n_{nueva}) \rightarrow Xfilt_{\Phi}^{Ch}(n_{nueva}) \in \mathbb{R}^{Ch \times N_{nueva}} \quad (5.5)$$

donde $Xfilt_{\Phi}^{Ch}(n_{nueva})$ es la señal discreta filtrada que contiene la información de cada EEG de cada canal por sujeto.

5.4 Extracción de épocas y aumento de datos

Se define una época como en (3.3) mediante

$$\begin{aligned} Xep_{\Phi}^{Ch}(k) &= Xfilt_{\Phi}^{Ch}(q_{ep} + k + inc) \quad ep = 1, 2, \dots, 4p ; \quad k = 1, 2, \dots, 2Fs \\ Xep_{\Phi}^{Ch}(k) &\in \mathbb{R}^{Ch \times p \times 2Fs} \end{aligned} \quad (5.6)$$

donde inc también varía como en (3.4) y $p=144$ ya que la cantidad de ensayos realizados es la misma a la base de datos *BCI Competition IV dataset 2a*. Esto genera un total de $10p$ épocas para cada VM.

De igual manera que con las bases de datos del capítulo 3, las épocas resultantes se dividieron en dos partes: $8p$ épocas de VM que representan el 80% destinado para la etapa de entrenamiento y el restante 20%, $2p$ épocas de VM, para la validación.

5.5 Extracción de características mediante CSP₆+CWT

Utilizando las filas $fil = \{1, 2, 3, 6, 7, 8\}$ del filtro espacial $W_{CSP} \in \mathbb{R}^{8 \times 8}$ generado mediante CSP (ver sección 3.4.1), se hace la transformación para cada época de entrenamiento

$$\mathbf{Z}_{CSP}^{fil}(k) = [W_{CSP}^{fil}]^T [Xep(k)], \quad \mathbf{Z}_{CSP}^{fil}(k) \in \mathbb{R}^{6 \times 2Fs \times 8p} \quad (5.7)$$

Después, se aplica la transformada Wavelet continua de la matriz generada por CSP

$$\mathbf{Z}_{CSP_CWT}^{fil,Es}(k) = abs\left(CWT\left\{\mathbf{Z}_{CSP}^{fil}(k)\right\}\right) \quad (5.8)$$

Como se utilizó el método CSP₆+CWT para extracción de características es necesario concatenar las matrices resultantes de la CWT de cada fila, generando una sola matriz

$$\begin{aligned} \mathbf{Q}_{CSP_CWT}(i, k) &= \mathbf{Z}_{CSP_CWT}^{j, [i-(j-1)*Es]}(k) \quad \mathbf{Q}_{CSP_CWT} \in \mathbb{R}^{6Es \times 2Fs \times 8p} \\ i &= 1, 2, \dots, 6Es \\ j &= \begin{cases} 1 & 0 < i \leq Es \\ 2 & Es < i \leq 2Es \\ 3 & 2Es < i \leq 3Es \\ 4 & 3Es < i \leq 4Es \\ 5 & 4Es < i \leq 5Es \\ 6 & 5Es < i \leq 6Es \end{cases} \end{aligned} \quad (5.9)$$

El último paso antes de entrenar la red CNN es aplicar la interpolación bicúbica para reducir la dimensión de la matriz que representa la entrada de la red

$$INT\left[\mathbf{Q}_{CSP_CWT}\right] \rightarrow I_{CSP_CWT} \in \mathbb{R}^{22 \times 100 \times 8p} \quad (5.10)$$

5.6 Implementación del esquema modular de red CNN

Después de obtener las matrices de entrada para las redes CNN, se utilizó el esquema modular presentado en la sección 4.2, que fue el que presentó mejores desempeños al evaluarlo con la base de datos *BCI Competition IV dataset 2a*.

Para ello, se entrenaron los clasificadores de dos clases de VM utilizando la arquitectura de red CNN presentada en la sección 3.5.2 en la figura 3.15.

Utilizando el promedio de los resultados obtenidos con validación cruzada, se tiene que para la etapa de entrenamiento hay un desempeño de todos los sujetos del $90.5 \pm 5.35\%$ como se muestra en la tabla 5.2 De igual manera, para la etapa de validación se obtuvo un desempeño del $84.99 \pm 6.24\%$ como se presenta en la tabla 5.3.

Tabla 5.2. Resultados del entrenamiento de los clasificadores CNN de 2 VM por sujeto.

ENTRENAMIENTO									
Sujeto / VM	Izq vs Der	Izq vs Pie	Izq vs Len	Der vs Pie	Der vs Len	Pie vs Len	Si vs No	Promedio	Mejor clasificador de VM por sujeto
S8	0.924	0.919	0.970	0.932	0.967	0.948	0.969	0.9470	Izq vs Len
S10	0.956	0.971	0.900	0.985	0.973	0.946	0.891	0.9460	Der vs Pie
S1	0.935	0.944	0.955	0.935	0.971	0.954	0.914	0.9440	Der vs Len
S14	0.901	0.931	0.949	0.929	0.917	0.953	0.968	0.9354	Pie vs Len
S11	0.965	0.931	0.962	0.961	0.893	0.966	0.824	0.9289	Pie vs Len
S2	0.955	0.929	0.928	0.913	0.963	0.960	0.801	0.9213	Der vs Len
S3	0.972	0.835	0.893	0.881	0.958	0.923	0.947	0.9156	Izq vs Der
S13	0.899	0.895	0.928	0.939	0.902	0.910	0.928	0.9144	Der vs Pie
S9	0.961	0.879	0.885	0.904	0.883	0.962	0.889	0.9090	Izq vs Der
S7	0.891	0.973	0.950	0.909	0.817	0.788	0.845	0.8819	Izq vs Pie
S15	0.900	0.899	0.832	0.912	0.935	0.884	0.775	0.8767	Der vs Len
S4	0.949	0.917	0.826	0.850	0.760	0.938	0.831	0.8673	Izq vs Der
S6	0.927	0.901	0.907	0.830	0.892	0.913	0.682	0.8646	Izq vs Der
S5	0.839	0.935	0.865	0.902	0.712	0.895	0.898	0.8637	Izq vs Pie
S12	0.965	0.805	0.754	0.919	0.874	0.921	0.776	0.8591	Izq vs Der
Promedio	0.9293	0.9109	0.9003	0.9134	0.8945	0.9241	0.8625	0.9050	Izq vs Der
STD	0.0360	0.0439	0.0584	0.0378	0.0758	0.0438	0.0790	0.0535	

Tabla 5.3. Resultados de la validación los clasificadores CNN de 2 VM por sujeto.

VALIDACIÓN									
Sujeto / VM	Izq vs Der	Izq vs Pie	Izq vs Len	Der vs Pie	Der vs Len	Pie vs Len	Si vs No	Promedio	Mejor clasificador de VM por sujeto
S10	0.899	0.953	0.887	0.963	0.948	0.892	0.866	0.9154	Der vs Pie
S8	0.888	0.884	0.946	0.917	0.943	0.895	0.923	0.9137	Izq vs Len
S1	0.882	0.928	0.932	0.900	0.946	0.900	0.874	0.9089	Der vs Len
S11	0.907	0.854	0.934	0.901	0.872	0.900	0.802	0.8814	Izq vs Len
S14	0.823	0.868	0.897	0.872	0.857	0.887	0.960	0.8806	Izq vs Len
S3	0.902	0.795	0.853	0.840	0.906	0.857	0.910	0.8661	Der vs Len
S2	0.891	0.874	0.882	0.848	0.909	0.907	0.738	0.8641	Der vs Len
S9	0.898	0.830	0.836	0.870	0.846	0.872	0.855	0.8581	Izq vs Der
S13	0.788	0.834	0.846	0.872	0.822	0.832	0.856	0.8357	Der vs Pie
S7	0.792	0.952	0.933	0.855	0.795	0.712	0.767	0.8294	Izq vs Pie
S12	0.920	0.768	0.731	0.877	0.837	0.842	0.733	0.8154	Izq vs Der
S4	0.895	0.843	0.774	0.792	0.700	0.856	0.780	0.8057	Izq vs Der
S15	0.815	0.822	0.749	0.830	0.843	0.771	0.731	0.7944	Der vs Len
S5	0.760	0.849	0.782	0.818	0.669	0.802	0.868	0.7926	Izq vs Pie
S6	0.841	0.819	0.835	0.744	0.789	0.820	0.663	0.7873	Izq vs Der
Promedio	0.8601	0.8582	0.8545	0.8599	0.8455	0.8497	0.8217	0.8499	Izq vs Der
STD	0.0500	0.0519	0.0680	0.0511	0.0806	0.0534	0.0815	0.0624	

En las tablas anteriores se utilizaron los dos códigos de colores presentados en la sección 4.2.1, pero ahora la escala abarca 15 tonalidades distintas, en el caso del código de colores de desempeños, como se muestra en la figura 5.6.



Figura 5.6. Escala para evaluar desempeños, del más alto (verde o número 1) al más bajo (rojo o número 15).

El código de colores de la figura anterior se implementó por columna (abarcando las 15 filas que incluyen todos los sujetos de prueba) en los diferentes tipos de clasificadores de 2 VM para indicar cuál sujeto fue el que obtuvo mejor desempeño en dicho clasificador y quién fue el que salió con más bajo desempeño. Por ejemplo, en el caso del clasificador “Izq vs Der” el sujeto con mejor desempeño en la etapa de validación fue s_{12} y el más bajo fue s_5 .

En el caso de las filas de “promedio” y “STD” de las tablas 5.2 y 5.3 se implementó el mismo código de la figura 5.6, para dar a conocer cuál clasificador de 2 VM fue el mejor y cuál la menor desviación estándar. Resultando ganador en la etapa de validación el clasificador “Izq vs Der” con $86.01 \pm 5\%$ y perdedor el clasificador “Sí vs No” con $82.17 \pm 8.15\%$.

Con las redes CNN entrenadas se da paso a la implementación del esquema modular, para el cual se eligieron los parámetros de entrenamiento de los desempeños de validación más altos obtenidos en validación cruzada.

Para probar el sistema se generó un conjunto de VM de la base de datos adquirida, incluyendo 432 VM de cada clase y se obtuvieron los resultados que se muestran en la tabla 5.4.

Se puede observar que todos los sujetos tuvieron un mejor desempeño de clasificación al utilizar el algoritmo sgSM en comparación con utilizar solamente la moda. Además, el promedio general del esquema modular al utilizar sólo la moda fue del $82.98\% \pm 5.98\%$ y con la sgSM fue de $86.48\% \pm 4.74\%$. Además, se incluye el coeficiente kappa con un promedio de 0.8198 ± 0.0632 .

Tabla 5.4. Resultados del esquema modular utilizando la moda, sgSM y coeficiente kappa.

Sujeto	Moda	sgSM	Kappa de sgSM
S ₁₀	92.13%	93.63%	0.9151
S ₈	90.05%	92.65%	0.9020
S ₁	89.81%	91.84%	0.8912
S ₁₁	89.81%	91.61%	0.8881
S ₂	87.04%	89.58%	0.8611
S ₉	84.32%	88.31%	0.8441
S ₁₄	85.13%	87.73%	0.8364
S ₃	81.83%	86.00%	0.8133
S ₇	82.29%	84.43%	0.7924
S ₁₃	80.67%	84.43%	0.7924
S ₁₂	77.78%	84.38%	0.7917
S ₁₅	76.39%	81.94%	0.7593
S ₄	78.65%	81.48%	0.7531
S ₅	76.45%	80.67%	0.7423
S ₆	72.40%	78.53%	0.7137
Promedio	82.98%	86.48%	0.8197
STD	5.98%	4.74%	0.0632

Una vez que se implementó la metodología CSP₆+CWT+CNN y se hizo la prueba con el esquema modular, se procedió al diseño de la aplicación en tiempo real donde se utilizan estas herramientas para extracción de características y clasificación de visualizaciones motoras en un ambiente virtual.

Es importante señalar que las pruebas de la aplicación BCI en tiempo real la realizaron un total de 8 sujetos, seleccionados como los primeros 5 lugares y los últimos 3 lugares en desempeño en la etapa de validación de los clasificadores de 2 VM (ver tabla 5.3). Se buscó que los 15 sujetos de prueba participaran, pero desafortunadamente no pudieron por causas de disponibilidad por lo que se optó por los 8 que sí tenían oportunidad y que permitieron generar el esquema de trabajo que ayudara a evaluar el sistema con los mejores y peores lugares en los clasificadores generales.

De tal manera que los sujetos que pudieron participar son S₁, S₅, S₆, S₈, S₁₀, S₁₁, S₁₄ y S₁₅. Aun cuando la selección de estos sujetos fue por disponibilidad, representan los mejores y peores lugares en los clasificadores generales, incluyendo la clasificación Sí vs No VM, que es un

indicador importante para determinar si el sujeto puede ser o no apto para el uso de un sistema BCI [55].

5.7 Conclusiones del capítulo

En este capítulo se abordó lo referente al diseño y registro de una base de datos con 15 sujetos de prueba donde se consideraron factores como el dispositivo OpenBCI para obtener el EGG de cada sujeto, la cantidad de electrodos a utilizar y el posicionamiento en el cuero cabelludo de acuerdo con el sistema internacional 10-20, los electrodos de tierra y referencia, así como el protocolo propuesto para la etapa de entrenamiento del sistema ante las visualizaciones motoras.

La base de datos registra 4 tipos de VM: mano izquierda, mano derecha, movimiento de pies y apretón de mandíbula. Por lo que se generó una interfaz gráfica que ayudara en el esquema de tiempo para detectar cada una de las VM y registrar la información en una base de datos. Cada sujeto efectuó 12 sesiones con 12 ensayos cada una, con un total de 144 VM de cada clase. Una cantidad suficiente, como en la base de datos *BCI Competition IV dataset 2a*, para entrenar las redes CNN e implementar la metodología.

Se propuso esquema visual que se basa en el paradigma de Graz para el registro de cada VM. Para ello se tienen animaciones de cada VM que proponen estimular la visualización de los sujetos de prueba y acotar el tipo de visualización. Es decir, en lugar de que un sujeto tenga la puerta abierta para efectuar cualquier tipo de visualización con la mano derecha como puede ser el movimiento de la misma, apretándola, tomando una pelota, saludando a una persona, entre otras, se acotó a un protocolo específico. De igual manera para la mano izquierda, pies y apretón de mandíbula.

Esto da como resultado una base de datos completa, con suficientes sujetos de prueba e información que fue revisada para eliminar datos erróneos o ruido excesivo en las señales, lo que dio paso al entrenamiento de las redes neuronales convolucionales, extrayendo características con CSP₆+CWT e implementando el esquema modular con sgSM.

Una vez que se finalizaron los entrenamientos, evaluaciones y pruebas de la metodología de clasificación se obtuvo un desempeño promedio del $86.48\% \pm 4.74\%$ de toda la base de datos

(con los 15 sujetos de prueba) y un coeficiente kappa del 0.8198 ± 0.0632 (ver tabla 5.4), lo que lo posiciona como superior a los trabajos reportados en [24], [32], [49], [50] y [51] los cuales también utilizaron 4 VM evaluadas de 9 sujetos de prueba (*BCI Competition IV dataset 2a*), cuando en este caso se utilizaron también 4 VM pero de 15 sujetos.

CAPÍTULO 6.

6. APLICACIÓN BCI EN TIEMPO REAL

En este capítulo se presenta el procedimiento utilizado para implementar en tiempo real la metodología propuesta, así como las interfaces diseñadas para la evaluación de clasificación de VM en un ambiente virtual.

6.1 Implementación de la metodología en tiempo real

Para utilizar la metodología de clasificación en tiempo real, se utilizó el esquema mostrado en la figura 6.1




Figura 6.1. Esquema para implementar metodología en tiempo real.

En la figura 6.1 se observa que el esquema en tiempo real que se lleva a cabo es tipo *pipeline*, en el que se toma una primera ventana de muestras de 2 segundos y cuando comienza la etapa de procesamiento, la cual dura 270 ms, el sistema sigue tomando muestras almacenándolas en un buffer. De tal manera que la primera salida sí es secuencial, tomando un tiempo de 2.27 segundos, pero de ahí en adelante las salidas serán cada 2 segundos.

Este esquema implementado utiliza ventanas de 2 segundos como en la metodología propuesta, asegurando que la VM esté presente. Además, se trató que no hubiera tanto traslape

entre ventanas ya que esto repercute en la correcta clasificación de las VM y baja el desempeño del sistema en tiempo real.

En la tabla 6.1 se presentan las características de los equipos de cómputo en los que se probó la metodología propuesta en tiempo real y en todos ellos se mantuvo el esquema de tiempo propuesto en la figura 6.1.

Tabla 6.1. Características de los equipos de cómputo para pruebas de interfaz en tiempo real.

Característica / Equipo	Equipo 1	Equipo 2	Equipo 3
Sistema operativo	Windows 10 Pro x64 bits		
Procesador	Intel® Xeon® E5-1620 v3 3.50GHz	Intel® Core™ i7-6820HQ 2.70GHz	Intel® Core™ i7-6820HQ 2.70GHz
Memoria RAM	16 GB, 2133 MHz	16 GB, 2133 MHz	16 GB, 2133 MHz
Almacenamiento	SSD		
GPU	NVIDIA GeForce GTX 970	NVIDIA Quadro M1000M	NVIDIA GeForce GTX 970M

Una vez que se implementó la metodología en tiempo real y se tenía el equipo de cómputo para realización de pruebas, se diseñaron 4 escenarios de ambiente virtual para la clasificación de las diferentes VM, generando una etapa de entrenamiento y 3 niveles con diferentes escenarios interactivos.

6.2 Escenarios virtuales para evaluar la metodología en tiempo real

Los escenarios se diseñaron con la intención de aumentar el nivel de dificultad y de respuesta del sujeto de prueba, sometiéndolo a diferentes niveles de estrés y adrenalina por querer superar el mini juego. De tal manera que se tiene un total de 4 escenarios: escenario de entrenamiento, escenario nivel 1: baño, escenario nivel 2: autopista y escenario nivel 3: carritos.

Los escenarios están acomodados de menor a mayor nivel, por lo que en el escenario de entrenamiento no se evalúa ninguna métrica, sólo es un escenario para que el sujeto de prueba se acostumbre a la aplicación en tiempo real. En el escenario nivel 1, el sujeto debe realizar una serie de VM que ya están establecidas, es decir, siempre que se juegue en ese escenario serán las mismas VM en el mismo orden por lo que es el escenario de menor dificultad. En el caso del nivel 2, las VM siempre varían, lo que aumenta el grado de dificultad ya que el sujeto tiene que responder ante VM que pide el sistema de manera aleatoria. En los niveles 1 y 2 los sujetos

de prueba pueden equivocarse o realizar VM erróneas y esto repercutirá sólo en que el tiempo establecido para cumplir el objetivo del minijuego será mayor, pero se podrá seguir participando. Sin embargo, el escenario del nivel 3 es el más difícil, porque con una mala clasificación de VM, ya sea por error del sujeto o mal entrenamiento de las redes CNN, el juego habrá terminado, lo que hace ver la dificultad y la precisión que exige.

6.2.1 Escenario de entrenamiento

En este escenario se buscó simular el ambiente de la etapa de entrenamiento de los sujetos cuando fue la toma de muestra por lo que el fondo, animaciones y elementos son muy similares. El escenario en condiciones iniciales se muestra en la figura 6.2.




Figura 6.2. Escenario de entrenamiento dentro de la interfaz BCI para tiempo real en condiciones iniciales.

El sistema arroja una respuesta cada 270 ms, como se observa en la parte inferior izquierda de la figura 6.3, indicándole al sujeto de prueba qué clase de VM se está detectando. Además, si el sujeto necesita ayudas visuales para realizar la VM se pueden mostrar las animaciones de las VM utilizadas dentro del protocolo de muestras.

Con base en dichas animaciones de las VM se pensó en implementar un panel que mostrara cada una de las VM por separado. Este panel aparece en cada uno de los escenarios virtuales y funge como ayuda visual para que los sujetos de prueba puedan realizar las VM como en la etapa de entrenamiento.




Figura 6.3. Ayudas visuales en el escenario de entrenamiento y detección de la mano izquierda en el escenario de entrenamiento.

Para ello se generó un *script* que muestra la ventana o panel con la VM que se le pide al sujeto de prueba que realice de acuerdo con cada uno de los minijuegos. Cada una de las ventanas se presentan en la figura 6.4.




Figura 6.4. Ventanas de ayuda visual (panel visual) para su uso en los diversos escenarios virtuales.

Con las ventanas de ayuda visual se está en condiciones de generar los demás escenarios virtuales.

6.2.2 Escenario nivel 1: baño

Este escenario representa el nivel 1 de dificultad dentro del entorno virtual y consiste en colocar la secadora en el espacio correspondiente. Para ello, la mano azul posicionada en la

parte izquierda del escenario (ver figura 6.5) debe moverse hacia la derecha, tomar la secadora, regresarla y soltarla. Además, se agregó una serie de indicadores, que representan LEDs verdes, para que el jugador esté consciente de cuántas VM le faltan para completar cada una de las 4 tareas.




Figura 6.5. Escenario nivel 1: baño en condiciones iniciales.

Consecuentemente, para este escenario, se le pide al sujeto que ejecute 10 VM de cada clase y se realizan de la siguiente manera. Primero se deben ejecutar 10 VM de la mano derecha para que la mano se mueva en la dirección adecuada, es decir, que vaya por la secadora, como se muestra en la figura 6.6. Después, cuando la mano llega a la posición de la secadora, es necesario “levantarla” virtualmente. Para ello se pide que el jugador ejecute 10 VM de la mandíbula como se muestra en la figura 6.7. Aparece también el panel de ayuda visual, asumiendo que el sujeto necesite de dicha herramienta.

Una vez que la secadora ha sido levantada, se debe mover hacia el hueco o dibujo en gris que representa la secadora, como se observa en la figura 6.8. Por tal motivo, se deben realizar 10 VM de la mano izquierda que moverán la mano junto con la secadora hacia el lugar deseado.

Finalmente, para terminar las tareas de este escenario virtual, se debe soltar la secadora realizando 10 VM de los pies, como se aprecia en la imagen de la figura 6.9.




Figura 6.6. Escenario nivel 1: baño, después de que el sujeto de prueba ejecutó 9 VM de la mano derecha.




Figura 6.7. Escenario nivel 1: baño, después de haber ejecutado 10 VM de la mano derecha y 8 VM de la mandíbula.




Figura 6.8. Escenario nivel 1: baño, después de haber ejecutado 10 VM de la mano derecha, 10 VM de la mandíbula y 8 VM de la mano izquierda.




Figura 6.9. Escenario nivel 1: baño, después de completar el escenario virtual.

Cada una de las VM se evalúa siguiendo el esquema de tiempos de la figura 6.1, por lo que, en promedio, al ser 10 VM de cada clase el objetivo sería completar el escenario nivel 1 en 80 segundos. Sin embargo, como existen 3 cambios entre VM, se agrega este margen de error de visualizaciones motoras como tolerancia del sistema.

De tal manera que se considera que el ideal es que el sujeto realice 43 VM y como son 2 segundos entre VM, se tiene un tiempo de 86 segundos como mínimo para completar este escenario. Es decir, si un sujeto completa el escenario en un promedio de 86 segundos, entonces el sistema habrá detectado cada VM con precisión perfecta. En cambio, si el sujeto comete errores, es decir, se pide una VM en específico y se está ejecutando o detectando otra diferente, esto hará que el tiempo en el que se realice el escenario virtual sea mayor y por lo tanto el desempeño del sistema será más bajo.

El tiempo que tardó el jugador en completar el escenario se muestra en la parte central de la derecha, como se aprecia en la figura 6.9.

6.2.3 Escenario nivel 2: autopista

El siguiente escenario que se implementó se denominó “autopista” y consiste en dar una vuelta a la autopista moviendo el carrito desde el punto de partida hasta la meta señalada como se observa en la figura 6.10.




Figura 6.10. Escenario nivel 2: autopista en condiciones iniciales.

Para ello, es necesario realizar 20 VM, 5 de cada clase, que aparecen aleatoriamente. Además, se puede o no utilizar el panel visual, por ejemplo, en el caso de la figura 6.11 se ejemplifica cuando el sujeto no ha necesitado del panel de ayuda visual y está completando las visualizaciones motoras que se le piden, logrando que el carrito avance por la autopista.




Figura 6.11. Escenario nivel 2: autopista, ejemplificando que el usuario no necesita el panel de ayuda visual.

Al igual que el escenario anterior, se tiene un tiempo establecido para completar el escenario con un desempeño perfecto de 46 segundos.

6.2.4 Escenario nivel 3: carritos

El último escenario se muestra en la figura 6.12 y consiste en el clásico minijuego de esquivar carritos moviendo el carrito principal a la izquierda o a la derecha. En esta ocasión, sólo se utilizan 2 VM, las cuales se escogieron al analizar la tabla 5.3, seleccionando el clasificador de 2 VM que tuvo el mejor desempeño por cada sujeto. Por ejemplo, en el caso de la figura 6.12, el clasificador con mejor desempeño para el sujeto de ejemplo fue aquel que discrimina entre VM de la mano izquierda y VM de los pies. En la figura 6.13 se presenta el caso en el cual el jugador debe realizar la VM que ayude a mover el carro principal (rojo) en la dirección contraria al carro que se aproxima para chocarlo. En este ejemplo debe realizar una VM de la mano izquierda. Sin embargo, si el sujeto realiza mal la VM o si el sistema la clasifica como errónea, entonces los carros chocarán y el minijuego habrá terminado, como se muestra en la figura 6.14. Esta es la dificultad del minijuego, pues no se tiene margen de error y por eso se colocó como en el nivel 3, ya que el sistema debe estar detectando correctamente todas las VM para que el carro principal pueda esquivar los carritos que buscan chocarlo. Con un error, el juego habrá terminado.




Figura 6.12. Escenario nivel 3: carritos en condiciones iniciales cuando el sujeto seleccionado posee un clasificador de VM de mano izquierda contra VM de los pies.




Figura 6.13. Escenario nivel 3: carritos, ejemplificando que el sujeto debe realizar VM de la mano izquierda para esquivar el auto que se aproxima.




Figura 6.14. Escenario nivel 3: carritos, ejemplo de choque entre carritos cuando el sujeto realizó mal la VM o el sistema la detectó como errónea.

Esto permite evaluar la eficiencia del sistema para estar detectando correctamente las VM y se asignó un objetivo de 20 carritos consecutivos para esquivar. Es decir, si el jugador logra esquivar todos los carritos, el sistema habrá detectado las VM con precisión perfecta.

6.3 Métricas de evaluación de la aplicación BCI en tiempo real

Las pruebas BCI en tiempo real las realizaron 8 sujetos: s_{10} , s_8 , s_1 , s_{11} , s_{14} , s_{15} , s_6 y s_5 con la finalidad de abarcar sujetos de prueba con desempeños altos, medios y bajos de acuerdo con los resultados reportados en el esquema modular de la tabla 5.4.

Para evaluar los diferentes niveles dentro de la interfaz BCI en tiempo real se proponen dos métricas: una cuantitativa, que compara tiempos, desempeños y eficiencia, y otra cualitativa, que considera el factor humano.

6.3.1 Resultados generales

En este apartado se presentan los resultados generales en donde cada uno de los sujetos de prueba seleccionados realizó 3 pruebas en cada escenario virtual.

En el caso de los niveles 1 (ver tabla 6.2) y 2 (ver tabla 6.3) se registraron las marcas de tiempo de cada una de las pruebas y se calculó el promedio de los tiempos de cada sujeto.

Tabla 6.2. Resultados del nivel 1 del sistema BCI en tiempo real.

Escenario baño → Nivel 1 (tiempo en segundos)				
Sujeto	Prueba 1	Prueba 2	Prueba 3	Promedio
S ₈	162.7	140.7	138.7	147.4
S ₁₀	176.7	178.7	176.7	177.4
S ₁₁	220.5	208.7	190.6	206.6
S ₁	288.4	232.5	226.5	249.1
S ₁₄	346.6	310.6	332.5	329.9
S ₁₅	358.2	280.4	352.1	330.2
S ₆	482.2	452.2	290.5	408.3
S ₅	508.3	490.3	450.2	482.9

Tabla 6.3. Resultados del nivel 2 del sistema BCI en tiempo real.

Escenario autopista → Nivel 2 (tiempo en segundos)				
Sujeto	Prueba 1	Prueba 2	Prueba 3	Promedio
S ₁₀	60.2	68.2	78.1	68.8
S ₈	88.1	70.1	74.1	77.5
S ₁	136.1	108.1	114.1	119.4
S ₁₁	158.0	98.1	150.0	135.4
S ₁₅	197.8	110.2	223.9	177.3
S ₁₄	198.0	182.0	174.0	184.7
S ₆	158.0	204.0	200.0	187.3
S ₅	245.9	194.0	160.0	200.0

En la tabla 6.2 se observa que el sujeto ganador fue *s₈* con un tiempo promedio de 147.4 segundos, lo que significa que utilizó aproximadamente 30 VM más para completar el minijuego del nivel 1 al excederse por alrededor de 60 segundos de acuerdo con el tiempo mínimo de 86 segundos para lograr el objetivo.

Se puede observar que los tiempos en el escenario del nivel 1 son mayores a los del nivel 2. Esto se debe a que es mayor la cantidad de VM que los sujetos de prueba deben realizar, en unión a que se tenía menor experiencia y control de las VM a detectar por el sistema BCI en tiempo real.

Sin embargo, un punto importante a señalar es que todos los sujetos que participaron en este escenario completaron la prueba, aun cuando el tiempo fuera prolongado como en el caso del sujeto *s₅*. De manera similar, la tabla 6.3 presenta los tiempos registrados al evaluar el escenario

autopista. En este caso las VM aparecen de manera aleatoria y fue el sujeto s_{10} quien ganó en este minijuego y también es el ganador del esquema modular.

En la prueba 1 del sujeto s_{10} se registró el menor tiempo y sólo se excede en 14 segundos de un tiempo perfecto de 46 segundos, lo que corresponde a haber realizado 7 VM más de lo que se pedían o a que el sistema no las clasificó correctamente. Por otra parte, en la tabla 6.4 se muestran los resultados al evaluar el escenario carritos de nivel 3.

Tabla 6.4. Resultados del nivel 3 del sistema BCI en tiempo real.

Escenario carritos → Nivel 3 (número de carritos superados)					
Sujeto	Prueba 1	Prueba 2	Prueba 3	Promedio	VM
s_{10}	10	8	19	12.33	Der vs Pie
s_1	3	6	20	9.67	Der vs Len
s_8	6	6	10	7.33	Izq vs Len
s_{14}	6	5	6	5.67	Izq vs Len
s_{11}	3	4	5	4.00	Izq vs Len
s_{15}	3	4	3	3.33	Der vs Len
s_5	2	3	3	2.67	Izq vs Pie
s_6	1	1	2	1.33	Izq vs Der

En promedio, nuevamente ganó el sujeto s_{10} ya que el sistema clasifica correctamente alrededor de 12 VM de manera consecutiva para dicho sujeto. Sin embargo, sólo el sujeto s_1 logró completar el minijuego con una clasificación perfecta al esquivar los 20 carritos propuestos.

De manera general, cada uno de los sujetos de prueba fue mejorando sus tiempos o al menos los mantuvo, al participar en cada uno de los escenarios virtuales. Esto es prometedor, ya que se plantea que los sujetos de prueba van aprendiendo o se van entrenando en sus VM para que el sistema BCI responda cada vez con mayor acierto y precisión.

6.3.2 Resultados individuales

En las tablas 6.5 a 6.12 se presentan los resultados individuales en las pruebas de nivel 1 y de nivel 2 en donde **RH** representa VM de la mano derecha, **JC** de la mandíbula, **LH** de la mano izquierda y **FT** de los pies.

Tabla 6.5. Resultados de los niveles 1 y 2 del sujeto s₁₀.

s ₁₀							
Escenario Baño → Nivel 1						Escenario Autopista → Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	58.82%	35.71%	38.46%	55.56%	47.14%	Prueba 1	66.49%
Prueba 2	90.91%	27.78%	32.26%	83.33%	58.57%	Prueba 2	58.69%
Prueba 3	90.91%	40.00%	24.39%	83.33%	59.66%	Prueba 3	51.19%
Desempeño de VM	80.21%	34.50%	31.70%	74.07%	55.12%	Desempeño de VM	58.79%
VM utilizadas cuando el mínimo es 10	12	29	32	14	18	VM utilizadas cuando el mínimo es 20	34

Tabla 6.6. Resultados de los niveles 1 y 2 del sujeto s₈.

s ₈							
Escenario Baño → Nivel 1						Escenario Autopista → Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	83.33%	90.91%	100.00%	20.41%	73.66%	Prueba 1	45.40%
Prueba 2	71.43%	50.00%	100.00%	37.04%	64.62%	Prueba 2	57.03%
Prueba 3	90.91%	43.48%	83.33%	41.67%	64.85%	Prueba 3	53.96%
Desempeño de VM	81.89%	61.46%	94.44%	33.04%	67.71%	Desempeño de VM	52.13%
VM utilizadas cuando el mínimo es 10	12	16	11	30	15	VM utilizadas cuando el mínimo es 20	38

Tabla 6.7. Resultados de los niveles 1 y 2 del sujeto s₁.

s ₁							
Escenario Baño --> Nivel 1						Escenario Autopista --> Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	43.48%	28.57%	66.67%	13.89%	38.15%	Prueba 1	29.39%
Prueba 2	47.62%	32.26%	45.45%	23.26%	37.15%	Prueba 2	37.00%
Prueba 3	34.48%	50.00%	43.48%	23.81%	37.94%	Prueba 3	35.06%
Desempeño de VM	41.86%	36.94%	51.87%	20.32%	37.75%	Desempeño de VM	33.82%
VM utilizadas cuando el mínimo es 10	24	27	19	49	26	VM utilizadas cuando el mínimo es 20	59

Tabla 6.8. Resultados de los niveles 1 y 2 del sujeto s₁₁.

s ₁₁							
Escenario Baño --> Nivel 1						Escenario Autopista --> Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	45.45%	23.26%	55.56%	35.71%	40.00%	Prueba 1	25.32%
Prueba 2	38.46%	37.04%	45.45%	33.33%	38.57%	Prueba 2	40.77%
Prueba 3	76.92%	31.25%	47.62%	33.33%	47.28%	Prueba 3	26.67%
Desempeño de VM	53.61%	30.51%	49.54%	34.13%	41.95%	Desempeño de VM	30.92%
VM utilizadas cuando el mínimo es 10	19	33	20	29	24	VM utilizadas cuando el mínimo es 20	65

Tabla 6.9. Resultados de los niveles 1 y 2 del sujeto s₁₄.

S ₁₄							
Escenario Baño --> Nivel 1						Escenario Autopista --> Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	12.05%	45.45%	22.73%	40.00%	30.06%	Prueba 1	20.20%
Prueba 2	14.29%	33.33%	38.46%	33.33%	29.85%	Prueba 2	21.98%
Prueba 3	23.81%	45.45%	12.99%	38.46%	30.18%	Prueba 3	22.99%
Desempeño de VM	16.71%	41.41%	24.73%	37.26%	30.03%	Desempeño de VM	21.72%
VM utilizadas cuando el mínimo es 10	60	24	40	27	33	VM utilizadas cuando el mínimo es 20	92

Tabla 6.10. Resultados de los niveles 1 y 2 del sujeto s₁₅.

S ₁₅							
Escenario Baño --> Nivel 1						Escenario Autopista --> Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	12.50%	41.67%	24.39%	28.57%	26.78%	Prueba 1	20.22%
Prueba 2	21.74%	26.32%	52.63%	26.32%	31.75%	Prueba 2	36.30%
Prueba 3	21.74%	40.00%	11.76%	47.62%	30.28%	Prueba 3	17.87%
Desempeño de VM	18.66%	35.99%	29.60%	34.17%	29.61%	Desempeño de VM	24.80%
VM utilizadas cuando el mínimo es 10	54	28	34	29	34	VM utilizadas cuando el mínimo es 20	81

Tabla 6.11. Resultados de los niveles 1 y 2 del sujeto s₆.

S ₆							
Escenario Baño --> Nivel 1						Escenario Autopista --> Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	20.83%	6.99%	47.62%	33.33%	27.19%	Prueba 1	25.32%
Prueba 2	20.83%	8.55%	55.56%	22.73%	26.92%	Prueba 2	19.61%
Prueba 3	21.74%	17.24%	83.33%	33.33%	38.91%	Prueba 3	20.00%
Desempeño de VM	21.14%	10.93%	62.17%	29.80%	31.01%	Desempeño de VM	21.64%
VM utilizadas cuando el mínimo es 10	47	92	16	34	32	VM utilizadas cuando el mínimo es 20	92

Tabla 6.12. Resultados de los niveles 1 y 2 del sujeto s₅.

S ₅							
Escenario Baño --> Nivel 1						Escenario Autopista --> Nivel 2	
Prueba / VM	RH	JC	LH	FT	Promedio	Prueba / VM	4 VM
Prueba 1	24.39%	62.50%	22.22%	6.54%	28.91%	Prueba 1	16.27%
Prueba 2	23.81%	29.41%	7.94%	22.73%	20.97%	Prueba 2	20.62%
Prueba 3	28.57%	23.81%	12.50%	14.49%	19.84%	Prueba 3	25.00%
Desempeño de VM	25.59%	38.57%	14.22%	14.59%	23.24%	Desempeño de VM	20.63%
VM utilizadas cuando el mínimo es 10	39	26	70	69	43	VM utilizadas cuando el mínimo es 20	97

Los valores más importantes en las tablas 6.5 a 6.12 corresponden a los promedios de desempeño de VM y a la fila que indica el número de VM utilizadas. El desempeño indica un valor rígido que proporciona información acerca de cuántas VM fueron detectadas correctamente por el sistema. En cambio, las VM utilizadas para lograr el objetivo arrojan información para determinar cuántas VM fueron necesarias por cada sujeto para llevar a cabo una tarea en tiempo real. De tal manera que es un complemento de información entre el desempeño obtenido en la clasificación y la cantidad de VM que ejecutó cada sujeto.

En las tablas 6.5 a 6.12 se muestran desempeños de cada VM por cada uno de los sujetos, permitiendo evaluar cuál VM fue mejor clasificada y con resultados que van desde un 94.44%, en el caso del sujeto s_8 para clasificar la VM de la mano izquierda, hasta un 10.93%, es decir, prácticamente no reconoce la VM del movimiento de mandíbula del sujeto s_6 .

Es importante señalar que, aunque los resultados se muestran con desempeños bajos en general, esto no significa que el sistema BCI en tiempo real sea catalogado como un sistema que no responde bien ante las VM. Los bajos resultados se deben a que la evaluación de desempeños es muy rígida y a que existen muchos factores que hacen que las señales EEG varíen, afectando las transformaciones en tiempo-frecuencia y provocando que en ocasiones no sean las esperadas por el sistema. Además, a esto se une que cada VM utiliza ventanas de 2 segundos, lo que repercute en que las diferencias en tiempos se vean muy lejanas en comparación con los tiempos establecidos para cada escenario virtual.

De tal manera que el desempeño más bajo, del 10.93% promedio, hace alusión a que el usuario tendrá que realizar 10 veces mayor esfuerzo o VM para que la mano izquierda sea detectada correctamente. En el caso contrario, el sujeto con desempeño del 94% tendrá que realizar, en ocasiones, una VM extra a las que el sistema está solicitando.

En relación con lo anterior, se buscó implementar una métrica que complementara la evaluación rígida de los desempeños, por lo que se propuso un esquema cualitativo en el que los sujetos tienen oportunidad de describir su experiencia ante el sistema BCI en tiempo real.

6.3.3 Resultados cualitativos

En los sistemas BCI en tiempo real el factor humano juega un papel importante al considerar aspectos físicos, psicológicos y emocionales. Similarmente, repercute directa e indirectamente en que los sujetos de prueba puedan realizar correctamente las VM o mantener una constancia entre las VM registradas en la etapa de entrenamiento contra las VM presentes en la etapa de ejecución. Para ello, se pensó en realizar un cuestionario que abarcara todos estos factores, desde la etapa de entrenamiento hasta la de la implementación del sistema BCI en tiempo real. En la tabla 6.13 se presenta el cuestionario al que dieron respuesta los sujetos de prueba. De este cuestionario se pueden obtener observaciones importantes por lo que se analizará cada pregunta con detenimiento y en comparación con los resultados cuantitativos.

En la pregunta 1 se analiza qué tan diferente percibió el sistema BCI en tiempo real cada uno de los sujetos de prueba al iniciar los minijuegos, en comparación con la última vez que los completaron. Se observa que los sujetos notaron una mejoría en el tiempo de respuesta e incluso algunos comentan que pudieron dominar más sus VM en las últimas pruebas. Esto se puede afirmar en la sección de resultados generales e individuales, donde la mayoría de los sujetos pudo superar su propio récord de tiempos y de carritos superados.

En el caso de la pregunta 2 se evalúa la VM que más se le dificultó a cada sujeto. Por ejemplo, los sujetos s_{14} y s_{15} son zurdos y a ambos se les dificultó visualizar el movimiento de la mano derecha e inclusive su desempeño en esa VM es el más bajo en comparación con las otras 3 VM como se observa en las tablas 6.9 y 6.10, respectivamente. Esto puede significar que, al no utilizar tan constantemente dicho miembro del cuerpo, es más difícil visualizarlo en movimiento. Por otra parte, el sujeto s_8 fue el que reportó mejores resultados de cada VM individualmente, con desempeños hasta de un 100% en el caso de la mano izquierda. Sin embargo, cuando se trata de la VM de los pies no tuvo muy buen desempeño y se debe a que cambió el tipo de VM durante el entrenamiento, de tal manera que no fue tan constante como con las otras 3, lo que dificulta al sistema BCI en tiempo real a determinar la clase VM de los pies correctamente. Similarmente sucedió con los sujetos s_{14} y s_5 quienes no siguieron al pie de la letra el protocolo de entrenamiento.

Tabla 6.13a. Preguntas 1 y 2 del cuestionario para evaluar la métrica cualitativa.

	1. ¿Cuál fue la diferencia entre la primera prueba de los escenarios en tiempo real con respecto a las últimas pruebas? ¿Consideras que <u>hubo avance en la clasificación</u> y respuesta acertada del sistema BCI ante tus Visualizaciones Motoras (VM)?	2. ¿Cuál fue la <u>VM que más se te complicó</u> , por qué y qué pensamientos pasaban por tu mente al momento de realizarla?
S10	Sí cambió porque al inicio las pruebas me causaban desconcentración. Sí hubo avances.	Lengua, siempre estuve enfocado en imaginar ese movimiento, pero no pasaba la prueba.
S8	La diferencia fue que el tiempo de respuesta de las últimas pruebas fue más rápida y acertada.	Fue la de las piernas, se me complicó ya que en la etapa de entrenamiento no mantuve una VM fija.
S1	En tiempo. Creo que si hubo una pequeña mejora en el tiempo de respuesta.	Mandíbula, fue la que más batalló el sistema en detectar, pensaba en masticar un chicle.
S11	Mejor captación de las señales. Aumentó la velocidad de captación de las señales por lo que sí hubo un avance.	La mano izquierda, así como la mano derecha, en ocasiones pensaba en ambas manos.
S14	Se considera que hubo un avance positivo a lo largo del tiempo en cuanto al desempeño de las pruebas, reflejándose en los tiempos en precepción del usuario.	La visualización más complicada resultó ser la mano derecha, siendo que era la que mayor concentración requería para acertar en la aplicación en relación a las otras puesto que las demás salían con una mejor fluidez. Se adoptaron varias técnicas para visualizar la mano derecha a lo largo de las pruebas, y es esta diversificación la que posiblemente haga la diferencia con respecto a las otras partes del cuerpo. En última instancia, el pensamiento idóneo que se adoptó fue la de sentir que se saludaba a una persona.
S15	Sí, pude dominar más el movimiento de los escenarios al final.	La mano derecha, visualizaba los movimientos mostrados en pantalla y un recuerdo de mi haciéndolos, pero no siempre lograba visualizarlo de igual manera.
S6	Sí, conforme más tiempo lo utilizaba mejor me iba adaptando al sistema.	Movimiento de mandíbula, era difícil porque era la única parte con la que no tenía contacto visual directo, imaginaba mi cara de perfil.
S5	Al principio batallaba para acertar las VM, al punto de no lograr la detección con la mano derecha, sin embargo, en las últimas pruebas, la detección mejoró notablemente, permitiéndome finalizar todas las pruebas impuestas	La visualización con la mano izquierda. Al momento de hacer la VM no lograba controlar la mente e imaginaba un dedo extra o un giro en la mano que me era imposible detener.

Tabla 6.13b. Preguntas 3 y 4 del cuestionario para evaluar la métrica cualitativa.

3. ¿Cuál fue la <u>VM</u> que menos se te complicó, por qué y qué pensamientos pasaban por tu mente al momento de realizarla?		4. Durante el <u>protocolo de entrenamiento</u> de VM, ¿visualizaste el movimiento que se presentaba para entrenar el sistema BCI; por ejemplo, visualizar tocar cada dedo con el pulgar en cada mano, visualizar apretar mandíbula / mover lengua, o movimiento de pies como si fueras en bicicleta?
S ₁₀	Mano derecha, sólo imaginaba la mano	Sí.
S ₈	La de ambas manos ya que la visualización del movimiento era bastante clara.	Sí, solo que para los pies visualicé diferentes movimientos.
S ₁	Mano derecha, fue la que sentí que mejor detectaba el sistema, pensaba en que abría y cerraba el puño.	Sí.
S ₁₁	Pies, pensaba en caminar.	Sí.
S ₁₄	Se considera que mandíbula fue la más sencilla de controlar, pues salía rápidamente acertada en las pruebas. Se pensaba en morder alguna comida apetitosa.	Durante el protocolo de entrenamiento se visualizaron la mayoría de las veces estas visualizaciones, pero había ciertos puntos del entrenamiento donde resultaba más cansado esto que imaginar otra cosa relacionada con la misma parte del cuerpo, por lo que hubo veces que se adoptó otra visualización similar.
S ₁₅	El movimiento de las piernas, fue más fácil visualizar el movimiento como si fuera una bicicleta.	Sí, en un recuerdo de mi haciendo eso.
S ₆	Mano izquierda, imaginaba el protocolo de la visualización, además las manos quedaban en una posición en la que podía establecer contacto visual aun durante las pruebas.	Sí, excepto con el apretón de mandíbula.
S ₅	El movimiento de lengua. Durante todo el entrenamiento fue el pensamiento que más pude mantener sin cambios, por lo que al momento de las pruebas lograba reproducir el recuerdo de manera exitosa. Los pensamientos que utilizaba para llevar a cabo la VM, era imaginar que estaba comiendo, en diversas ocasiones el alimento cambiaba, pero el movimiento era el mismo.	Sí, sin embargo, no lograba mantener el pensamiento siempre igual. En ocasiones imaginaba apéndices extra a las manos, el escenario de fondo, la situación en la que estaba realizando, mentalmente, el movimiento. Estas situaciones complicaron que lograra reutilizar estos recuerdos para las pruebas.

Tabla 6.13c. Preguntas 5, 6 y 7 del cuestionario para evaluar la métrica cualitativa.

	<i>5. Durante la evaluación del sistema BCI en tiempo real ¿buscaste hacer las <u>mismas VM</u> que las hechas en la etapa de entrenamiento?</i>	<i>6. ¿Cómo calificarías la <u>respuesta</u> del sistema BCI ante tus VM?</i>	<i>7. Durante los diferentes escenarios ¿te fueron <u>útiles las ventanas</u> que mostraban la VM a realizar o te concentrabas más sin prestar atención a la ventana de VM?</i>
S ₁₀	Sí.	Muy buena, sólo con lengua se atoraba.	Sí.
S ₈	Sí.	La respuesta para las manos fue bastante buena, para la quijada buena y para los pies regular.	Me fueron útiles para visualizar la cadencia del movimiento.
S ₁	Sí.	Me pareció muy bien, la verdad esperaba que sería más complicado.	Me parecieron útiles porque era a lo que estaba acostumbrado en el entrenamiento.
S ₁₁	Sí.	Excelente.	En ocasiones la ventana era de gran ayuda y en otras me distraían.
S ₁₄	Se intentaron varias ideas, incluida esta, y en algunos casos se observó que era más sencillo adoptar otra visualización, como la de la pregunta 2, que se prefirió por sentir que se saludaba a alguien, visualización que no se desarrolló sino hasta la evaluación.	Se piensa que la respuesta es de un 80%.	Ciertamente resultaba mejor incluso cerrar los ojos para concentrarse por completo a la visualización, por lo que no resultaron del todo útiles personalmente, pero no se descarta su utilidad para otras personas.
S ₁₅	Sí.	Demasiado precisa.	Durante las pruebas finales fue mejor no prestar atención.
S ₆	Si, pero no obtuve muy buenos resultados.	Regular, fue necesario hacer cambios en lo que imaginaba para que el sistema los detectara correctamente.	Me concentraba mejor sin prestar atención a la ventana, y me era más útil ver la parte del cuerpo que necesitaba mover.
S ₅	Sí.	Buena. Sobre todo, al final, donde existió un mayor número de aciertos.	Si. Las ventanas me ayudaban a enfocarme a la VM que debía llevar a cabo en ese momento.

Tabla 6.13d. Preguntas 8 y 9 del cuestionario para evaluar la métrica cualitativa.

	8. <i>¿Consideras que hubo diferencias en tu estado emocional, físico y psicológico entre la etapa de entrenamiento del sistema y la etapa de evaluación al probar los escenarios en tiempo real? De ser así ¿qué cambios notaste?</i>	9. <i>¿Qué mejoras propones al sistema BCI, en cuanto a electrodos, escenarios de evaluación, respuesta del sistema, etc.?</i>
S10	Sí, entre más tiempo tardaban las pruebas más me dolía la cabeza.	Unos electrodos más cómodos, de ahí en fuera todo perfecto.
S8	En la etapa de entrenamiento me dio sueño, y ya en la etapa de evaluación si me mantuve alerta.	Utilizar electrodos más cómodos.
S1	Tal vez un poco en lo emocional porque ya realizar las visualizaciones en un juego se siente uno más motivado que sólo estar tomando muestras.	Cambiaría los electrodos, usar el casco con esos electrodos es muy incómodo. después de unos minutos comienza a doler, lo demás me pareció perfecto.
S11	No.	Ambiente más controlado para probar el sistema y para el entrenamiento.
S14	Sí hubo algunos cambios, como el horario de entrenamiento y evaluación. Pero no se percibió una correlación entre el desempeño y los cambios observados en ese sentido, y en el caso de que así fuera, la multi-factoriedad entre las dos situaciones implicó que fuera muy difícil percibir como influyó cada uno en el desempeño general.	Aunque la plataforma utilizada cerebro-computadora está plenamente justificada debido a que los recursos disponibles para la realización de la tesis, el uso del casco y de los electrodos resultaba incómodo al usarse durante un largo tiempo, lo cual pudo influir al momento de realizar evaluaciones durante un periodo considerable de tiempo. Más allá de este punto, se considera que el sistema es suficientemente bueno para la realización del proyecto.
S15	Estuve más alerta en los escenarios, más concentrado en los movimientos, lo que me hacía pensar en los movimientos equivocados.	Un casco más grande o para las cabezas de otras formas/tamaños.
S6	Estaba un poco más desvelado durante el periodo de pruebas en tiempo real. Era más difícil concentrarme	Reducir los tiempos de tomas de muestras (menos sesiones) y definitivamente conseguir electrodos que incomoden menos al usuario.
S5	En el entrenamiento había una molestia gradual con los electrodos del casco. Al principio era tolerable, pero con el paso del tiempo el dolor era bastante considerable. En la evaluación a tiempo real sucedió lo mismo respecto a los electrodos. A esto se le agregaba un poco de estrés al no detectarse las VM, pero cuando se lograba, la sensación fue bastante satisfactoria.	Que los electrodos resulten menos molestos o dolorosos.

Tabla 6.13e. Pregunta 10 del cuestionario para evaluar la métrica cualitativa.

10. *En términos generales, cómo calificas el sistema BCI en tiempo real: muy malo, malo, regular, bueno o muy bueno y por qué.*

S ₁₀	Bueno, porque siempre detectó eficazmente mis visualizaciones.
S ₈	Muy bueno, ya que el sistema respondió muy bien a mis visualizaciones, mejor de lo que esperaba.
S ₁	Muy bueno, ya que detecto las VM mejor de lo esperado por mí.
S ₁₁	Bueno.
S ₁₄	El sistema se califica como bueno, competente y eficiente al utilizar una plataforma de costo menor y consiguiendo resultados favorables. Los resultados pueden ser aún mejores pero la clasificación se consideró con buen potencial para aplicarse a un sistema donde las decisiones tomen una trascendencia más importante.
S ₁₅	Muy bueno, porque se tomaron en cuenta que estuviera calmado al momento de tomar las muestras.
S ₆	Bueno
S ₅	Muy bueno. A pesar de no haber realizado una VM ideal en el entrenamiento, la detección en los escenarios era buena, y una vez encontrados los pensamientos más adecuados para el sistema, las pruebas se llevaron con relativa facilidad.

Continuando con la pregunta 2, también está el caso del sujeto s_6 , cuya VM con menor desempeño cuantitativo y cualitativo fue el de la mandíbula y lo justificó diciendo que es una parte del cuerpo que no puede observar directamente, en comparación con las manos y los pies, que con observarlos puede más fácilmente provocar un estímulo de visualización.

Cuando se observan los comentarios correspondientes a la pregunta 3, se puede determinar que en su mayoría el mejor desempeño determinado por el sistema BCI en tiempo real corresponde a la VM que fue más sencilla realizar para cada uno de los sujetos. Esto afirma una relación muy cercana entre la constancia de la VM, su reproducibilidad en la mente de cada sujeto al visualizarla muy parecida en cada situación y la correcta clasificación del sistema asignándole una clase en concreto.

Por otra parte, con la pregunta 4 se tuvo la intención de asegurarse que los sujetos sí hayan completado correctamente el protocolo de VM en la toma de muestras. Los resultados señalan que la mitad sí cumplió con el protocolo al pie de la letra y los sujetos s_5 , s_6 , s_8 , y s_{14} tuvieron dificultades en mantener una VM en específico y eso repercutió directamente en el desempeño de la VM en el sistema en tiempo real.

Pasando a la pregunta 5, se cuestionó a los sujetos si mantuvieron las VM realizadas en el entrenamiento, es decir, aun cuando no hayan seguido el protocolo propuesto, si realizaron una VM más sencilla para ellos y la mantuvieron en la etapa de tiempo real, el sistema debería ser capaz de clasificarla correctamente. Sin embargo, sólo el sujeto s_{14} dio una respuesta no positiva, ya que intentó diferentes tipos de VM para lograr la respuesta acertada del sistema. Esto hace pensar que los sujetos que sí siguieron el protocolo y sí mantuvieron sus VM obtuvieron mejores resultados y se expresa en las tablas generales e individuales.

La siguiente pregunta número 6 aborda el tema de cómo califica el sujeto la respuesta del sistema BCI ante las VM realizadas, lo que permite evaluar tanto el sistema como el sentir de la persona ante los minijuegos. Los resultados se muestran muy buenos para los sujetos que sí siguieron el protocolo de toma de muestras y cuyos desempeños son altos y regular para quienes tienen desempeños promedio y desempeños bajos. Incluso el sujeto s_5 menciona que en las últimas pruebas los resultados fueron más acertados.

Debido a que el objetivo a futuro es trasladar el sistema BCI en tiempo real a una aplicación portable, en la pregunta 7 se buscó evaluar qué tanto el sujeto debe prestar atención a una ayuda visual para estimular el desarrollo de una VM. Por lo tanto, es necesario determinar si los sujetos requieren de alguna herramienta que les permita concentrarse o si pueden efectuar las VM sin ayuda. Los resultados muestran que las ventanas de VM diseñadas para los escenarios fueron útiles para 4 sujetos, pues estaban acostumbrados a realizar las VM siguiendo el movimiento propuesto en el protocolo. Los otros 4 sujetos no necesitaban de las ventanas e incluso cuando completaban algún minijuego se observó que se concentraban más si observaban las partes de su cuerpo directamente, promoviendo la VM o que les causaba desconcentración y por tal motivo cerraban los ojos. Este último punto afectaba en los tiempos para completar cada

escenario virtual, pues al momento de cerrar los ojos perdían segundos de respuesta y no prestaban atención directa al cambio de VM que exigía el sistema. En esos casos se optó por ayudarlos diciéndoles cuándo el sistema BCI en tiempo real había determinado la VM que estaban realizando y que debían cambiar de VM.

Otro aspecto que se buscó analizar fue la constancia emocional, física y psicológica ante la etapa de entrenamiento y la de ejecución en tiempo real. Por ello, en las respuestas a la pregunta 8 se puede observar que sólo un sujeto dijo no haber presentado ningún tipo de cambio ni físico ni emocional ni psicológico. Sin embargo, el resto de los sujetos sí tuvo complicaciones entre las que se presentan es sueño (mayor sueño en la etapa de entrenamiento y estado de alerta en la etapa de ejecución en tiempo real), dolor físico en la cabeza, causado por el uso de los electrodos (factor importante que hace que los sujetos pierdan concentración), cambios en el estado emocional también provocados por el deseo de ganar en cada minijuego y superar sus récords. Esto afirma la importancia de considerar todos los factores que puedan afectar al sistema BCI, pero también indica que no se puede tener todo perfectamente controlado pues los factores emocional y psicológico están fuera del control del sistema BCI aun cuando se quieran someter a cierto grado de estabilidad.

La penúltima pregunta, la número 9, permite retroalimentar cómo mejorar el sistema BCI desde el punto de vista de los usuarios, que son el fin último. La mayoría coincidió en que los electrodos deben ser menos dolorosos o que el casco sea cómodo para poder utilizarlo sin inconvenientes que provoquen desconcentración. También se hace mención de buscar un ambiente más controlado para probar el sistema y quizá ver la posibilidad de reducir los tiempos de tomas de muestras para el entrenamiento. Lo anterior son elementos muy importantes que se deben tomar en cuenta para el avance en esta investigación.

Finalmente, los resultados de la pregunta 10 califican al sistema en términos generales y por parte de los sujetos que lo utilizaron, en donde se les pidió que en escala subjetiva de muy malo, malo, regular, bueno y muy bueno dieran una conclusión sobre el sistema BCI en tiempo real. Los comentarios abarcan de bueno a muy bueno y se observan expresiones como “mejor de lo que esperaba”, “mejor de lo esperado por mí”, “bueno, competente, eficiente” y el sujeto

ganador s_{10} lo calificó como “bueno, porque siempre detectó eficazmente mis visualizaciones”. Esto da una noción general de cómo perciben los usuarios el sistema BCI en tiempo real propuesto en este trabajo.

6.4 Conclusiones del capítulo

En este capítulo se presentó la manera en que la metodología propuesta fue implementada en tiempo real para evaluar el sistema BCI ante diferentes escenarios virtuales. Para ello, se eligieron 8 sujetos de los 15 de la base de datos, de entre los cuales se encuentran sujetos con bueno, regular y bajo desempeño de los resultados obtenidos en el capítulo 5.

Se diseñaron 4 diferentes escenarios virtuales que se ordenaron de acuerdo con el nivel de dificultad. El primero de ellos es un escenario de entrenamiento que es muy similar al utilizado en la toma de muestras. El siguiente es el escenario baño que corresponde al nivel 1, en donde se evalúan 40 VM, 10 de cada clase que se presentan de manera ordenada, comenzando por la mano derecha, luego mandíbula, mano izquierda y al final los pies. Para el nivel 2 se propuso el escenario autopista en donde se evalúan 20 VM, 5 de cada clase, pero ahora se presentan aleatoriamente. Finalmente, se tiene el nivel 3 con el escenario carritos que consiste en un auto que se mueve por medio de 2 VM de un lado al otro para esquivar los carritos que quieren chocar contra él.

Los 8 sujetos de prueba completaron satisfactoriamente todos los minijuegos y se registraron los puntajes obtenidos de cada una de las 3 pruebas realizadas por cada escenario virtual. De tal manera que, para dar mayor profundidad a la evaluación del sistema BCI en tiempo real se consideraron dos métricas: una cuantitativa, donde se arrojan desempeños de correcta clasificación del sistema y otra cualitativa, en donde los sujetos dieron respuesta a un cuestionario acerca de diversos temas relacionados al sistema BCI. Estas dos métricas se complementaron y compararon y se obtuvo una congruencia muy directa, para la mayoría de los sujetos y aseveraciones, entre ellas.

De tal manera que el sistema BCI en tiempo real propuesto se evaluó como “bueno” a “muy bueno”, con áreas de oportunidad como el tipo de electrodos a utilizar y el tiempo que se invierte para completar la base de datos para el entrenamiento de las redes CNN.

Se observó que los sujetos que siguieron el protocolo para la toma de muestras con mayor precisión, fueron también aquellos que obtuvieron mejores resultados en los puntajes de los minijuegos. Hubo otros cuyas VM cambiaron de la etapa de entrenamiento a la de ejecución y sus resultados se presentan como bajos. Pero algo en lo que coinciden los sujetos de prueba es que conforme superaban una y otra vez el minijuego, ganaban experiencia y aprendían a realizar las VM de la manera en que el sistema las clasificaba como correctas, provocando una etapa de “reentrenamiento” para el sujeto de prueba.

CAPÍTULO 7.

7. CONCLUSIONES Y TRABAJO FUTURO

Uno de los objetivos de esta tesis fue analizar y diseñar técnicas para reconocimiento de visualizaciones motoras para aplicaciones en tiempo real. Inicialmente, se consultó y analizó el estado del arte sobre la información actual acerca de los sistemas BCI que utilizan visualizaciones motoras, así como la teoría relacionada al tema. Se observó que la mayoría de los trabajos presentan metodologías que funcionan fuera de línea y proponen como trabajo futuro la implementación en una aplicación en tiempo real. Además, la mayoría de las metodologías utilizan filtros espaciales en combinación con bandas de frecuencia específicas o transformaciones en tiempo-frecuencia para extracción de características y clasificadores como SVM y redes neuronales. Sin embargo, no se encontró ningún trabajo que planteara la combinación de patrones espaciales con una transformación tiempo-frecuencia, sólo con bandas de frecuencia, pero dejando de lado el tiempo.

Ante tal situación se buscó aprovechar al máximo las particularidades de los métodos de extracción de características más utilizados en la literatura y proponer una metodología completa y robusta para ser implementada en un sistema BCI en tiempo real.

De tal manera que se analizaron, diseñaron y evaluaron un total de 14 métodos para extraer características y clasificar entre VM de diferentes tipos: CSP_2+SVM , $CWT+SVM$, $ST+SVM$, $CSP_2+CWT+SVM$, $CSP_2+ST+SVM$, CSP_2+CNN , $CWT+CNN$, $ST+CNN$, $CSP_2+CWT+CNN$, $CSP_2+ST+CNN$, $CSP_4+CWT+CNN$, $CSP_4+ST+CNN$, $CSP_6+CWT+CNN$, $CSP_6+ST+CNN$. Estos se probaron con dos bases de datos utilizadas en la literatura con 2 VM: de mano izquierda contra mano derecha.

Al extraer características con los métodos combinados: $CSP+CWT$ y $CSP+ST$ los desempeños fueron más altos en comparación con utilizar los métodos individuales: CSP , CWT y ST , con el clasificador CNN , (Tabla 3.3 y Tabla 3.5). Estos altos desempeños se deben a que CSP combina información de las clases involucradas y genera una matriz que ayuda a encontrar

la mayor varianza entre ellas, reduciendo la dimensión de los datos utilizados y con las características más discriminantes entre clases. Unido a esto, se hace una transformación tiempo-frecuencia sobre el resultado de CSP, lo cual aporta más información para distinguir entre visualizaciones motoras.

Se hizo una evaluación con 2, 4 y 6 filas de la matriz de proyección de los patrones de CSP en los métodos CSP+CWT y CSP+ST, (Tablas 3.6-8) que permitieran aprovechar las ventajas de CSP, sin exceder el número de canales disponibles de acuerdo con el dispositivo OpenBCI que permite hasta 8 canales en la configuración estándar y que generan información balanceada al tener 2 tipos de VM por cada CNN y elegir una cantidad par de filas. Como resultado se observó que con un mayor número de filas se obtenía un mejor desempeño, pues la red CNN recibe más información para aprender. Además, aun cuando las redes CNN extraen características por sí mismas, se probó que ante la misma arquitectura de red la CNN produce mejores desempeños cuando las características son más discriminantes. De tal manera que al utilizar CSP₆+CWT se obtuvo el mejor desempeño promedio de ambas bases de datos con $97.25\% \pm 1.76\%$ al discriminar entre visualizaciones de la mano derecha contra visualizaciones de la mano izquierda. Lo anterior dio paso a expandir la metodología a 4 VM e incluir, además de las manos, los pies y la lengua.

La metodología CSP₆+CWT+CNN se implementó para clasificar 4 visualizaciones motoras, utilizando un esquema modular y un algoritmo propuesto denominado sgSM que reportó desempeños del $91.37\% \pm 03.29\%$, Tabla 4.6. Esto coloca la metodología propuesta en una posición bastante competitiva en comparación con los trabajos reportados en la literatura. Además, al utilizar una transformación tiempo-frecuencia y no tener que seleccionar bandas de frecuencia determinadas y evaluarlas por separado (lo que consume mucho tiempo computacional) el tiempo de procesamiento es bastante reducido, pues al sistema le toma 270 ms para determinar cuál visualización motora corresponde a la actividad cerebral que proviene del EEG, en comparación a otros trabajos del estado del arte, Tabla 4.8.

En la evaluación de la metodología se generó una base de datos con 15 sujetos de prueba y se diseñó un sistema BCI en tiempo real que contiene 4 escenarios virtuales. Para la elaboración

de la base de datos del sistema se propuso un protocolo para la toma de muestras que delimita el tipo de visualización motora, incluyendo visualizaciones de las manos derecha, izquierda, pies y lengua. Se observó que las bases de datos más comunes como *BCI Competition* no delimitan la visualización motora, permitiendo que los sujetos sean libres de visualizar algún movimiento que corresponda a determinado miembro del cuerpo. Sin embargo, esto hace que el sistema sea demasiado abierto y las posibilidades de visualización son infinitas. Por lo que, con base en un artículo reportado en la literatura [29], se adoptó un protocolo para la obtención de una visualización específica de las manos, pies y apretón de mandíbula. Ésta última fue propuesta en este trabajo y aunque no se ha reportado en otras bases de datos demostró buenos resultados. Para concluir esta sección, se adoptó un protocolo para la obtención de una visualización específica de las manos, pies y apretón de mandíbula. Los resultados al evaluar la base de datos con 15 sujetos e implementar la metodología CSP₆+CWT+CNN con el esquema modular y sgSM fueron del $86.48\% \pm 4.74\%$, casi un 5% más bajos (véase Tabla 5.4) que cuando se evaluó esta misma metodología, pero con *BCI Competition IV dataset 2a*, aunque en esta ocasión se tienen 6 sujetos más de prueba, véase Tabla 4.3.

Para evaluar el sistema BCI en tiempo real, se seleccionaron 8 sujetos representativos de la base de datos propuesta. Durante la evaluación, todos los sujetos completaron el objetivo de cada uno de los escenarios virtuales. Sin embargo, se observó que el factor humano como el estado emocional, físico y psicológico de los usuarios repercute directamente en la generación de visualizaciones motoras similares de la misma clase. Es decir, a algunos sujetos que siguieron el protocolo propuesto en la toma de muestras se les dificultó la ejecución de visualizaciones en tiempo real en los escenarios virtuales porque su estado emocional había cambiado, estaban más alertas por querer lograr los objetivos, más estresados o incluso frustrados. De tal manera que se presentó una etapa de reentrenamiento por parte del usuario, en la cual éste se adaptaba e iba aprendiendo cómo realizar las visualizaciones de manera que el sistema las clasificara como acertadas. O hubo incluso, quienes trataban de simular o entrar en el estado anímico que tenían durante la toma de muestras, lo que sí ayudaba a que el sistema BCI clasificara con mejor desempeño.

Se consideraron dos métricas para evaluar el sistema: una cuantitativa y otra cualitativa. La cualitativa se encargó de evaluar el factor humano mediante un cuestionario (Tabla 6.13) y la cuantitativa reporta los puntajes obtenidos de cada sujeto en los escenarios virtuales. Con la información de las métricas, se determinó que aquellas visualizaciones que fueron más difíciles de imaginar para cada uno de los sujetos resultaron ser los desempeños más bajos en dicha clase (Tablas 6.2-12). Es decir, si a un sujeto se le dificultaba visualizar la mano derecha (como en el caso de los dos sujetos zurdos) esto se veía reflejado en el desempeño del sistema en tiempo real. En el caso contrario, cuando el sujeto tenía facilidad para visualizar un movimiento, el sistema lo determinaba correcto con buen desempeño.

El análisis y diseño de los métodos propuestos para extraer características y clasificar entre VM generó, como consecuencia de los buenos desempeños y el estudio previo, la viabilidad de implementar un sistema BCI en tiempo real con posibilidad de expandirse para hacer una aplicación portable, pero con áreas de oportunidad como:

- Mejorar la calidad de los electrodos para que los sujetos los utilicen sin que cause dolor su uso por tiempo prolongado.
- Un protocolo de toma de muestras de las visualizaciones motoras que motive o provoque que todos los sujetos de prueba sigan el protocolo al pie de la letra para que se presente uniformidad en las señales EEG.
- Buscar la manera de que los sujetos entren en un estado físico, emocional y psicológico cómodo para ellos y que sea constante a lo largo de las etapas de entrenamiento, validación y pruebas en tiempo real.

Sin embargo, más que generar una aplicación BCI en tiempo real, es necesario resaltar la importancia de haber utilizado una metodología que combina dos de las herramientas más utilizadas en BCI en el área de visualizaciones motoras: patrones espaciales comunes y transformaciones en tiempo-frecuencia. Para ello, se implementó un método para analizar la información proveniente de las señales EEG de los ritmos sensoriomotores proyectándola a un subespacio de menor dimensión mediante CSP y se aplicó la transformada CWT para observar su comportamiento en tiempo-frecuencia. Esta combinación CSP+CWT fue fundamental en la

metodología de clasificación. No obstante, cuando se implementó en tiempo real, las condiciones se modificaron, ya que aparece el factor humano que altera el comportamiento habitual de los ritmos sensoriomotores presentes en el EEG registrados durante la toma de muestras.

Para dar solución a esta problemática se propone un modelo de sistema BCI que vaya aprendiendo conforme se realizan las pruebas. Es decir, plantear un protocolo de toma de muestras que no exija muchas muestras pero que sí sea representativo de la actividad cerebral correspondiente a las visualizaciones motoras que se desea discriminar. Luego, comenzar las pruebas en tiempo real, pero buscando que el sistema vaya registrando los cambios producidos en la actividad cerebral debidos al factor humano y elementos externos como el ambiente o el posicionamiento de los electrodos. De tal manera que el sistema tenga la capacidad de retroalimentarse con las nuevas muestras y siga aprendiendo cómo es la actividad cerebral del usuario, complementando cada vez más su base de datos.

REFERENCIAS

- [1] O. Müller y S. Rotter, “Neurotechnology: Current Developments and Ethical Issues”, *Front. Syst. Neurosci.*, vol. 11, núm. December, pp. 1–5, 2017.
- [2] L. A. Pineda, *La Computación en México por especialidades académicas*, First Ed. México: Academia Mexicana de Computación A.C., 2017.
- [3] L. F. Nicolas-Alonso y J. Gomez-Gil, “Brain computer interfaces, a review”, *Sensors*, vol. 12, núm. 2, pp. 1211–1279, 2012.
- [4] F. Lotte, L. Bougrain, y M. Clerc, “Electroencephalography (EEG)-based Brain-Computer Interfaces”, *Wiley Encyclopedia of Electrical and Electronics Engineering*. p. 44, 2015.
- [5] H. H. Jasper, “Report of the committee on methods of clinical Examination in electroencephalography”, *Electroencephalogr. Clin. Neurophysiol.*, vol. 10, núm. 2, pp. 370–375, 1958.
- [6] G. Pfurtscheller y C. Neuper, “Motor imagery and direct brain- computer communication”, *Proc. IEEE*, vol. 89, núm. 7, pp. 1123–1134, 2001.
- [7] C. Brunner y R. Leeb, “BCI Competition 2008 – Graz data set A”, *Knowl. Creat. Diffus. Util.*, pp. 1–6, 2008.
- [8] F. Škola y F. Liarokapis, “Embodied VR environment facilitates motor imagery brain–computer interface training”, *Comput. Graph.*, vol. 75, pp. 59–71, 2018.
- [9] F. Parivash, L. Amuzadeh, y A. Fallahi, “Design Expanded BCI with Improved Efficiency for VR-embedded NeuroRehabilitation Systems”, *2017 Artif. Intell. Signal Process. Conf.*, pp. 230–235, 2017.
- [10] S. Liang, K. S. Choi, J. Qin, W. M. Pang, Q. Wang, y P. A. Heng, “Improving the discrimination of hand motor imagery via virtual reality based visual guidance”, *Comput. Methods Programs Biomed.*, vol. 132, pp. 63–74, 2016.

- [11] S. Bhaduri, A. Khasnobish, R. Bose, y D. N. Tibarewala, “Classification of Lower Limb Motor Imagery Using K Nearest Neighbor and Naive-Bayesian Classifier”, en *3rd International Conference on Recent Advances in Information Technology (RAIT)*, 2016, pp. 499–504.
- [12] M. Behri, A. Subasi, y S. M. Qaisar, “Comparison of Machine Learning Methods for Two Class Motor Imagery Tasks using EEG in Brain–Computer Interface”, en *Advances in Science and Engineering Technology International Conferences (ASET)*, 2018, pp. 1–5.
- [13] J. Zhang, C. Yan, y X. Gong, “Deep convolutional neural network for decoding motor imagery based brain computer interface”, en *2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*, 2017, pp. 1–5.
- [14] H. K. Lee y Y.-S. Choi, “A Convolution Neural Networks Scheme for Classification of Motor Imagery EEG based on Wavelet Time-Frequency Image”, en *2018 International Conference on Information Networking (ICOIN)*, 2018, pp. 2–5.
- [15] S. Sethi, R. Upadhyay, y H. S. Singh, “Stockwell-common spatial pattern technique for motor imagery-based Brain Computer Interface design”, *Comput. Electr. Eng.*, vol. 71, núm. July, pp. 492–504, 2018.
- [16] C. S. Chen, “Statistical analysis of space-varying morphological openings with flat structuring elements”, *IEEE Trans. Signal Process.*, vol. 44, núm. 4, pp. 998–1001, 1996.
- [17] T. Nguyen, I. Hettiarachchi, A. Khatami, L. Gordon-Brown, C. P. Lim, y S. Nahavandi, “Classification of Multi-Class BCI Data by Common Spatial Pattern and Fuzzy System”, *IEEE Access*, vol. 6, pp. 27873–27884, 2018.
- [18] L. Duan, Z. Hongxin, M. S. Khan, y M. Fang, “Recognition of motor imagery tasks for BCI using CSP and chaotic PSO twin SVM”, *J. China Univ. Posts Telecommun.*, vol. 24, núm. 3, pp. 83–90, 2017.
- [19] M. Aljalal, R. Djemal, y S. Ibrahim, “Robot Navigation Using a Brain Computer Interface Based on Motor Imagery”, *J. Med. Biol. Eng.*, vol. 39, núm. 4, pp. 508–522,

- 2019.
- [20] Y. Zhang, C. S. Nam, G. Zhou, J. Jin, X. Wang, y A. Cichocki, “Temporally Constrained Sparse Group Spatial Patterns for Motor Imagery BCI”, *IEEE Trans. Cybern.*, vol. 49, núm. 9, pp. 3322–3332, 2018.
 - [21] H. S. An, J. W. Kim, y S. W. Lee, “Design of an asynchronous brain-computer interface for control of a virtual Avatar”, *4th Int. Winter Conf. Brain-Computer Interface, BCI 2016*, pp. 5–6, 2016.
 - [22] A. S. Aghaei, M. S. Mahanta, y S. Member, “Separable Common Spatio-Spectral Patterns for Motor Imagery BCI Systems”, *Ieee Trans. Biomed. Eng.*, vol. 63, núm. 1, pp. 15–29, 2016.
 - [23] J. S. Kirar y R. K. Agrawal, “Relevant Feature Selection from a Combination of Spectral-Temporal and Spatial Features for Classification of Motor Imagery EEG”, *J. Med. Syst.*, vol. 42, núm. 5, 2018.
 - [24] L. He, D. Hu, M. Wan, Y. Wen, K. M. Von Deneen, y M. Zhou, “Common Bayesian Network for Classification of EEG-Based Multiclass Motor Imagery BCI”, *IEEE Trans. Syst. Man, Cybern. Syst.*, vol. 46, núm. 6, pp. 843–854, 2016.
 - [25] S. Qu, J. Liu, W. Chen, J. Zhang, y W. Chen, “Pattern Recognition of Motor Imagery EEG Signal in Noninvasive Brain-Computer Interface”, *2018 13th IEEE Conf. Ind. Electron. Appl.*, pp. 1814–1819, 2018.
 - [26] A. M. Eldeib y S. Member, “Unsupervised Processing Methods for Motor Imagery-Based Brain- Computer Interface”, en *2018 IEEE 4th Middle East Conference on Biomedical Engineering (MECBME)*, 2018, pp. 106–111.
 - [27] M. Dharani y M. Sivachitra, “Motor imagery signal classification using semi supervised and unsupervised extreme learning machines”, *2017 Int. Conf. Innov. Information, Embed. Commun. Syst.*, pp. 1–4, 2017.
 - [28] N. Lu, T. Li, X. Ren, y H. Miao, “A Deep Learning Scheme for Motor Imagery

- Classification based on Restricted Boltzmann Machines”, *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 25, núm. 6, pp. 566–576, 2017.
- [29] H. Cho, M. Ahn, S. Ahn, M. Kwon, y S. C. Jun, “EEG datasets for motor imagery brain-computer interface”, *Gigascience*, vol. 6, núm. 7, pp. 1–8, 2017.
- [30] B. Xu *et al.*, “Wavelet Transform Time-Frequency Image and Convolutional Network-Based Motor Imagery EEG Classification”, *IEEE Access*, vol. 7, pp. 6084–6093, 2019.
- [31] T. Uktveris y V. Jusas, “Convolutional neural networks for four-class motor imagery data classification”, en *Intelligent Distributed Computing XI. IDC 2017.*, Springer,., vol. 737, S. M. (eds) Ivanović M., Bădică C., Dix J., Jovanović Z., Malgeri M., Ed. 2018, pp. 185–197.
- [32] B. E. Olivas-Padilla y M. I. Chacon-Murguia, “Classification of multiple motor imagery using deep convolutional neural networks and spatial filters”, *Applied Soft Computing*, vol. 75, Elsevier B.V., pp. 461–472, 2018.
- [33] A. F. Perez-Zapata, A. F. Cardona-Escobar, J. A. Jaramillo-Garzon, y G. M. Diaz, “Deep Convolutional Neural Networks and Power Spectral Density Features for Motor Imagery Classification of EEG Signals”, *Augment. Cogn. Intell. Technol.*, vol. 10915, núm. Schmorrow D., Fidopiasstis C. (eds), pp. 158–169, 2018.
- [34] L. G. Hernandez y J. M. Antelis, “A Comparison of Deep Neural Network Algorithms for Recognition of EEG Motor Imagery Signals”, *Pattern Recognition*, vol. 10880, Springer, Cham, pp. 126–134, 2018.
- [35] S. Sakhavi, C. Guan, y S. Yan, “Learning Temporal Information for Brain-Computer Interface Using Convolutional Neural Networks”, *IEEE Trans. Neural Networks Learn. Syst.*, vol. 29, núm. 11, pp. 5619–5629, 2018.
- [36] H. Wang, T. Li, A. Bezerianos, H. Huang, Y. He, y P. Chen, “The control of a virtual automatic car based on multiple patterns of motor imagery BCI”, *Med. Biol. Eng. Comput.*, pp. 1–11, 2018.

- [37] R. Bousseta, I. El Ouakouak, M. Gharbi, y F. Regragui, “EEG Based Brain Computer Interface for Controlling a Robot Arm Movement Through Thought”, *Irbm*, vol. 39, núm. 2, pp. 129–135, 2018.
- [38] K. Belwafi, F. Ghaffari, R. Djemal, y O. Romain, “A Hardware/Software Prototype of EEG-based BCI System for Home Device Control”, *J. Signal Process. Syst.*, vol. 89, núm. 2, pp. 263–279, 2017.
- [39] M. Tangermann *et al.*, “Review of the BCI competition IV”, *Front. Neurosci.*, vol. 6, núm. 55, pp. 1–31, 2012.
- [40] M. X. Cohen, *Analyzing Neural Time Series Data : Theory and Practice.*, MIT Press. Cambridge, MA: 1 edition, p. 600, 2014.
- [41] L. Taylor y G. Nitschke, “Improving Deep Learning using Generic Data Augmentation”, en *Proceedings of the IEEE Symposium Series on Computational Intelligence (SSCI)*, 2017, pp. 1542–1547.
- [42] I. The MathWorks, “CWT”, *Continuous 1-D wavelet transform*, 2016. [En línea]. Disponible en: <https://www.mathworks.com/help/wavelet/ref/cwt.html>. [Consultado: 12-nov-2019].
- [43] H. Cho, M. Ahn, y S. C. Jun, “A Step-by-Step Tutorial for a Motor Imagery–Based BCI”, en *Brain–Computer Interfaces Handbook: Technological and Theoretical Advances*, núm. March, Taylor & Francis Group, 2018, pp. 445–460.
- [44] I. The MathWorks, “Imresize”, *Resize image*, 2019. [En línea]. Disponible en: <https://www.mathworks.com/help/matlab/ref/imresize.html#d117e714068>. [Consultado: 12-nov-2019].
- [45] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, y R. Salakhutdinov, “Dropout: A Simple Way to Prevent Neural Networks from Overfittin”, *J. Mach. Learn. Res.*, vol. 15, pp. 1929–1958, 2014.
- [46] Matthew D. Zeiler y R. Fergus, “Visualizing and Understanding Convolutional

- Networks”, en *Computer Vision – ECCV 2014*, 2014, vol. 8689, pp. 818–833.
- [47] D. P. Kingma y J. Ba, “Adam: A Method for Stochastic Optimization”, en *International Conference on Learning Representations.*, 2014, pp. 1–15.
 - [48] D. Wang, D. Miao, y G. Blohm, “Multi-class motor imagery EEG decoding for brain-computer interfaces”, *Front. Neurosci.*, vol. 6, núm. 151, pp. 1–13, 2012.
 - [49] A. Jafarifarmand, M. A. Badamchizadeh, S. Khanmohammadi, M. A. Nazari, y B. M. Tazehkand, “A New Self-Regulated Neuro-Fuzzy Framework for Classification of EEG Signals in Motor Imagery BCI”, *IEEE Trans. Fuzzy Syst.*, vol. 26, núm. 3, pp. 1485–1497, 2018.
 - [50] K. K. Ang, Z. Y. Chin, C. Wang, C. Guan, y H. Zhang, “Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b”, *Front. Neurosci.*, vol. 6, núm. 39, pp. 1–9, 2012.
 - [51] H. Raza, H. Cecotti, y G. Prasad, “A combination of transductive and inductive learning for handling non-stationarities in motor imagery classification”, en *2016 International Joint Conference on Neural Networks (IJCNN)*, 2016, pp. 763–770.
 - [52] R. B. Braga, C. D. Lopes, y T. Becker, “Round Cosine Transform Based Feature Extraction of Motor Imagery EEG Signals”, *World Congr. Med. Phys. Biomed. Eng.*, vol. 68, núm. 2, pp. 511–515, 2019.
 - [53] A. Selim, Sahar & Tantawi, Manal & Shedeed, Howida & Badr, “Comparing Multi-class Approaches for Motor Imagery Using Renyi Entropy”, *Proc. Int. Conf. Adv. Intell. Syst. Informatics*, vol. 2018, núm. January, pp. 127–136, 2019.
 - [54] M. Teplan, “Fundamentals of EEG measurement”, *Meas. Sci. Rev.*, vol. 2, núm. 2, pp. 1–11, 2002.
 - [55] R. Carabalona, “The role of the interplay between stimulus type and timing in explaining BCI-illiteracy for visual P300-based Brain-Computer Interfaces”, *Front. Neurosci.*, vol. 11, núm. JUN, p. 363, 2017.

NOTACIÓN MATEMÁTICA

τ	Tiempo de localización espectral
d	Factor de dilatación
t	Tiempo en segundos
f	Frecuencia de la señal
ω_c	Frecuencia de corte
ω	Frecuencia
$W(\tau, d)$, CWT {}	Transformada Wavelet Continua
$S(\tau, f)$, ST {}	Transformada Stockwell
$g(t)$	Función evaluada en el tiempo
nCh	Número de canales
F_s	Frecuencia de muestreo
$X_{raw}^{Ch}(n)$	Señal discreta que contiene los N datos crudos del EEG de cada canal Ch
$H(\omega)$	Respuesta en frecuencia de un filtro IIR Butterworth
$X_{filt}^{Ch}(n)$	Señal discreta filtrada que contiene la información de cada EEG de cada canal Ch por sujeto
x_{ep}^{Ch}	Época de cada canal Ch
q_{ep}	índice que hace referencia a la muestra de inicio de la VM de la época ep
p	Número de VM que tiene una base de datos.
$\overline{Cov}_c$	Covarianza normalizada de cada clase c
W_{CSP}	Filtro espacial utilizado en CSP
Z_{CSP}^{fil}	Matriz resultante de aplicar el método CSP utilizando fil filas.
$Z_{CWT}^{Ch, Es}$	Matriz resultante de aplicar el método CWT utilizando Ch canales y Es escalas.
$Z_{ST}^{Ch, F}$	Matriz resultante de aplicar el método ST utilizando Ch canales y F frecuencias.
$Z_{CSP_CWT}^{fil, Es}$	Matriz resultante de aplicar el método CSP+CWT utilizando fil filas y Es escalas.
$Z_{CSP_ST}^{fil, F}$	Matriz resultante de aplicar el método ST utilizando fil filas y F frecuencias.
Y_{CSP}^{fil}	Vector de características obtenido con CSP para entrada al clasificador SVM
Y_{CWT}^{Ch}	Vector de características obtenido con CWT para entrada al clasificador SVM
Y_{ST}^{Ch}	Vector de características obtenido con ST para entrada al clasificador SVM
$Y_{CSP_CWT}^{fil}$	Vector de características obtenido con CSP+CWT para entrada al clasificador SVM

$Y_{CSP_ST}^{fil}$	Vector de características obtenido con CSP+ST para entrada al clasificador SVM
$INT[\]$	Operador de interpolación bicúbica.
I_{CSP}	Imagen de entrada a la CNN con información procedente del método CSP
I_{CWT}	Imagen de entrada a la CNN con información procedente del método CWT
I_{ST}	Imagen de entrada a la CNN con información procedente del método ST
I_{CSP_CWT}	Imagen de entrada a la CNN con información procedente del método CSP+CWT
I_{CSP_ST}	Imagen de entrada a la CNN con información procedente del método CSP+ST
$CONVx_{i,j}^{nFiltro}$	Resultados de la capa x de convolución de la CNN ante $nFiltro$ filtros.
$Fil_x^{nFiltro}$	filtros de convolución de la primera capa x
β_x	<i>Bias</i> de la capa x
$Mx_{i,j}^{nFiltro}$	Mapa de características de la capa x
$FC^{C,nFiltro}$	Salida de la capa “totalmente conectada” para C clases
SM^C	Salida de la función <i>softmax</i> para la clase c
<i>output</i>	Salida de la red CNN
<i>GT</i>	<i>Ground Truth</i>
SS_{ep}	Variable binaria que toma el valor 1 cuando sí se clasificó correctamente y 0 cuando se clasificó incorrectamente
<i>dE</i>	Desempeño de la etapa de entrenamiento
<i>dV</i>	Desempeño de la etapa de validación
<i>kappa</i>	Coeficiente Cohen's kappa
$STR_{\Phi\Delta\Xi}^{Ch}(n)$	Muestra en específico (n) del sujeto (Φ), sesión (Δ), ensayo (Ξ) y canal (Ch) de la base de datos propuesta

GLOSARIO

Adquisición de las señales. Método por el cual se obtienen los datos crudos que representan la entrada de un sistema.

Artefactos. Señales, comúnmente indeseadas, que se presentan en el registro de la actividad eléctrica cerebral y que pueden proceder del movimiento de músculos faciales, del latido del corazón, respiración o elementos no fisiológicos, como el ruido producido por el hardware adquirente de las señales electroencefalográficas.

Buffer. Espacio de memoria destinado para almacenar muestras de la señal EEG para su uso posterior.

Clasificador. Algoritmo que asigna una etiqueta o clase a un conjunto de datos que tienen información muy relacionada entre sí.


Electrodos húmedos. Conductor eléctrico que requiere de una solución o un gel electrolítico para permitir la conducción de la actividad eléctrica cerebral, del cuero cabelludo hacia el pin del electrodo.

Electrodos secos. Conductor eléctrico que permite la conducción de la actividad eléctrica cerebral, del cuero cabelludo hacia el pin del electrodo, y no requiere de ninguna sustancia conductiva.

Electroencefalograma (EEG). Método de adquisición de señales cerebrales con el cual se registra la actividad eléctrica a través de electrodos colocados en el cuero cabelludo.

Ensayo. Intervalo de tiempo en el cual se registra la actividad cerebral por medio del EEG partiendo de un paradigma específico (en este caso paradigma de Graz) y que se compone de un rango de muestras correspondientes a dicha actividad cerebral desde que se dio indicación de preparar la visualización motora, llevarla a cabo, hasta el descanso, presentándose sólo una visualización motora en cada ensayo. En otras palabras, cada vez que se implementa el paradigma de Graz para una visualización motora en específico, se genera un ensayo.

Época. Intervalo de tiempo en el cual se deben incluir al menos dos ciclos de la señal temporal que se desea analizar. De tal manera que la cantidad de muestras presentes en una época será definida de acuerdo con la frecuencia de muestreo para el registro del EEG y la certeza de incluir al menos dos ciclos de la señal temporal de interés. Así, un ensayo se dividirá en cierto número de épocas, donde cada época debe incluir el rango de frecuencias de interés para el análisis.



Ejemplo de ensayo y épocas.

Extracción de características. Método por el cual se reduce la dimensión de los atributos de una señal pre-procesada, sin eliminar datos importantes, permitiendo la descripción de un evento con información muy específica.

Gráfica de mariposa. Representación de las señales EEG obtenidas de cada uno de los electrodos, dentro de un mismo espacio y bajo las mismas coordenadas y dimensiones.

Sesión. Es un conjunto de ensayos (implementación del paradigma de Graz) en el cual se incluyen diferentes tipos de visualizaciones motoras y que se establece como parte de un protocolo para la toma de muestras dentro del diseño de una interfaz cerebro computadora. Algunas sesiones son destinadas para el entrenamiento de los algoritmos y otras se utilizan en la validación. Por ejemplo, una sesión se puede componer de 20 ensayos: 5 ensayos donde se visualiza la mano derecha, 5 ensayos donde se visualiza la mano izquierda, 5 ensayos donde se visualizan los pies y 5 ensayos donde se visualiza el movimiento de lengua. Si se tienen 10 sesiones, 8 pueden ser destinadas para el entrenamiento y 2 para la validación.

Sistema Interfaz cerebro-computadora (Sistema BCI). Conjunto de hardware-software que registra la actividad eléctrica cerebral del usuario para ser traducida en comandos, mediante algoritmos clasificadores, para generar una aplicación específica.

Sistema Internacional o sistema 10-20. Es un estándar de posicionamiento de los electrodos sobre la superficie del cuero cabelludo para el registro de la actividad eléctrica cerebral a través de un electroencefalograma.

ANEXOS 1-15 Consentimientos informados de los sujetos para pruebas BCI


Consentimiento informado para prueba BCI

YO Daniel Alberto Posada Urrutia voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Daniel Alberto Posada Urrutia
Persona que presenta la prueba



Eduardo Rivas-Posada
Persona que aplica la prueba

Chihuahua, Chih., 20 de agosto del 2019

Consentimiento informado para prueba BCI

YO José Manuel Macías Macías voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



José Manuel Macías Macías
Persona que presenta la prueba


Eduardo Rivas-Posada
Persona que aplica la prueba

Chihuahua, Chih., 20 de agosto del 2019

Consentimiento informado para prueba BCI


YO Andrea Rivero Olivas voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Andrea Rivero Olivas

Persona que presenta la prueba



Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 21 de agosto del 2019

Consentimiento informado para prueba BCI

YO Luis Xavier Nevárez Ochoa voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.


Luis Xavier Nevárez Ochoa

Persona que presenta la prueba


Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 21 de agosto del 2019

Consentimiento informado para prueba BCI

YO David Alexis Hernández Zubía voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



David Alexis Hernández Zubía

Persona que presenta la prueba



Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 21 de agosto del 2019

Consentimiento informado para prueba BCI


YO Luis Gerardo Esquivel Ríos voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Luis Gerardo Esquivel Ríos

Persona que presenta la prueba



Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 22 de agosto del 2019

Consentimiento informado para prueba BCI

YO Francisco Javier Álvarez Prieto voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.

Francisco Javier Álvarez Prieto

Persona que presenta la prueba

Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 22 de agosto del 2019

Consentimiento informado para prueba BCI


YO Oscar Alejandro Soto Orozco voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Oscar Alejandro Soto Orozco

Persona que presenta la prueba



Eduardo Rivas-Posada


Persona que aplica la prueba

Chihuahua, Chih., 22 de agosto del 2019

Consentimiento informado para prueba BCI


YO Abimael Guzmán Pando voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Abimael Guzmán Pando

Persona que presenta la prueba



Eduardo Rivas-Posada


Persona que aplica la prueba

Chihuahua, Chih., 23 de agosto del 2019

Consentimiento informado para prueba BCI


YO Luis Madrid Herrera voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Luis Madrid Herrera

Persona que presenta la prueba



Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 23 de agosto del 2019

Consentimiento informado para prueba BCI


YO Raúl Rangel González voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Raúl Rangel González

Persona que presenta la prueba



Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 23 de agosto del 2019


Consentimiento informado para prueba BCI

YO Alonso Reyes Porras voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.


Alonso Reyes Porras

Persona que presenta la prueba


Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 26 de agosto del 2019

Consentimiento informado para prueba BCI


YO José Luis Chacón Muñoz voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



José Luis Chacón Muñoz

Persona que presenta la prueba



Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 27 de agosto del 2019

Consentimiento informado para prueba BCI

YO Iván Esteban Acosta Lara voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.

Iván E. Acosta

Iván Esteban Acosta Lara

Persona que presenta la prueba

Eduardo Rivas-Posada

Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 27 de agosto del 2019

Consentimiento informado para prueba BCI


YO Daniel Eduardo Morales Fernández voluntaria y conscientemente, doy mi consentimiento para participar en una prueba BCI cuyo proceso de aplicación es conducido por Eduardo Rivas-Posada en el Instituto Tecnológico de Chihuahua. Por este medio expreso que recibí una explicación clara y completa de la naturaleza general y de los propósitos de la prueba, así como de la razón específica por la que se me somete a esta. También recibí información sobre los tipos de pruebas y otros procedimientos que van a aplicarse y la forma en que se utilizarán los resultados.

Estoy consciente de que quizás no es posible que la persona que aplica la prueba me explique todos los aspectos de la misma hasta que haya terminado. También entiendo que puedo dar por terminada mi participación en la prueba en el momento en que lo considere sin recibir ningún castigo. Entiendo que me informarán sobre los resultados y estos se manejarán con estricta confidencialidad y doy mi consentimiento para ser publicados con fines científicos.



Daniel Eduardo Morales Fernández

Persona que presenta la prueba



Eduardo Rivas-Posada

Persona que aplica la prueba

Chihuahua, Chih., 28 de agosto del 2019