

**INTERFAZ CEREBRO COMPUTADOR BASADA EN POTENCIALES DE ESTADO
ESTABLE EVOCADOS VISUALMENTE PARA EL CONTROL DE MOVIMIENTO DE
UN DISPOSITIVO VIRTUAL**

MARÍA ESTEFANÍA RENGIFO BEDOYA
JOHAN LEANDRO PORRAS GALINDO



UNIVERSIDAD DEL VALLE
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
FACULTAD DE INGENIERÍAS
SANTIAGO DE CALI
2016

**INTERFAZ CEREBRO COMPUTADOR BASADA EN POTENCIALES DE ESTADO
ESTABLE EVOCADOS VISUALMENTE PARA EL CONTROL DE MOVIMIENTO DE
UN DISPOSITIVO VIRTUAL**

MARÍA ESTEFANÍA RENGIFO BEDOYA
JOHAN LEANDRO PORRAS GALINDO

Trabajo de grado Ingeniería Electrónica
Universidad del Valle

Directores:

Humberto Loaiza, Ph.D.
Sandra Esperanza Nope, Ph.D.

UNIVERSIDAD DEL VALLE
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
FACULTAD DE INGENIERÍAS
SANTIAGO DE CALI
2016

NOTA DE ACEPTACIÓN:

Humberto Loaiza, Ph.D.

Sandra Esperanza Nope, Ph.D.

SANTIAGO DE CALI, 29 DE ENERO DE 2016

TABLA DE CONTENIDO

TABLA DE CONTENIDO	4
ÍNDICE DE FIGURAS	6
ÍNDICE DE TABLAS.....	7
RESUMEN	8
ABSTRACT	9
1. INTRODUCCIÓN.....	10
2. MARCO TEÓRICO	12
2.1 ANTECEDENTES	12
2.2 SEÑALES CEREBRALES Y SU ADQUISICIÓN.....	15
2.2.1. TÉCNICAS DE MONITOREO DE LA ACTIVIDAD CEREBRAL	15
2.2.1.1. Electroencefalografía (EEG)	15
2.2.1.2. Electrocorticografía (ECoG)	15
2.2.1.3. Registro intracortical neuronal	15
2.2.2. ELECTROENCEFALOGRAFÍA	16
2.3 INTERFACES CEREBRO COMPUTADOR	18
2.3.1 INTRODUCCIÓN A LAS INTERFACES CEREBRO COMPUTADOR	18
2.3.2 DESCRIPCIÓN DE UNA INTERFAZ CEREBRO COMPUTADOR.....	19
2.3.3 TIPOS DE SEÑALES DE CONTROL DE LAS INTERFACES CEREBRO COMPUTADOR.....	20
2.3.3.1. Potenciales corticales lentos SCP (Slow Cortical Potentials)	21
2.3.3.2. Potenciales evocados P300.....	21
2.3.3.3. Ritmos sensoriomotores (ritmos μ y β).....	22
2.3.3.4. Potenciales evocados visualmente VEP (Visual Evoked Potentials)	22
2.3.4 ICC EXÓGENAS Y ENDÓGENAS	24
2.3.5 ICC SÍNCRONAS Y ASÍNCRONAS	25
2.3.6 MATERIALES Y CONFIGURACIONES PARA UNA ICC BASADA EN SSVEPS	26
2.3.6.1. ICC cableada	27
2.3.6.2. ICC inalámbrica	28
2.3.6.3. Plataformas software de desarrollo para sistemas ICC	29
2.4 RESUMEN	30
3. PLATAFORMA HARDWARE	32

3.1	FUENTE DE ESTIMULOS VISUALES.....	32
3.1.1	descripción de la fuente	32
3.1.2	DISEÑO IMPLEMENTADO	32
3.1.2.1	Sistema microcontrolador	33
3.1.2.2	Controlador de potencia.....	34
3.1.2.3	Estimulos led.....	34
3.1.3	MONTAJE FINAL.....	35
3.2	CASCO DE ELECTROENCEFALOGRAFIA EMOTIV EPOC	36
3.3	ORDENADOR	37
4.	APLICACIÓN SOFTWARE	38
4.1	PREPROCESAMIENTO	40
4.2	CÁLCULO DE CARACTERÍSTICAS	41
4.3	CLASIFICACIÓN.....	46
4.4	RESUMEN	48
5.	PROTOCOLO EXPERIMENTAL.....	49
5.1	CREACIÓN DEL BANCO DE DATOS	49
5.2	SESIONES ON-LINE	50
5.3	INTERFAZ PRINCIPAL	51
5.4	RESUMEN	54
6.	PRUEBAS Y RESULTADOS	55
6.1	CONFIGURACIÓN DE LAS PRUEBAS OFF-LINE	55
6.2	RESULTADOS DE LAS PRUEBAS OFF-LINE	55
6.3	RESULTADOS DE LAS PRUEBAS ON-LINE.....	61
6.4	RESUMEN	63
7.	CONCLUSIONES.....	64
8.	TRABAJO FUTURO	65
	REFERENCIAS	66
	ANEXOS.....	69

ÍNDICE DE FIGURAS

Figura 2-1 Interfaz cerebro computador para el monitoreo de la señales eléctricas cerebrales.	18
Figura 2-2. Diagrama de flujo de una Interfaz Cerebro Computador.	19
Figura 2-3. Configuración de una Interfaz Cerebro Computador. Tomado de [20].	20
Figura 2-4. Casco de adquisición ofrecido por la compañía Compumedics Neuroscan.	27
Figura 2-5. Amplificador de señales EEG ofrecido por la compañía Compumedics Neuroscan.	27
Figura 2-6. Diagrama de la configuración de la ICC implementada.	31
Figura 3-1. Diagrama de la configuración hardware implementada.	32
Figura 3-2. Diagrama de la configuración de los estímulos visuales implementados.	33
Figura 3-3. Tarjeta de desarrollo Arduino UNO R3.	33
Figura 3-4. Controlador mosfet de 4 canales.	34
Figura 3-5. Diagrama del circuito impreso del estímulo LED implementado.	35
Figura 3-6. Fuente de estímulos visuales.	36
Figura 3-7. Emotiv Epoc	36
Figura 3-8. Estándar de localización de electrodos 10-20. Tomada de [28].	37
Figura 4-1. Diagrama de bloques de la aplicación software en configuración offline.	39
Figura 4-2. Diagrama de bloques de la aplicación software en configuración online.	39
Figura 5-1. Procedimiento experimental para la adquisición de la base de datos.	49
Figura 5-2. Procedimiento experimental para la prueba laberinto.	51
Figura 5-3. Interfaz principal online	52
Figura 5-4. Diagrama de flujo del ciclo online.	53
Figura 5-5. Ventana de visualización del entorno 3D prueba Comandos.	54
Figura 5-6. Ventana de visualización del entorno 3D prueba Laberinto.	54
Figura 6-1. Desempeño de las técnicas de extracción de características usando máxima criterion, para diferentes tamaños de la ventana de análisis.	56
Figura 6-2. Desempeño de los métodos implementados vs la desviación estándar de los resultados obtenidos para una ventana de tres segundos.	57
Figura 6-3. Valor máximo de SNR de todas las muestras del banco de datos, cuando fueron bien y mal clasificadas.	59

ÍNDICE DE TABLAS

Tabla 1. Comparación de trabajos similares desarrollados anteriormente	14
Tabla 2. Comparación entre técnicas de registro de actividad cerebral.....	16
Tabla 3. Clasificación en bandas de frecuencia de las señales cerebrales	17
Tabla 4. Comparación entre señales de control de ICC.	21
Tabla 5. Comparación de métodos para construir los estímulos visuales.....	24
Tabla 6. Comparación entre ICC exógena y endógena [16].	25
Tabla 7. Comparación entre ICC síncrona y asíncrona [16].	26
Tabla 8. Comparación entre <i>headsets</i> comerciales.	29
Tabla 9. Canales y acciones efectuadas durante CAR.	40
Tabla 10. Características de filtro pasa banda.	41
Tabla 11. Canales utilizados para cada método.....	41
Tabla 12. Topología de la red neuronal.....	48
Tabla 13. Comparación de las técnicas de extracción de características con máxima criterion.	55
Tabla 14. Comparación de los clasificadores.....	57
Tabla 15. Comparación de SNR para cada ventana de tiempo.....	59
Tabla 16. Comparación de los resultados después de aplicar el criterio del SNR para cada ventana de tiempo.....	60
Tabla 17. Comparación de los resultados después de aplicar el criterio SNR para cada voluntario.....	60
Tabla 18. Rata de éxito y rata de muestras ignoradas en la prueba comandos.	61
Tabla 19. Matriz de confusión prueba comandos.	62
Tabla 20. Tiempo de cada usuario en el laberinto.	62

RESUMEN

Este trabajo describe el desarrollo de una interfaz cerebro computador basada en el paradigma de potenciales de estado estable evocados visualmente (SSVEP, del inglés *Steady State Visual Evoked Potentials*). De esta manera, expone herramientas para el desarrollo de interfaces cerebro computador, y contribuye a la investigación en este tipo de sistemas que tienen como objetivo, entre otros, proporcionar autonomía a las personas con limitaciones físicas y mejorar su calidad de vida.

La interfaz recibe comandos a partir de la interpretación de las señales electroencefalográficas y los ejecuta sobre una silla de ruedas virtual. Cada comando corresponde a uno de los cuatro estímulos visuales presentados al usuario.

Inicialmente se tomaron datos para definir las herramientas de extracción y clasificación de características capaces de definir el conjunto de cinco clases: ir al frente, ir atrás, girar 90° a la izquierda, girar 90° a la derecha y señal no válida. Usando un tamaño de muestra de cuatro segundos el método de combinación de energía mínima (MEC, por sus siglas en inglés) y un clasificador bayesiano, se obtuvo una tasa de éxito del 87%.

Una vez entrenado el sistema de comandos se procedió a tomar nuevas muestras on-line, donde se obtuvo una tasa de acierto del 86.06% usando un tamaño de muestra de cuatro segundos, siendo puesta en marcha con usuarios diferentes a aquellos con los que el sistema fue entrenado.

Palabras clave: Interfaces cerebro computador, potenciales en estado estable evocados visualmente, SSVEP.

ABSTRACT

This work describes the development of a brain-computer interface based on the SSVEP (Steady State Visual Evoked Potentials) paradigm. It exposes tools for the development of brain computer interfaces, and contributes to the research in this type of systems, that aim to provide independence to people with physical disabilities and improve their life quality.

The interface receives commands from the interpretation of the EEG signals and run the commands on a virtual wheel chair. Each command corresponds to one of four visual stimuli presented to the user.

Initially a data set was acquired to define the tools for extraction and classification of the characteristics, to define the set of five classes: go forward, go backward, turn 90 ° to the left, turn 90 ° to the right and invalid signal. Using a time segment of four seconds, the method of Minimum Energy Combination (MEC) and a Bayesian classifier, a success rate of 87% was obtained.

Once the system was trained, new samples were taken online, where a success rate of 86.06% was obtained using a time segment of four seconds and different users from those who participated in the training stage.

Keywords: Brain Computer Interfaces, Steady State Visual Evoked Potentials, SSVEP.

1. INTRODUCCIÓN

Según los resultados del Censo de Población y Vivienda del 2005 proporcionados por el DANE, el 6.4% de las personas en Colombia tienen por lo menos una limitación, y el 44% de esas personas, es decir el 2.8% de la población colombiana, se encuentran limitadas para caminar o para usar brazos y manos [1].

Para la población que padece de algún tipo de deficiencia locomotora resulta difícil o incluso imposible, comunicarse con los dispositivos externos que la rodean, pues usualmente las máquinas se comandan con movimientos que dichas personas no pueden controlar o realizar en lo absoluto; esto implica que deben contar con ayuda constante y ver su autonomía gravemente limitada. Las interfaces cerebro computador buscan permitir la transmisión de intenciones sin necesidad de realizar movimientos, generando independencia y bienestar en las personas que tienen parcial o completamente afectada su motricidad.

En este trabajo de grado se implementó un sistema capaz de interpretar señales electroencefalográficas para establecer intenciones de movimiento de una silla de ruedas virtual; intenciones que transmite el usuario a través de estímulos visuales. Adicionalmente, el sistema estima si las señales adquiridas presentan un alto porcentaje de ruido, caso en el que las señales se ignoran y se otorga al usuario una nueva posibilidad para transmitir su intención.

El objetivo general que se planteó en este proyecto es:

- Desarrollar un sistema para el comando de un dispositivo virtual mediante señales electroencefalográficas generadas por estímulos visuales.

Para lograr este objetivo se propusieron los siguientes objetivos específicos:

1. Establecer las características de las señales EEG útiles para discriminar cuatro tipos de señales SSVEP.
2. Identificar los principales requerimientos de interfaces cerebro computador en aplicaciones afines.
3. Establecer la configuración de la interfaz cerebro computador para el comando del dispositivo virtual.
4. Desarrollar las fuentes generadoras de los estímulos visuales que puedan evocar las señales estacionarias en el cerebro del usuario.
5. Implementar técnicas de procesamiento y clasificación de las señales EEG activadas por estímulos visuales.
6. Definir y desarrollar una aplicación virtual que responda a las señales EEG.
7. Integrar las técnicas de procesamiento y clasificación de las señales EEG con la aplicación virtual.
8. Establecer un protocolo de pruebas para determinar alcances y limitaciones de la interfaz.

El documento que se presenta a continuación comprende cuatro partes fundamentales: marco teórico, descripción del hardware implementado, descripción de las técnicas software implementadas y reporte de resultados.

El capítulo 2 corresponde al marco teórico del proyecto, inicialmente describe los trabajos que se han realizado a nivel nacional e internacional en el campo de interfaces cerebro computador. Luego expone las bases matemáticas y científicas sobre las cuales se fundamenta el funcionamiento del sistema.

El capítulo 3 menciona las plataformas hardware implementadas, describe la construcción de los estímulos visuales y expone un diagrama de bloques que representa la configuración hardware del sistema.

En el capítulo 4 se explican las técnicas software aplicadas a las señales cerebrales con el objetivo de interpretarlas como una intención de locomoción, y se presenta un diagrama que describe el procesamiento implementado.

Finalmente en el capítulo 5 se reporta el protocolo adoptado para la toma de datos, los indicadores de desempeño del sistema y la comparación de su desempeño con otros trabajos. Se presentan los resultados alcanzados para el funcionamiento *off-line* y *on-line* del sistema.

2. MARCO TEÓRICO

Se describen las bases científicas y matemáticas que fundamentan el funcionamiento de la interfaz cerebro computador desarrollada en este proyecto. Inicialmente se mencionan algunos trabajos en el área de las interfaces cerebro computador; después, se introducen las técnicas de monitoreo de la actividad cerebral, especialmente la electroencefalografía; luego se exponen de forma general las características de las interfaces cerebro computador, se identifican las señales cerebrales que comúnmente se usan como señal de control, los tipos de interfaces y los componentes del sistema seleccionado.

2.1 ANTECEDENTES

Debido a los avances que en los años recientes se han logrado en cuanto a precisión y practicidad para las interfaces cerebro computador, la investigación en torno a este tipo de sistemas se ha convertido en un área que crece rápidamente y despierta interés entre los académicos [2]. Una aplicación en neurociencia se presenta en el trabajo “*BKI: Brain Kinect Interface, a New Hybrid BCI for Rehabilitation*” [3], el cual propone una ICC (Interfaz Cerebro Computador) híbrida que combina las señales biomecánicas adquiridas con el sensor Kinetic y las señales SSVEP adquiridas con el casco comercial de adquisición Emotiv EPOC, con el objetivo de que pacientes con discapacidades neuromotoras interactúen en un espacio mediante movimientos y pensamientos y los especialistas puedan realizar valoraciones de aspectos cognitivos y motores.

En cuanto a trabajos de interacción hombre máquina el trabajo titulado “*Comando de un Cursor en 2D Mediante Señales EEG*” [4], tuvo como objetivo implementar una interfaz de control mediante señales EEG que permitiera diferenciar entre el movimiento horizontal, vertical y el click del cursor. Para ello se capturaron ondas Mu y Beta resultantes de la imaginación del movimiento, y el potencial evocado cognitivo P300 generado a partir de un estímulo visual.

El método de potenciales evocados en estado estable ha sido usado en diversos trabajos. El trabajo “*Propuesta de interfaz cerebro computador para el comando de un vehículo autónomo*” [5], presenta una propuesta de una interfaz cerebro computador para comandar un vehículo usando señales electroencefalográficas; además aplica la técnica de detección relacionada a eventos para que el usuario pueda activar y desactivar los estímulos visuales con el fin de reducir la fatiga visual. El sistema discrimina entre 4 clases y se probó en usuarios sanos y en usuarios con alguna discapacidad motora, obteniendo un porcentaje de aciertos del 90%. El trabajo “*Sistema de reconocimiento de patrones de potenciales evocados visuales de estado estacionario*” [6], desarrolló un sistema de reconocimiento de patrones a partir de señales EEG, basado en el paradigma SSVEP, que buscaba discriminar entre dos clases para ser usado en el control básico de videojuegos. Se usó el dispositivo de adquisición USBamp y se obtuvo un porcentaje de aciertos máximo de 97.62% para un tamaño de muestra de 10 segundos. El trabajo “*An SSVEP BCI to Control a Hand Orthosis for Persons with Tetraplegia*” [7], se propone una ICC asíncrona para el control de una órtesis, lo que le da al usuario la posibilidad de mover la órtesis en cualquier momento que lo desee, sin tener que limitarse a señales externas. El sistema se evaluó en siete sujetos sanos, seis de los siete tuvieron un buen control sobre el sistema, y en total se obtuvo un porcentaje promedio de aciertos del 78%. En el futuro se pretende validar este trabajo con personas que padezcan de tetraplejía.

Un desarrollo enfocado en comparar y mejorar las técnicas de procesamiento de señales electroencefalográficas con potenciales en estado estable evocados visualmente es “*Development of SSVEP-based BCI using Common Frequency Pattern to Enhance*” [8], el cual usó el método de patrón de frecuencia común (CFP) para mejorar la tasa de aciertos de una ICC basada en SSVEP. Se implementaron cuatro clasificadores, con una ventana de tiempo de cuatros segundos y en el mejor caso se obtuvo una tasa de éxito del 80% sin usar CFP y del 95% con CFP.

Otro desarrollo es “*VOG- enhanced ICA for SSVEP response detection from consumer grade EEG*” [9], el cual usó la información proporcionada por un video oculográfico y el análisis de componentes independientes (ICA), para abordar el problema de los artefactos presentes en las señales EEG (electroencefalográficas) producidos por los movimientos del ojo. La técnica implementada resalta la necesidad de métodos robustos que eliminen los artefactos en las señales EEG para aumentar la precisión de los sistemas al detectar los SSVEP.

La tabla 1 presenta las principales características de los desarrollos presentados arriba con su respectiva tasa de éxito, el sistema de adquisición, la cantidad de individuos, el de la muestra (en segundos) y la cantidad de comandos que ofrece el sistema.

La tasa de éxito más alta entre los trabajos registrados en la tabla, corresponde al proyecto “*VOG-Enhanced ICA for SSVEP Response Detection from Consumer-Grade EEG*” [9], donde se alcanza un porcentaje de aciertos del 96.38% para una ventana de tiempo de dos segundos, usando el método de análisis de componentes independientes (ICA) y el clasificador de los k vecinos más cercanos, además de información proveniente de un video oculográfico para eliminar artefactos. El trabajo “*The Combination of CCA and PSDA Detections Methods in a SSVEP*”[10] registra una tasa de éxito del 68% para una ventana de tiempo de cinco segundos, siendo el porcentaje de éxito más bajo. En este último se aplicaron las técnicas de análisis de la correlación canónica y análisis del espectro de densidad de potencia, técnicas ampliamente usadas en ICC basadas en SSVEP pero que no proporcionan los mejores resultados.

Tabla 1. Comparación de trabajos similares desarrollados anteriormente

Nombre del trabajo	Año	Sujetos	Casco	Comandos	Tiempo (s)	Éxito (%)	Error (%)
“Research on SSVEP feature extraction based on HHT”[11]	2010	-	-	4	5	88.9	-
					4	86.8	
					3	87.8	
					2	84.5	
“Vog-Enhanced ICA for Ssvep Response Detection from Consumer-Grade EEG” [9]	2014	5	EMOTIV	3	2	96.38	-
“Improving Classification Accuracy of SSVEP based BCI using RBF SVM with Signal Quality Evaluation”[12]	2014	4	EMOTIV	5	5	86	9
					4	84	10
					3	83	14
					2	74	21
					1	62.5	35
“The Combination of CCA and PSDA Detection Methods in a SSVEP-BCI System” [10]	2014	4	SynAmps2	4	5	68	-
					4	64	
					3	62	
					2	56	
					1	39	
“Chromatic SSVEP BCI Paradigm Targeting the Higher Frequency EEG Responses”[13]	2014	3	USBamp	4	5	75	-
					4	67	
					3	58	
					2	50	
					1	32	
“Development of SSVEP-based BCI using Common Frequency Pattern to Enhance System Performance”[8]	2014	16	Neuroscan	2	4	95	-
“Steady State Visually Evoked Potentials Based Brain Computer Interface System”[14]	2014	1	EMOTIV	5	4.5	87	-
“Interface Cérebro Computador Baseada em Ssvep e ERD para o Comando de um Veículo Autônomo”[15]	2014	19	EMOTIV	4		94.2	-

2.2 SEÑALES CEREBRALES Y SU ADQUISICIÓN

En esta sección se expone una breve investigación sobre las técnicas que permiten monitorear la actividad cerebral, haciendo énfasis en la electroencefalografía, la cual permite la adquisición de señales cerebrales a partir de la medición de potenciales eléctricos en el cuero cabelludo. Del mismo modo se describen los tipos de ondas cerebrales y sus características.

2.2.1. TÉCNICAS DE MONITOREO DE LA ACTIVIDAD CEREBRAL

Las interfaces cerebro computador (ICC) miden la actividad cerebral y la convierten en una señal eléctrica. Existen diversas técnicas para monitorear las actividades cerebrales; a continuación se presentan y describen brevemente las técnicas principales que se usan en este tipo de sistemas. Estas técnicas miden las actividades cerebrales electrofisiológicas que ocurren cuando hay un intercambio de información entre transmisores electroquímicos de neuronas.

2.2.1.1. Electroencefalografía (EEG)

La electroencefalografía es una técnica no invasiva y fácil de usar que mide el promedio de la actividad eléctrica cerebral en diferentes partes del cerebro. Para registrar estas señales se coloca un set de electrodos en el cuero cabelludo. Sin embargo las señales se ven fuertemente afectadas por artefactos, que son alteraciones producidas por múltiples causas como los movimientos musculares, oculares, entre otros; generados dentro del cráneo y en el cuero cabelludo, además de que la señal tiene que atravesar varias capas antes de llegar al sensor, razón por la cual la señal adquirida es débil y de baja calidad [16].

2.2.1.2. Electrocorticografía (ECoG)

Es una técnica que mide la actividad eléctrica generada en la corteza cerebral, usando electrodos directamente conectados en la superficie del cerebro. Las señales obtenidas tienen mayor amplitud y robustez que las obtenidas mediante EEG, pues son poco afectadas por los artefactos que se producen internamente dentro del cráneo, además pueden tener una mayor resolución espacial y temporal. Sin embargo, se trata de una técnica invasiva que es difícil de aplicar y representa riesgos para la salud del usuario [16].

2.2.1.3. Registro intracortical neuronal

Es una técnica invasiva que trabaja con neuroimágenes, midiendo la actividad eléctrica de la materia gris del cerebro. Para ello se implanta un arreglo de microelectrodos dentro de la corteza cerebral, lo que permite medir el potencial individual de neuronas o campos eléctricos localizados de neuronas. Las señales son de alta calidad y resolución temporal, pero se pueden ver afectadas por la reacción de la membrana que se encuentra en contacto con los microelectrodos [16].

En la tabla 2 se compara el rendimiento y los datos más importantes de las tres técnicas mencionadas, tomados del libro [16], donde se evidencia que las técnicas invasivas ofrecen una mayor resolución temporal y espacial.

Tabla 2. Comparación entre técnicas de registro de actividad cerebral.

Método	Resolución temporal	Resolución espacial	Riesgo	Portabilidad
EEG	~0.05 s	~10 mm	No invasivo	Portable
ECoG	~0.003 s	~1 mm	Invasivo	Portable
Registro intracortical neuronal	~0.003 s	~0.5 mm-0.005 mm	Invasivo	Portable

No obstante, los métodos invasivos, presentan también muchos inconvenientes, como la aceptación de la membrana a los microelectrodos, la conexión no cableada entre los microelectrodos y un dispositivo externo hardware para evitar riesgos de infección, entre otros. Además, implantar microelectrodos dentro del cráneo conlleva importantes riesgos para la salud, por lo que restringe su uso en ambientes experimentales. Dadas estas condiciones, la electroencefalografía es la técnica más usada, con una alta portabilidad, ningún riesgo para los usuarios, suficiente resolución temporal y costo relativamente bajo.

La interfaz desarrollada en este proyecto usa la electroencefalografía para obtener información de la actividad cerebral, por esta razón, se describirá de forma más detallada en la siguiente subsección.

2.2.2. ELECTROENCEFALOGRAFÍA

El descubrimiento de la electroencefalografía se le atribuye al científico alemán Hans Berger quien en 1929 publicó la primera medición de actividad eléctrica cerebral en humanos. La electroencefalografía se convirtió después en una de las técnicas para detectar disfunciones y patologías del sistema nervioso central [17].

Una señal electroencefalográfica mide la actividad cerebral causada por las corrientes que fluyen en medio de excitaciones sinápticas (las cuales dan lugar a la comunicación entre neuronas), en un gran número de neuronas, en diferentes partes del cerebro [18], siendo las células piramidales, que son aquellas que se hallan en la corteza cerebral, las que generan la parte más fuerte de la señal EEG [19].

La información que transmite una célula cerebral a través del axón se llama potencial de acción o impulso eléctrico, tiene una duración de 5 a 10 ms y es causado por un intercambio de iones en la membrana celular que genera temporalmente una diferencia de potencial en la misma.

Para medir la variación de los potenciales eléctricos que se generan en la corteza cerebral, se coloca un arreglo de electrodos, hechos de un material conductor como plata u oro, sobre el cuero cabelludo, y se mide la diferencia de potencial, ya sea entre pares de electrodos o entre cada electrodo respecto a un electrodo pasivo de referencia. La actividad eléctrica medida tiene una amplitud de tan solo 30 - 100 μ V, debe ser filtrada y amplificada, y posee información no sólo sobre las acciones funcionales del cerebro sino también sobre el estado de todo el cuerpo.

Berger además encontró que la forma y frecuencia de las ondas cerebrales podía relacionarse con las actividades y los estados de conciencia, e introdujo lo que él llamó las oscilaciones alfa y beta. Posteriormente en el año 1938, Jasper y Andrews introdujeron el término “gamma” para referirse a las ondas con frecuencias por encima de 30 Hz,

y en 1936 Walter introdujo las ondas teta y delta [19]. A pesar de que ninguna de estas oscilaciones es emitida de forma exclusiva, se torna predominante dependiendo del estado de conciencia del sujeto. En la tabla 3 se registran las 5 bandas de frecuencias en que se dividen las oscilaciones cerebrales y sus características principales.

Tabla 3. Clasificación en bandas de frecuencia de las señales cerebrales

Tipo de onda	Banda de frecuencia (Hz)	Principales características
Ondas delta	0,5 - 4	Son las ondas más lentas y se presentan cuando se duerme profundamente.
Ondas teta	4 – 8	Se relacionan con el estrés emocional, la decepción, la frustración o la ineficiencia; y las más lentas representan la diferencia entre el estado de estar despierto o dormido. También pueden estar relacionadas con la inspiración o el estado de meditación profunda.
Ondas alfa	8 - 13	Reflejan principalmente el procesamiento visual que ocurre en la región occipital del cerebro. Se presentan en estados de relajación e inactividad mental, se hacen más eminentes con los ojos cerrados y se eliminan o reducen al abrir los ojos, escuchar un sonido no familiar o concentrarse.
Ondas beta	13 - 30	Se asocian a los estados de concentración, actividad mental, atención, solución de problemas concretos. Un alto nivel de estas ondas puede adquirirse cuando un sujeto se encuentra en estado de pánico, ansiedad o tensión. Se encuentran principalmente en la región central y en la región frontal del cerebro.
Ondas gamma	>30	Están relacionadas con el mecanismo de la conciencia, que integra distintas funciones cerebrales en percepciones coherentes; y también se encuentran relacionadas con los procesos cognitivos, de atención y de percepción. Tienen una amplitud muy baja y se encuentran localizadas en el área anterior central del cerebro.

Como se indica en la tabla, las ondas alfa se encuentran en la región occipital del cerebro y reflejan el procesamiento visual, por lo tanto, los potenciales evocados en estado estable con estimulación visual son más prominente en esta banda de frecuencia, siendo en este mismo sentido las ondas de mayor interés para cumplir el objetivo de este trabajo.

2.3 INTERFACES CEREBRO COMPUTADOR

A lo largo de esta sección se presenta una descripción acerca de las interfaces cerebro computador, sus aplicaciones, características y los fundamentos básicos de su funcionamiento. También se hace una comparación de diferentes señales que se suelen usar como señal de control de este tipo de sistemas, haciendo énfasis en los potenciales de estado estable.

2.3.1 INTRODUCCIÓN A LAS INTERFACES CEREBRO COMPUTADOR

El objetivo de las Interfaces Cerebro Computador no es determinar las intenciones del usuario mediante el espionaje de la actividad cerebral, sino usar la actividad cerebral de manera que el usuario pueda modularla y controlar una salida del sistema. De esta forma, el usuario comunica una intención a un computador, sintetizador de voz o prótesis, sin usar un canal muscular; lo cual resulta muy atractivo para aquellas personas que sufren de limitaciones motrices severas.



Figura 2-1 Interfaz cerebro computador para el monitoreo de la señales eléctricas cerebrales.

Entre los desafíos que se abordan en el desarrollo de este tipo de sistemas E. A. Larsen [17] lista los siguientes:

- Las características de las ICC contienen mucho ruido y valores atípicos, debido a que las señales EEG se ven afectadas por artefactos provenientes de las señales electromiográficas (generadas a partir del movimiento de los músculos) y señales electrooculográficas (generadas a partir del movimiento ocular), siendo su relación señal a ruido pobre.
- Los vectores de características de estos sistemas suelen ser de grandes dimensiones debido a que se extraen muchas características de diferentes canales y segmentos de tiempo.
- Las características no son estacionarias y por lo tanto deben contener información sobre el tiempo. Esto se debe que las señales EEG varían rápidamente en el tiempo y especialmente, entre sesiones.

- Los sets de entrenamiento son pequeños, pues el entrenamiento demanda mucho tiempo y disposición por parte del usuario.

El desarrollo de una ICC se resume en cuatro etapas: la adquisición de la señal, el procesamiento, la clasificación y la interacción con una maquina o computador. En la primera etapa se adquiere un conjunto de datos a partir de la medición de la actividad cerebral del usuario; en la siguiente etapa, la señal se amplifica, se filtra y se procesa para construir un vector con valiosas características, que permitan discriminar las señales pertenecientes a diferentes clases; en la etapa de clasificación, se usa el vector de características para clasificar la señal adquirida entre cierto número determinado de clases; y finalmente, la interfaz de control permite que, según la clasificación de la señal, se genere un comando coherente que se traslada a un computador o dispositivo externo. La figura 2-2 muestra el diagrama de flujo en una ICC común y en la siguiente subsección se explicará de forma más detallada ese tipo de sistemas.




Figura 2-2. Diagrama de flujo de una Interfaz Cerebro Computador.

2.3.2 DESCRIPCIÓN DE UNA INTERFAZ CEREBRO COMPUTADOR

Una interfaz típica para la adquisición, procesamiento y transmisión de las señales cerebrales es presentada en la figura 2-3, la cual es tomada de [20]. Aquí los *EEG Sensors* se encargan de la adquisición de las señales y posteriormente el bloque *Analog Front End* se encarga de su acondicionamiento y tratamiento. Este último bloque, comprende un filtro rechazo de banda para frecuencias de 50 y 60 Hz, con el fin de eliminar la posible contaminación proveniente de la red de alimentación, y un amplificador que incrementa el nivel de la señal. Luego, en el bloque *Digital System*, se multiplexan las señales para que se pueda realizar la conversión análogo-digital de múltiples canales usando un solo conversor. La frecuencia de muestreo del conversor análogo-digital suele encontrarse entre 100 y 1024 Hz y es determinada por el microprocesador y la velocidad de transmisión entre *EEG Acquisition part* y *Translation part*. Finalmente la señal entregada por el microprocesador es transmitida (en este caso de forma inalámbrica usando un *Wireless Transmitter*) hacia el bloque *Translation Part* que debe recibirla, procesarla y traducirla en características que se interpreten como comandos ejecutables en una aplicación (*Application Program*).




Figura 2-3. Configuración de una Interfaz Cerebro Computador. Tomado de [20].

2.3.3 TIPOS DE SEÑALES DE CONTROL DE LAS INTERFACES CEREBRO COMPUTADOR

Las señales eléctricas adquiridas por las interfaces cerebro computador están relacionadas con múltiples procesos cognitivos que en su mayoría aún resultan incomprensibles y de los cuales se desconoce su origen. Sin embargo, se han encontrado señales cerebrales que pueden generarse de tal manera que el usuario aprenda a modularlas según lo desee, para permitir que la interfaz interprete sus intenciones.

Estas señales pueden considerarse como las señales de control de las ICC y actualmente se usan las siguientes: potenciales evocados visualmente (VEP), potenciales corticales lentos (SCP), potenciales evocados P300 y ritmos sensoriomotores [16]. La tabla 4 presenta una lista de las señales de control y sus características más importantes. Posteriormente se dará una breve descripción de cada tipo de señal, siendo la descripción de los potenciales evocados visualmente más detallada, gracias a que se escogió como la señal de control de la interfaz cerebro computador que se desarrolló en este proyecto.

Tabla 4. Comparación entre señales de control de ICC.

Señal	Fenómeno fisiológico	Número de elecciones	Entrenamiento	Rata de transferencia de información
VEP	Modulación de la señal cerebral en la corteza visual	alta	No	60-100 bits/min
SCP	Cambios lentos de voltaje en las señales cerebrales	baja (2 o 4)	Si	5-12 bits/min
P300	Picos positivos debido a estímulos infrecuentes	alta	No	20-25 bits/min
Ritmos sensoriomoto-res	Modulación de dichos ritmos, sincronizados a las actividades motoras	baja (2, 3, 4, 5)	Si	3-35 bits/min

2.3.3.1. Potenciales corticales lentos SCP (Slow Cortical Potentials)

Los potenciales corticales lentos, son cambios lentos de voltaje de la señal EEG que duran desde un segundo a varios segundos. Pertenecen a la parte de la señal EEG que tiene una frecuencia por debajo de un Hz. Los potenciales corticales negativos están relacionados con el aumento de la actividad neuronal y los positivos con el decrecimiento de la actividad en células individuales. El usuario puede entrenarse para generar estos potenciales de forma voluntaria. Los porcentajes de éxito que han conseguido sistemas que usan los SCPs como señales de control varían entre el 70 y 80%, los cuales son valores aceptables, no obstante la tasa de transmisión de información es baja y se requiere mucho entrenamiento y práctica continua [16].

2.3.3.2. Potenciales evocados P300

Los potenciales evocados P300 son picos positivos en la señal EEG que se producen 300 ms después de que se perciba un estímulo inusual en medio de varios estímulos frecuentes. Algunos estudios han probado que entre menos probable sea el estímulo, más grande es la amplitud del pico que se genera en la señal EEG [16]. Las ICC que usan P300 no requieren entrenamiento, sin embargo cuando el usuario se acostumbra al estímulo infrecuente la amplitud del pico decrece.

Una aplicación típica de ICC que usa los potenciales P300 como señal de control implica una matriz de números, símbolos o comandos, que pertenecen a una columna y fila que parpadean con una frecuencia aleatoria. Esta aplicación presenta la desventaja de que para seleccionar un solo carácter la columna o fila a la que pertenece el símbolo debe parpadear repetidas veces, razón por la que el número de elecciones por minuto es bajo.

A diferencia de la respuesta de los potenciales evocados visualmente (VEP), la respuesta P300 no se ve mayormente afectada cuando el usuario no mira fijamente el símbolo deseado, lo cual tiene importantes aplicaciones clínicas para aquellos pacientes que no pueden controlar el movimiento de los ojos.

2.3.3.3. Ritmos sensoriomotores (ritmos μ y β)

Los ritmos sensoriomotores comprenden dos tipos de oscilaciones, μ y β , que varían o se modulan cuando la actividad cerebral está relacionada con cualquier tarea motora, aunque es posible modular la amplitud de los ritmos sensoriomotores sin realizar ningún movimiento. Las oscilaciones μ corresponden a la banda de frecuencias entre 7-13 Hz y las oscilaciones β a la banda de frecuencias entre 13-30 Hz. Este tipo de señal, se ha usado para controlar ICC, ya que es posible aprender a modularla de forma voluntaria, como resultado de la imaginación de un acto motriz sin realizar movimiento alguno [16].

Para modular los ritmos sensoriomotores, las personas tienden a imaginar imágenes visuales relacionadas con movimientos reales, lo cual no resulta suficiente porque estos patrones difieren de los patrones de modulación reales, que se producen cuando se ejecuta una acción motriz [16]. Las personas deben concentrarse en experiencias kinestésicas y no en la representación visual de acciones.

2.3.3.4. Potenciales evocados visualmente VEP (Visual Evoked Potentials)

Los potenciales evocados visualmente, son modulaciones que se presentan en la corteza visual del cerebro, la cual se encuentra ubicada en el lóbulo occipital y se encarga de procesar la información visual. Se generan cuando la persona concentra su atención en un estímulo visual repetitivo, son fáciles de detectar gracias a que la amplitud de estos potenciales aumenta cuando el estímulo se acerca al centro del campo visual.

Los potenciales evocados visualmente pueden clasificarse según la frecuencia del estímulo. Un estímulo visual con una frecuencia menor a seis Hz provoca potenciales transitorios evocados visualmente TVEP (*Transient Visual Evoked Potentials*), mientras que un estímulo con una frecuencia por encima a seis Hz genera potenciales de estado estable evocados visualmente, SSVEP (*Steady State Visual Evoked Potentials*) [16]. Estos últimos, resultan atractivos como señal de control para interfaces cerebro computador, gracias a que son menos susceptibles que los TVEP en cuanto a los artefactos producidos por el parpadeo, el movimiento de los ojos y el ruido electromiográfico; requieren poco o ningún entrenamiento y presentan una alta tasa de transmisión de información. Además, los parámetros de amplitud y fase de los componentes frecuenciales de los SSVEP permanecen casi constantes por periodos largos de tiempo.

Las ICC que emplean los SSVEP como señal de control, trabajan con un estímulo visual repetitivo que pertenece generalmente a una de las siguientes tres categorías principales [21]:

- Estímulos de luz: se implementan usando fuentes de luz que pueden modularse a una frecuencia específica. Por lo general, estas fuentes de luz son controladas por un circuito electrónico que permite que reproduzcan con precisión cualquier secuencia.
- Estímulos gráficos individuales: se implementan en la pantalla de un computador y comprenden la aparición y desaparición de una figura como un rectángulo, cuadrado, flecha, en medio de un fondo. La frecuencia del estímulo corresponde al número de ciclos completos por segundo.
- Estímulos de reversión del patrón: también se implementan en la pantalla de un computador y presentan la alternación de patrones gráficos. Consiste en la alternación de por lo menos dos patrones y por lo general hace uso de tableros de ajedrez o tableros de líneas.

Si se trabaja con estímulos de luz, los potenciales evocados producen una señal que tiene forma sinusoidal, y una frecuencia fundamental correspondiente a la frecuencia de parpadeo del estímulo, mientras que si se trabaja con patrones gráficos, los potenciales aparecen con una tasa de frecuencia que corresponde a la frecuencia de reversión de los patrones y sus armónicos.

Como se mencionó anteriormente, los SSVEP se producen con fuentes de luz que parpadeen a una frecuencia mayor a seis Hz, presentando ciertas ventajas y desventajas dependiendo de qué tan alta o baja sea la frecuencia de parpadeo. Se pueden distinguir tres rangos de frecuencia: el rango de frecuencias bajas que llega hasta los 12 Hz, el rango medio que corresponde a frecuencias entre 12 y 30 Hz y el rango alto para frecuencias mayores a 30 Hz [22]. Los estímulos que pertenecen al rango bajo provocan SSVEP con una amplitud mayor que los estímulos en rango medio, por lo que es sencillo extraer de la señal cerebral los potenciales evocados. La desventaja radica en que los estímulos con frecuencias bajas resultan molestos para el usuario y después de un periodo de tiempo pueden volverse insoportables. En cambio los estímulos visuales en el rango medio son más agradables para el usuario pero provocan SSVEP con menor amplitud, por lo que se hace necesario algoritmos computacionales más complejos para extraer las componentes deseadas de la señal cerebral. Además se ha demostrado que el uso de estímulos de rango bajo y medio provocan ataques epilépticos [31]. Finalmente, el rango de altas frecuencias es el más cómodo para el usuario, causa la mínima fatiga visual, pero produce potenciales evocados muy débiles que son difíciles de detectar.

Los métodos más populares para implementar los estímulos visuales, que generan los potenciales en estado estable en las señales cerebrales, hacen uso de LED, LCD o CRT; la tabla 5 presenta las ventajas y desventajas más relevantes de cada uno. Los estímulos implementados usando LED son más confiables y los potenciales que evocan presentan una mayor amplitud en su frecuencia fundamental y armónicos, por otra parte, la implementación de los estímulos usando LCD o CRT resulta más sencilla ya que se usan pantallas y no es necesario desarrollar hardware dedicado a estos estímulos, sin embargo se ven afectados por las tasas de refresco de dichas pantallas [16]. Por lo anterior, se escogió la implementación en LED como la indicada para este trabajo.

Tabla 5. Comparación de métodos para construir los estímulos visuales.

Método	Ventajas	Desventajas
LED	Presenta mayor amplitud en la frecuencia fundamental. Es más fácil de ajustar una frecuencia exacta. Frecuencia estable y constante de parpadeo.	Requiere hardware dedicado. La aplicación ICC y la generación de estímulos están separadas.
LCD CRT	Se pueden integrar la generación de estímulos dentro de la aplicación ICC. No requiere hardware externo. Pueden llegar a ser más cómodos al usuario.	Los estímulos no son tan estables y se ven afectados por las tasas de refresco de las pantallas. Aparecen componentes de alta frecuencia (CRT) [22] Menos amplitud en la frecuencia fundamental.

2.3.4 ICC EXÓGENAS Y ENDÓGENAS

A partir de la naturaleza de la señal que ingresa a la interfaz cerebro computador se puede clasificar como exógena o endógena. Los sistemas exógenos usan la actividad neuronal provocada en el cerebro por estímulos externos, no requieren entrenamiento intensivo y alcanzan tasas de transferencia de información de 60 bits/min. Por lo general usan como señal cerebral los potenciales de estado estable evocados visualmente (SSVEP) o P300. Por otra parte, los sistemas endógenos se basan en la autorregulación de los ritmos cerebrales sin presencia alguna de estímulos externos [16]. A través de la neuro-realimentación el usuario puede aprender a modular sus señales para generar un patrón específico; usualmente usan como señal de control los potenciales corticales lentos o los ritmos sensoriomotores. Estos sistemas poseen una baja tasa de transferencia de información de 20-30 bits/min. En la tabla 6 se muestran las ventajas y desventajas de las interfaces cerebro computador dependiendo de su tipo, exógena o endógena.

Tabla 6. Comparación entre ICC exógena y endógena [16].

Tipo	Señal cerebral	Ventajas	Desventajas
ICC Exógena	SSVEP P300	Mínimo entrenamiento Alta Tasa de transferencia de información (60 bits/min) Configuración de la señal de control fácil y rápido.	Atención permanente al estímulo. Puede causar fatiga en los usuarios.
ICC Endógena	SCP Ritmos sensoriomotores	Útil para pacientes con daños en órganos sensoriales Independientes de estímulos Pueden ser operados a voluntad libre del usuario.	Mucho tiempo de entrenamiento. (Semanas y/o meses). No todos los usuarios alcanzan el control. Baja Tasa de transferencia de información (20-30 bits/min)

2.3.5 ICC SÍNCRONAS Y ASÍNCRONAS

Además de ser exógena o endógena una ICC puede ser síncrona o asíncrona; síncrona se entiende como aquella que hace la captura de datos por un periodo definido de tiempo y el usuario sabe cuándo se están tomando los datos y cuando no; las interfaces asíncronas toman los datos de manera continua, tal que los datos se analizan en todo momento; estos sistemas, si bien pueden ser más cómodos para el usuario, llegan a ser muy complejos de implementar. En este trabajo por simplicidad se abordó una configuración de tipo síncrona. En la tabla 7 se presentan las ventajas y desventajas de ambas configuraciones.

Tabla 7. Comparación entre ICC síncrona y asíncrona [16].

Tipo	Ventajas	Desventajas
ICC SÍNCRONO	Simple diseño y fácil de evaluar su desempeño. El usuario puede evitar generar artefactos como parpadeos o movimientos indeseados, pues pueden hacerlos cuando no se adquiere la señal.	No ofrece un modo natural de interacción.
ICC ASÍNCRONO	No debe esperar por señales externas. Ofrece un modo más natural de interacción.	Muchos más complicados de diseñar. Evaluación de desempeño más complicada.

2.3.6 MATERIALES Y CONFIGURACIONES PARA UNA ICC BASADA EN SSVEPS

Dentro de los sistemas ICC que usan EEG hay ciertos elementos que son comunes a todos los sistemas independientemente de la aplicación o enfoque que puedan tener; toda ICC se compone de dos partes [20]:

1. Una parte comprende la adquisición de la señal, que cuenta con mínimo tres electrodos, los dispositivos que la transmiten y los circuitos que se encargan de amplificarla y convertirla de formato analógico al digital.
2. La otra parte comprende el procesamiento y la traducción de la señal, y normalmente se ejecuta en dispositivos computacionales con alto poder de procesamiento, que se encargan de tratar la información, traducirla a una intención y controlar el programa de aplicación; dispositivos como computadores, laptops y smartphones.

En cuanto a la forma cómo el sistema comunica las señales biológicas al dispositivo de computación, los sistemas ICC se pueden clasificar como cableados o inalámbricos. A continuación se describen ambos tipos.

2.3.6.1. ICC cableada

Muchos sistemas ICC clásicos usan cables para comunicar las señales al dispositivo de aplicaciones y procesamiento, este tipo de sistemas vienen acompañados de un dispositivo que contiene, un robusto amplificador de señales biológicas, un conversor análogo-digital y un circuito encargado del pre procesamiento análogo. Las configuraciones cableadas son más complicadas pues el número de cables necesarios corresponde a la cantidad de electrodos, número que puede variar desde 3 hasta más de 100 electrodos, de forma que en caso de usar muchos electrodos el tiempo de preparación para la adquisición de los datos es generalmente largo. Lo anterior, sumado al hecho de que la movilidad del paciente o usuario se ve restringida por la distancia de los cables, hace que las interfaces cableadas solo tengan lugar en entornos controlados como laboratorios o clínicas; pero cabe resaltar que la fiabilidad de los resultados obtenidos en estas configuraciones es más alta que la obtenida en configuraciones inalámbricas [20].

En la figura 2-4 se presenta un ejemplo de un casco de adquisición cableado ofrecido por la compañía Compumedics Neuroscan, y la figura 2-5 muestra un ejemplo de un dispositivo amplificador de señales biológicas ofrecido por la misma compañía, usado en el proyecto de R. Wang, W. Wu, K. Iramina, y S. Ge (R. Wang, W. Wu, K. Iramina, S. Ge, 2014).



Figura 2-4. Casco de adquisición ofrecido por la compañía Compumedics Neuroscan.



Figura 2-5. Amplificador de señales EEG y potenciales relacionados a eventos (ERP, *Event Related Potential*) ofrecido por la compañía Compumedics Neuroscan.

2.3.6.2. ICC inalámbrica

Los sistemas ICC inalámbricos nacieron para eliminar la necesidad de conexión física por medio de cables entre la adquisición y el procesamiento de los datos, y de esta forma mejorar la experiencia del usuario, la portabilidad del sistema, y por lo tanto, su aplicabilidad en entornos cotidianos y finalmente en la vida diaria de los usuarios. Hoy en día se están desarrollando aplicaciones como cursores, interpretadores de palabras y videojuegos que exigen sistemas portables y amables con el usuario [20].

Debido a las ventajas que presenta este tipo de configuración en cuanto a comodidad y asequibilidad para el usuario, el sistema desarrollado en este proyecto implementa una interfaz cerebro computador inalámbrica. En la siguiente sección se presenta una breve comparación de las ICC inalámbricas disponibles en el mercado.

Actualmente existen varias soluciones en el mercado que permiten desarrollar ICC usando una configuración inalámbrica, y que incluyen la adquisición de la señal, desde el casco electroencefalográfico hasta el equipo de computación. Empresas como Emotiv, NeuroSky, MyndPlay y Muse technology ofrecen productos con dichas características de forma comercial. En la tabla 8 se muestra un resumen de las características más importantes de algunos cascos electroencefalográficos comerciales. En esta tabla el casco Emotiv EPOC se destaca en la mayoría de características, excepto en su precio y el ancho de banda en cual trabaja. Lo anterior sumado a su disponibilidad en el Laboratorio de Visión Artificial y Procesamiento de Señales de la Universidad del Valle propició que se eligiera para el desarrollo de este trabajo.

Tabla 8. Comparación entre *headsets* comerciales.

Características	Emotiv EPOC[23]	NeuroSkyMind Wave	MyndPlayBrainband	Muse
Numero de electrodos	16	3	4	9
Tasa de muestreo	128SPS(2048 Hz Internos)	512 Hz	512 Hz	220 Hz
Ancho de banda	0.2 - 45Hz, Filtros notch en 50 Hz y 60 Hz	3Hz – 100Hz	-	1hz-100hz
Resolución	14 bits 1 LSB = 0.51 μ V	12 bits.	-	-
Rango de entrada	8400 μ V (pp)	1mV pp	-	2 mV pp.
Conectividad	Wireless Propietario 2.4GHz band.	2.420 - 2.471GHz RF frecuencia.	-	Bluetooth
Vida de la batería	12 horas.	6 horas.	10 horas.	5 horas
Precio	600 Dólares	80 Dólares	£199.00	299 Dólares

2.3.6.3. Plataformas software de desarrollo para sistemas ICC

En la actualidad existen varias plataformas de desarrollo para la implementación de ICC, dichas plataformas permiten integrar los procesos de adquisición, procesamiento y aplicación. Gracias a que ya se contaba con experiencia programando en la plataforma Matlab y a las facilidades que ofrece en el procesamiento de señales, se escogió esta herramienta para implementar las técnicas de procesamiento y clasificación, y además, la aplicación de la ICC, la cual comprende una interfaz gráfica que simula el movimiento de una silla de ruedas virtual a partir del resultado entregado por la etapa de clasificación.

A continuación se describen algunas de las plataformas más populares [24].

- BCI 2000

BCI 2000 es un software de propósito general para investigación en ICC, puede ser usado para adquisición de datos, presentación de estímulos y aplicaciones de monitoreo cerebral [24].

Posee soporte para 19 sistemas hardware de adquisición de datos producidos por diferentes fabricantes, se puede integrar con Matlab para correr scripts directamente desde Matlab.

Adicional al hardware para EEG se puede también registrar actividad de otros dispositivos como Joysticks, teclados seguidores de ojo. De esta plataforma se resalta el hecho de que se viene desarrollando desde el año 2000 por lo que existe mucha documentación disponible.

- OpenVibe

OpenVibe es un software gratis y de código abierto usado para el diseño, prueba y uso de ICC. OpenVibe posee una interfaz gráfica fácil de usar, permite diferenciar tres tipos de usuario: investigadores, desarrolladores y clínicos, para adaptarse a las diferentes necesidades que puedan tener. Posee varias herramientas para el desarrollo de entornos 2D y escenarios de ejemplo para tareas de neurorealimentación. Funciona en Windows y Linux.

- Matlab

La popularidad de Matlab es innegable, aún el área de la neurociencia; en los últimos años se han desarrollado diversos paquetes que pueden ser usados dentro de Matlab para implementación de ICC. El prototipado rápido es uno de los mayores atractivos de Matlab y es por esto que ha sido popular en el desarrollo de ICC. Los Toolbox más populares de Matlab para el desarrollo de ICC son [25]:

EggLab: Un ambiente de análisis general y offline para EEG y otras señales electrofisiológicas, posee un ambiente para el procesamiento de estas señales basado en un menú interactivo y scripts corriendo dentro de Matlab. EggLab provee líneas de comando y una interfaz gráfica interactiva que brinda flexibilidad e interactividad al usuario para procesar sus datos.

Posee gran cantidad de métodos para el análisis de señales EEG.

BCILab: Es un toolbox de código abierto para la investigación avanzada en ICC, sus interfaces gráficas y scripts proveen acceso a una vasta colección de métodos bien establecidos para el filtrado de la señal, procesamiento y extracción de características.

BCILab está menos orientado al uso comercial y más a la investigación; además este toolbox permite el análisis online o en tiempo real de las señales, siendo atractivo para los proyectos. Es posible usarlo en conjunto con otros toolbox como EggLab y extender sus capacidades.

2.4 RESUMEN

De lo dicho hasta ahora se tiene que este trabajo de grado trabaja con una interfaz cerebro computador inalámbrica y síncrona. La señal de control de la interfaz se basa en los potenciales de estado estable evocados visualmente, que se generan en el cerebro después de que el sujeto enfoca su mirada a uno de los cuatro estímulos visuales que parpadean a 7.02, 9.07, 13.15 y 15.2 Hz; el usuario puede modular la señal EEG a partir del estímulo visual que decide enfocar. Y finalmente, los métodos de procesamiento y clasificación de la señal se implementaron en la

plataforma software Matlab, así como también la aplicación virtual que representa gráficamente el comando identificado por el sistema. La figura 2-6 presenta una descripción gráfica del sistema implementado.




Figura 2-7. Diagrama de la configuración de la ICC implementada.

3. PLATAFORMA HARDWARE

La configuración hardware desarrollada está compuesta de tres módulos que se ilustran en la figura 3-1: la fuente de estímulos visuales, el casco de electroencefalografía y el sistema de procesamiento. En esta sección se explicará con detalle cada uno de los módulos.




Figura 3-1. Diagrama de la configuración hardware implementada.

3.1 FUENTE DE ESTIMULOS VISUALES

Los estímulos visuales son los responsables de provocar los potenciales en estado estable en las señales cerebrales. A continuación se presenta el diseño y desarrollo de la fuente de estímulos visuales, se describen los elementos que la componen, se analizan sus prestaciones y características finales.

3.1.1 DESCRIPCIÓN DE LA FUENTE

Las ICC basadas en SSVEP requieren fuentes de luz que parpadeen a una frecuencia en el rango entre 6-50 Hz de forma continua y estable para garantizar la existencia de potenciales evocados en las señales cerebrales [22]. La tecnología LED permite controlar la frecuencia de parpadeo y el ciclo útil de la señal de luz digitalmente, por ello es comúnmente usada en este tipo de sistemas [16]. Además, la intensidad de la luz que genera contrasta con el entorno en que se encuentra el usuario, lo que favorece la generación de los potenciales en estado estable.

3.1.2 DISEÑO IMPLEMENTADO

El sistema fue diseñado de tal manera que pudiese cumplir los requisitos de diseño, y que además fuese reutilizable, fácil de modificar, personalizar y de bajo costo.

Este diseño se basa en el ejemplo presentado por Aboul Ella Hassanien y Ahmad Taher Azar en el libro Brain-Computer Interfaces: Current Trends and Applications [26]. En la figura 3-2 se presenta el diagrama de bloques de la fuente de estímulos visuales desarrollada.

El sistema se compone de la plataforma de procesamiento Arduino Uno, la fuente de poder para los estímulos LED, el controlador de potencia y los arreglos de matrices LED. La programación se hizo vía interfaz USB usando el entorno de desarrollo de Arduino. Además, dicha interfaz USB también permite la comunicación serial entre el

Arduino y la aplicación software de la ICC, lo cual fue útil en el momento de sincronizar la aplicación software con el encendido y apagado de los estímulos.




Figura 3-2. Diagrama de la configuración de los estímulos visuales implementados.

3.1.2.1 SISTEMA MICROCONTROLADOR

Arduino es una plataforma tipo hardware de código abierto, basada en microprocesadores de Atmel más específicamente en el ATmega 328 para el caso del Arduino Uno. El Arduino Uno posee 14 entradas o salidas digitales de las cuales 6 se pueden usar como PWM [27]. La programación de arduino es sencilla y se hace por medio de sketches cargados al microprocesador usando un entorno de programación propietario.




Figura 3-3. Tarjeta de desarrollo Arduino UNO R3.

El Arduino Uno es el responsable de generar señales PWM estables, con frecuencias y ciclo útil fijo, para cada uno de los estímulos LED implementados.

Para la generación del PWM de cada uno de los estímulos, el sketch trabaja con un contador libre en milisegundos y constantes de tiempo (una por cada estímulo) que especifican el número de conteos en milisegundos requeridos para conmutar la salida PWM respectiva.

Las constantes de tiempo son el elemento más importante dentro del funcionamiento del programa, pues definen la frecuencia de parpadeo de cada estímulo. La ecuación 3.1 describe el periodo T de la señal PWM, donde f es la frecuencia de oscilación que se desea configurar para el estímulo.

Para tener un ciclo útil del 50% se divide el periodo de la señal en dos, lo que significa que la mitad del periodo el LED permanecerá encendido, momento en que el PWM conmuta y apaga el LED por la mitad restante. Para

finalmente obtener el valor de la constante de tiempo en milisegundos se multiplica este resultado por 1000 como muestra la ecuación 3.2 [26].

$$T(s) = \frac{1}{f} \quad (3.1)$$

$$interval(ms) = \frac{T}{2} * 1000 \quad (3.2)$$

Para concretar, el Arduino entrega una señal cuadrada con un ciclo útil del 50%, periodo T y frecuencia f a cada uno de los estímulos visuales, tal que T y f son diferentes para cada uno de los cuatro estímulos y determinan la frecuencia de parpadeo de los mismos.

3.1.2.2 CONTROLADOR DE POTENCIA

Las señales PWM generadas en el Arduino Uno aunque son capaces de controlar eficientemente las frecuencias de los estímulos LED, no pueden proveer la potencia que ellos requieren. Para que el sistema sea capaz de controlar el parpadeo de los estímulos y a su vez proporcionar la corriente necesaria a los LED, es necesario un controlador de potencia que sirva de interfaz de acople entre la señal proveniente del Arduino y los LED. De esta forma se ofrece a los LED una alimentación de voltaje independiente.

La tarjeta Mosfet.4 que se puede ver en la figura 3-4 es un controlador de 4 Canales Mosfet IRF 540 con aislamiento óptico, dicho dispositivo permite controlar la potencia que se administra a los estímulos LED, alimentándolos con una fuente dedicada a ellos de acuerdo con la señal de conmutación generada por la señal PWM.




Figura 3-5. Controlador mosfet de 4 canales.

3.1.2.3 ESTIMULOS LED

Los estímulos LED comprenden el elemento emisor de luz tipo LED, que es controlado por los dos elementos anteriormente descritos. Para la elaboración de los estímulos led se utilizaron matrices 8x8 788BS LED, de dimensiones 2 cm x 2 cm, con requerimientos de 3.3 V y 100 mA para máxima intensidad.

Se busca que los estímulos sean lo suficientemente intensos para garantizar potenciales evocados con buenas amplitudes. Por ello se diseñaron cuatro matrices LED para cada estímulo, cuyo diseño se presenta en la figura 3-5.




Figura 3-6. Diagrama del circuito impreso del estímulo LED implementado.

Además del arreglo de cuatro matrices, la tarjeta contiene dos potenciómetros para modular la intensidad de luz de las matrices LED.

La tarjeta tiene unas dimensiones de 5 cm x 4 cm y 1.5 cm de altura. El diseño modular de los estímulos permite tener flexibilidad a la hora de evaluar diferentes configuraciones y poder variar la separación entre estímulos. Cada tarjeta consume aproximadamente 400 mA a máxima intensidad y se alimenta a 5 V. Para poder alimentar los cuatro estímulos simultáneamente es necesaria una fuente de 5 V dc y que proporcione al menos 1.6 A.

3.1.3 MONTAJE FINAL

Luego de que los elementos fueron evaluados por separado y que se comprobó el cumplimiento de los requisitos de diseño, se acoplaron como se puede apreciar en la Figura 3-6.

El sistema corresponde al diseño propuesto y satisface cada uno de los requisitos de diseño, es versátil, reutilizable, fácil de modificar, personalizar y de bajo costo. Las señales generadas satisfacen las condiciones de frecuencia y ciclo útil, tienen un comportamiento estable y óptimo para evocar los potenciales en el cerebro.



Figura 3-7. Fuente de estímulos visuales.

3.2 CASCO DE ELECTROENCEFALOGRAFIA EMOTIV EPOC

El casco de electroencefalografía Emotiv Epoc es un dispositivo de adquisición de señales EEG comercial, inalámbrico y no invasivo. Posee 14 electrodos, distribuidos según el estandar internacional 10-20, el cual se basa en que los electrodos adyacentes están distanciados 10% o 20% de la distancia entre el frente y el final del cráneo [16], cada electodo recibe una letra y un número relacionados con su ubicación en los hemisferios. En el caso del Emotiv se disponen de electrodos en las posiciones: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4, , como se muestra en la figura 3-8 [23]. Además posee dos electrodos que se usan como referencia. Para garantizar los niveles de impedancia adecuados en los electrodos, se humedecen con una solución esteril Renu®.

El fabricante Emotiv además pone a disposición un SDK y el software TestBench para la adquisición de las señales.



Figura 3-9. Emotiv Epoc




Figura 3-10. Estándar de localización de electrodos 10-20. Tomada de [28].

3.3 ORDENADOR

El sistema requiere de un ordenador de 64 bits donde se puedan instalar las plataformas software, específicamente el SDK del Emotiv Epoc y Matlab, usadas por el sistema para la adquisición y el procesamiento de los datos. El ordenador que se utilizó en el proyecto para el desarrollo de la interfaz cerebro computador es un ordenador de escritorio Optiplex 9020 de la compañía Dell con las siguientes especificaciones técnicas [29]:

- Sistema operativo: Windows 8.1 Pro 64 bits
- Procesador: Intel(R) Core (TM) i7-4790
- Memoria RAM: 8192 MB.

En conclusión, la configuración hardware implementada, proporciona cuatro estímulos visuales conformados por matrices LED, donde cada matriz parpadea en función a una señal cuadrática de frecuencia constante y ciclo útil del 50%, generada por el sistema microcontrolador Arduino Uno. Este sistema microcontrolador, genera específicamente cuatro señales simultaneas con frecuencias fundamentales de 7.02, 9.07, 13.15 y 15.2 Hz.

Posteriormente se adquieren las señales cerebrales usando el casco electroencefalográfico comercial Emotiv Epoc, y se envían por Bluetooth a un ordenador Optiplex 9020 de la compañía Dell, donde son recibidas y procesadas por plataformas software.

Los resultados del sistema indican que los estímulos visuales implementados evocan los potenciales en estado estable en las señales cerebrales, y que éstas últimas son capturadas con una resolución y calidad suficiente ya que es posible identificar correctamente la frecuencia fundamental de la señal en más del 80% de los casos.

4. APLICACIÓN SOFTWARE

En esta sección se explica la aplicación software desarrollada, cuya función es procesar e interpretar las señales electroencefalográficas adquiridas. Dando cumplimiento a los objetivos del proyecto se implementaron dos aplicaciones software correspondientes a las configuraciones *off-line* y *on-line*. En la configuración *off-line*, la aplicación software trabaja con un banco de datos obtenido a partir de 15 sujetos, procesa los datos con tres técnicas de extracción de características diferentes, destinan los datos de tres sujetos al entrenamiento de cuatro clasificadores y con los datos de los 12 sujetos restantes se valida su funcionamiento, como se muestra en la figura 4-1. De esta manera, se puede comparar el desempeño del sistema para cada técnica aplicada, para cada sujeto y para diferentes tamaños de muestra, es decir, diferentes ventanas de tiempo donde el usuario está mirando los estímulos para generar una muestra. Todo esto con el fin de escoger las técnicas con mejores prestaciones e implementarlas en la configuración *on-line*, la cual busca traducir una muestra en un comando, inmediatamente después de que el usuario la genera.

El funcionamiento de la aplicación software en configuración *on-line* se encuentra descrito por el diagrama de bloques de la figura 4-2. En este caso, la aplicación software recibe tan solo una muestra con un tamaño fijo determinado, la procesa con una única técnica de extracción de características y discrimina a que clase pertenece usando un solo clasificador, que fue entrenado anteriormente con los datos obtenidos en la configuración *off-line*, y la traduce inmediatamente en una intención de locomoción que envía a la aplicación virtual de la silla de ruedas para ser ejecutada, de manera que el usuario recibe realimentación inmediata de la clasificación de la muestra adquirida.

El capítulo describirá los fundamentos matemáticos de los algoritmos implementados para el preprocesamiento, la extracción de características y la clasificación de las señales electroencefalográficas. Inicialmente se describe el filtro espacial CAR (Common Average Reference), que corresponde al preprocesamiento y es el encargado de referenciar las señales de interés al promedio común de las señales medidas. Después se presentan los tres métodos de extracción de características que se aplicaron, MSI (Multivariate Synchronization Index), MEC (Minimum Energy Combination) y CCA (Canonical Correlation Analysis). Y finalmente, se explican los clasificadores usados, como lo son el clasificador Bayesiano, el máxima criterion, los k-vecinos más cercanos y la red neuronal artificial.




Figura 4-1. Diagrama de bloques de la aplicación software en configuración offline.




Figura 4-2. Diagrama de bloques de la aplicación software en configuración online.

4.1 PREPROCESAMIENTO

La fase de preprocesamiento se encarga de filtrar la señal para mejorar su calidad. Inicialmente se identificaron los canales que aportan poca información valiosa al sistema y se ignoraron los datos que entregan; como los canales AF3, AF4, F7 y F8, que están ubicados en la zona frontal de la cabeza donde se genera mucha actividad electromiográfica que no es objeto de estudio en este trabajo y en cambio aporta ruido y artefactos a las muestras. Los canales donde se considera que se encuentra la información valiosa son, O1, O2, P7 y P8, estos son los electrodos más cercanos a la región occipital, en dicha región se encuentran los potenciales evocados con mayor intensidad que en otras zonas. Los canales, F3, FC5, T7, T8, FC6 y F4, se tuvieron también en cuenta para la implementación de un filtro espacial, pues proporcionan información de la actividad generalizada del cerebro.

4.1.1 Filtro CAR

El filtro espacial CAR, el cual es comúnmente usado en EEG por su fácil implementación matemática y su eficacia en la mejora de la relación señal a ruido [30]. Este filtro se encuentra descrito por la ecuación 4.1, comprende el cálculo del valor medio de las señales $x_i(t)$ obtenidas en todos los canales y la sustracción de dicho valor de los canales de interés [15], es decir de las señales $x_j(t)$ adquiridas por los canales O1, O2, P7 y P8; m corresponde a el número de canales usados para calcular los valores medios, que en este caso corresponde a los 10 canales: F3, FC5, T7, P7, O1, O2, P8, T8, FC6 y F4.

$$CAR(x_j(t)) = x_j(t) - \sum_{i=1}^m \frac{x_i(t)}{m} \quad (4.1)$$

Los canales utilizados y las acciones ejecutadas sobre ellos se resumen en la tabla 9.

Tabla 9. Canales y acciones efectuadas durante CAR.

Canales	Acción
F3, F4, FC5, FC6, T7, T8, P7, P8, O1 y O2	Usados para calcular el ruido común
P7, P8, O1 y O2	Filtrados con CAR (Canales de interes)
AF3, AF4, F7 Y F8	Eliminados por contener artefactos provenientes de actividad electromiográfica.

4.1.2 Filtro Butterworth

Posteriormente se aplicó un filtro digital pasa altas tipo Butterworth, con el fin de conservar solo el espectro de frecuencia donde pueden detectarse las características de interés. Las características de este filtro se pueden observar en la tabla 10.

Tabla 10. Características de filtro pasa banda.

Característica	Valor
Frecuencia de muestreo	128 Hz
Orden	5
Frecuencia de corte inferior	4 Hz
Frecuencia de corte superior	60 Hz

4.2 CÁLCULO DE CARACTERÍSTICAS

La extracción de características constituye una de las etapas más importantes del desarrollo de este proyecto, ya que tiene una influencia directa en el proceso de reconocimiento y por ende en el desempeño final del sistema. Existen variedad de características que pueden ser obtenidas a partir de datos EEG, para seleccionarlas, se tienen en cuenta los objetivos y las propiedades del sistema.

En este caso, como ya se ha mencionado, se desarrolló una ICC basada en potenciales evocados de estado estable y con el objetivo de garantizar la mayor amplitud de estos potenciales, se trabajaron con frecuencias de los estímulos en el rango de las bajas frecuencias, el cual se encuentra centrado en 15 Hz [31]. Las frecuencias que se utilizaron para los estímulos fueron 7.02, 9.07, 13.15 y 15.2 Hz

Se implementaron tres métodos populares en la extracción de características para SSVEP, con el fin de compararlos y escoger aquel que ofreciera mejores resultados. Cada método entrega cuatro características (debido a que se tienen cuatro señales de referencia, una por cada señal de luz que entrega cada estímulo), donde cada característica es un indicador de similitud entre la señal adquirida y una de las cuatro señales de referencia. Cada señal de referencia se compone de la suma de senos y cosenos con la frecuencia fundamental de parpadeo de los estímulos (7.02, 9.07, 13.15 o 15.2 Hz) y las frecuencias de tres armónicos, lo cual resulta en la aproximación de una señal cuadrada, es decir, en la aproximación de la señal generada por uno de los estímulos visuales.

En la tabla 11 se muestran los canales empleados para la extracción de dichas características según el método aplicado y posteriormente se describe el funcionamiento de cada metodo.

Tabla 11. Canales utilizados para cada método.

	MSI	CCA	MEC
Canales utilizados	2 (O1 y O2 luego de filtro CAR)	2 (O1 y O2 luego de filtro CAR)	4 (P7, P8, O1 y O2 luego de filtro CAR)

4.2.1 Índice Multivariante de Sincronización (MSI)

MSI (*Multivariate Synchronization Index*), es un método que tiene como objetivo estimar la sincronización entre la señal EEG adquirida y las señales de referencia, que en este caso corresponden a las cuatro señales generadas por los cuatro estímulos visuales. La sincronización se expresa como el índice S y se basa en la entropía de los valores propios normalizados de la matriz de correlación de señales multivariantes [15].

Las señales EEG se expresan como una matriz X de $N \times M$ dimensiones, y las señales de referencias por una matriz Y de dimensiones $2Nh \times M$, donde N es el número de canales, M el número de muestras y Nh el número de armónicos de las señales seno y coseno que componen las señales de referencia. La matriz de correlación se calcula de la siguiente manera:

$$C = \begin{bmatrix} C_{11} & C_{12} \\ C_{21} & C_{22} \end{bmatrix} \quad (4.2)$$

Siendo:

$$C_{11} = \frac{1}{M} X X^T \quad (4.3)$$

$$C_{22} = \frac{1}{M} Y Y^T \quad (4.4)$$

$$C_{12} = C_{21} = \frac{1}{M} X Y \quad (4.5)$$

Luego se hace la siguiente transformación lineal, para reducir la influencia en la medida de la sincronización de la autocorrelación con la correlación cruzada de X y Y :

$$U = \begin{bmatrix} C_{11}^{1/2} & 0 \\ 0 & C_{22}^{1/2} \end{bmatrix} \quad (4.6)$$

La matriz de correlación transformada es:

$$R = U C U^T \quad (4.7)$$

Siendo $\lambda_1, \lambda_2, \dots, \lambda_p$ los valores propios de la matriz R , se normalizan así:

$$\lambda_i' = \frac{\lambda_i}{\sum_{i=1}^p \lambda_i} \quad (4.8)$$

Dónde:

$$P = N + 2Nh \quad (4.9)$$

Finalmente se obtiene el índice de sincronización entre dos señales con la siguiente ecuación:

$$S = 1 + \frac{\sum_{i=1}^P \lambda_i' \log(\lambda_i')}{\log(P)} \quad (4.10)$$

4.2.2 Análisis de la correlación canónica (CCA)

CCA (*Cannonical Correlation Analysis*), es una técnica de análisis estadístico multivariante que tiene como objetivo determinar la magnitud de las correlaciones que puedan existir entre dos conjuntos de datos. CCA busca un par de combinaciones lineales, denominadas variables canónicas, para dos conjuntos de datos, de forma que la correlación entre las dos variables canónicas sea máxima.

El vector multidimensional X representa las señales EEG para los N canales y el vector multidimensional Y representa las señales de referencia, que están compuestas de senos y cosenos con las frecuencias fundamentales de los estímulos visuales y sus armónicos, como se muestra en la ecuación 4.11 [32].

$$Y = \begin{pmatrix} \sin(2\pi fkt) \\ \cos(2\pi fkt) \\ \vdots \\ \sin(2\pi Nh fkt) \\ \cos(2\pi Nh fkt) \end{pmatrix} \quad (4.11)$$

Considerando las combinaciones lineales:

$$x = X^T W_x \quad (4.12)$$

$$y = Y^T W_y \quad (4.13)$$

Se obtiene la correlación total de acuerdo con la siguiente ecuación:

$$\rho(x, y) = \frac{E[x^T y]}{\sqrt{E[x^T x]E[y^T y]}} = \frac{E[W_x^T X Y^T W_y]}{\sqrt{E[W_x^T X X^T W_x]E[W_y^T Y Y^T W_y]}} \quad (4.14)$$

De esta manera, la frecuencia de la señal de referencia, con la cual la señal EEG adquirida presenta un mayor coeficiente de correlación, se selecciona como la frecuencia correspondiente al SSVEP.

4.2.3 Combinación Mínima de Energía (MEC)

MEC (*Minimum Energy Combination*), es un método que busca eliminar tanto como sea posible el ruido generado por otras actividades cerebrales que no están relacionadas con los SSVEP.

Este método, asume que un estímulo visual de frecuencia f es aplicado y que genera una señal captada por el electrodo i que se puede describir con la siguiente ecuación:

$$y_i(t) = \sum_{k=1}^{Nh} a_{i,k} \sin(2\pi kft + \phi_{i,k}) + \sum_j b_{i,j} z_j(t) + e_i(t) \quad (4.15)$$

La señal se divide en tres partes, la primera parte representa los SSVEP provocados en la señal EEG por los estímulos visuales, y comprende componentes sinusoidales con amplitud $a_{i,k}$ y fase $\phi_{i,k}$ con la frecuencia fundamental del estímulo y con las frecuencias de los Nh -ésimos armónicos. La segunda, contiene señales $z_j(t)$ producidas por otras actividades mentales concurrentes o artefactos. Estas señales son captadas por todos los electrodos, pero cada electrodo las capta a una escala determinada, representada por la magnitud $b_{i,j}$. La tercera parte $e_i(t)$ representa el componente de ruido medido por cada electrodo [14].

Para un segmento de tiempo con N_t muestras consecutivas, a una frecuencia de muestreo FS , se puede expresar el modelo en la siguiente forma vectorial:

$$y_i = Xa_i + Zb_i + e_i \quad (4.15)$$

Donde $y_i = [y_i(1), \dots, y_i(N_t)]^T$, es un vector de dimensiones $N_t \times 1$ con las N_t muestras consecutivas adquiridas. La matriz $X = [X_1 \ X_2 \ \dots \ X_{Nh}]$ representa los SSVEP y es de tamaño $N_t \times 2N_h$. Cada submatriz X_k contiene dos columnas, una con el componente $\sin(2\pi kft)$ y otra con el componente $\cos(2\pi kft)$, del k -ésimo armónico. El vector a_i de dimensión $2N_h \times 1$ contiene las correspondientes amplitudes de las componentes sinusoidales de cada armónico [33]. De manera similar, Z es una matriz que contiene las componentes de ruido producidas por artefactos o por otras actividades mentales, y el vector b_i contiene el vector de pesos correspondiente. Finalmente, asumiendo que se tienen señales dadas por $y_i(t)$ a partir de un número N_y electrodos con $i = 1, 2, \dots, N_y$, el modelo puede ser generalizado como:

$$Y = XA + ZB + E \quad (4.16)$$

Donde $Y = [y_1, \dots, y_{N_y}]$ es una matriz $N_t \times N_y$, con las señales provenientes de todos los electrodos como columnas, E es la matriz de ruido construida de la misma manera, igual que A y B que contienen los valores de amplitud de las señales sinusoidales y las señales de ruido para todos los electrodos, respectivamente.

Como se busca la interferencia de las actividades cerebrales que no están relacionadas con los SSVEP, inicialmente se removieron todos los componentes de potenciales SSVEP de todos los electrodos, al proyectarlos en el complemento ortogonal de la matriz X de acuerdo con la ecuación:

$$\tilde{Y} = Y - X(X^T X)^{-1} X^T Y \quad (4.17)$$

El denominador en la ecuación (4.18) corresponde a la energía total en la señal de ruido y el numerador corresponde a la energía total retenida cuando se usan N_s combinaciones. Se escoge entonces N_s tal que cerca del 90 % de la energía de la señal de ruido sea descartada.

$$\frac{\sum_{i=1}^{N_s} \lambda_i}{\sum_{j=1}^{N_y} \lambda_j} > 0.1 \quad (4.18)$$

Si se toman los vectores propios correspondientes $W = [w_1, \dots, w_{N_s}]$ se obtienen los canales $S = [s_1, \dots, s_{N_s}]$ aplicando la siguiente formula:

$$S = YW \quad (4.19)$$

Finalmente se encuentra la presencia de señales SSVEP utilizando la fórmula:

$$T = \frac{1}{N_s N_h} \sum_{l=1}^{N_s} \sum_{K=1}^{N_h} \frac{P_{k,l}}{\sigma_{k,l}^2} \quad (4.20)$$

T corresponde al promedio de la relación señal a ruido (SNR) a través de los N_h armónicos. Para calcular estas SNR se calcula la potencia de la señal así:

$$\hat{P}_{k,l} = \|X_k^T s_l\|^2 \quad (4.21)$$

Para la potencia de las demás señales se utiliza un modelo auto regresivo $AR(p)$ que es aplicado a la señal de los canales obtenidos luego de extraer las señales SSVEP, es decir sobre:

$$\tilde{S} = S - X(X^T X)^{-1} X^T S = \tilde{Y}W \quad (4.22)$$

Los modelos $AR(p)$ son eficientemente ajustados invocando el teorema Wiener-Khinchin para calcular la autocovarianza de cada canal y luego resolver la ecuación de YuleWalker. Así se encuentran los parámetros $\alpha_1, \alpha_2, \dots, \alpha_p$ del modelo $AR(p)$ al igual que la varianza del ruido blanco del proceso σ^2 [33].

Asumiendo que se ajustó un modelo $AR(p)$ al canal s_l , el nivel de ruido predicho para el armónico k de la frecuencia SSVEP esta dado por:

$$\sigma_{k,l}^2 = \frac{\pi N_t}{4} \frac{\sigma^2}{\left| 1 + \sum_{j=1}^p \alpha_j \exp\left(-\frac{2\pi i j f}{F_s}\right) \right|^2} \quad (4.23)$$

Se calcula entonces T a partir de la ecuación (4.20) para cada una de las frecuencias, obteniendo así una característica T por cada estímulo utilizado, en este caso el sistema proporciona cuatro estímulos visuales y por lo tanto el algoritmo entrega cuatro características [14].

4.3 CLASIFICACIÓN

La última etapa del sistema es la encargada de clasificar la señal EEG entre cuatro clases relacionadas a las cuatro frecuencias de parpadeo de los cuatro estímulos visuales.

En ésta etapa, se implementaron cuatro clasificadores para comparar su desempeño y escoger el que ofreciera mejores resultados. Los clasificadores van desde técnicas estadísticas hasta técnicas de inteligencia computacional y corresponden a: el máxima criterion, redes neuronales, los k-vecinos más cercanos y el clasificador bayesiano. A continuación se describe cada uno de ellos.

4.3.1 Máxima criterion

En la etapa de extracción de características, todas las técnicas entregaron cuatro características, donde cada característica representaba un índice de correlación entre la señal EEG medida y una señal de referencia. Esta última representa la señal generada por uno de los estímulos visuales. Este método se basa en que la característica de mayor valor corresponde a la mayor sincronía entre la señal medida y la señal de referencia, por lo tanto se asigna a la clase que representa la frecuencia de dicha señal de referencia.

4.3.2 Clasificador bayesiano

Es un clasificador probabilístico fundamentado en el teorema de Bayes. El clasificador implementado modela una función de densidad de probabilidad para cada clase; donde se asume que cada función sigue una distribución normal. De esta manera se modeló una función de densidad de probabilidad por clase a partir de los valores de las características extraídas en la etapa anterior [34]. Cada función se encuentra descrita por la siguiente ecuación matemática:

$$p(x) = \frac{1}{2\pi^{\frac{d}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left\{-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right\}$$

Para estimar el valor de la media y la matriz de covarianza que definen la función de densidad de probabilidad de cada clase, se aplicó la máxima verosimilitud, según la cual:

$$\hat{\mu} = \frac{1}{N} \sum_{n=1}^N x^n$$

$$\hat{\Sigma} = \frac{1}{N} \sum_{n=1}^N (x^n - \hat{\mu})(x^n - \hat{\mu})^T$$

Donde $\hat{\mu}$ y $\hat{\Sigma}$ son resultados intuitivos de la media y la matriz de covarianza, obtenidos a partir de un porcentaje de los datos totales, que se reservó para el modelamiento de la funciones de densidad de probabilidad, para posteriormente usar dichas funciones para la clasificación del resto de los datos [35].

Finalmente el clasificador bayesiano obtiene la clase C_k^* , a la cual asigna el vector de características, gracias a que representa la clase más probable a la cual tal vector puede pertenecer, no es necesario tener en cuenta la probabilidad a priori, ya que en este caso las clases son equiprobables.

4.3.3 Redes neuronales (RNA)

Las redes neuronales o RNA son modelos matemáticos que fueron diseñados para “emular” las características del funcionamiento básico de las neuronas biológicas, para esto, utilizan como elemento de procesamiento a la neurona artificial, que al igual que su homónimo biológico responde a una excitación y comunica dicha respuesta con demás neuronas, formando así conexiones sinápticas. Estas conexiones son las que proveen a las RNA de gran capacidad de aprendizaje.

Para su funcionamiento, se aplica un conjunto de entradas a la neurona, cada una de las cuales representa una salida de otra neurona. Cada entrada se multiplica por su "peso" o ponderación correspondiente análogo al grado de conexión de la sinapsis. Todas las entradas ponderadas se suman y se determina el nivel de excitación o activación de la neurona. El peso que se asocia a cada entrada es determinado entonces por un proceso de aprendizaje que puede ser supervisado o no supervisado. En el entrenamiento supervisado la red es expuesta a pares entrada-salida conocidos y en el no supervisado la red se entrena únicamente con vectores de entrada, no requiere de resultados esperados.

En la tabla 12 se resume la topología de la red neuronal implementada.

Tabla 12. Topología de la red neuronal

Tipo	Feedforward
Entradas	4
Salidas	4
Capas ocultas	1
Neuronas en capa oculta	10
Épocas	160
Performance	0.493
Función de activación	Tansig en ambas capas
Aprendizaje	Supervisado

4.3.4 Los k vecinos más cercanos

Este es un método de clasificación no paramétrico y supervisado, que se basa en el principio de que una muestra representada por un vector de m dimensiones, donde m es el número de características, pertenece a la clase a la que pertenecen la mayor cantidad de vecinos de los k vecinos más cercanos a ella. En la fase de entrenamiento, el algoritmo almacena los vectores que contienen las características de cada muestra de entrenamiento y las etiquetas de las clases a donde pertenece. Ante la presencia de un nuevo dato, el algoritmo calcula la distancia (generalmente la distancia euclidiana) de la nueva muestra a cada muestra del conjunto de entrenamiento y tiene en cuenta solo las k muestras más próximas a ella, y le asigna la clase a la que pertenece la mayoría de dichas k muestras. Para este proyecto se trabajó con un k igual a 11, valor que se determinó heurísticamente.

4.4 RESUMEN

En este capítulo se explicaron brevemente los cuatro métodos de extracción de características y los cuatro de clasificación que se implementaron en el sistema en configuración offline. Estas herramientas se implementaron con el propósito de comparar el desempeño de cada una, y finalmente escoger las características y el clasificador con mejor desempeño y usarlos en configuración online.

5. PROTOCOLO EXPERIMENTAL

Para asegurar las condiciones de reproducibilidad de los resultados es necesario contar con un protocolo experimental claro que describa las condiciones con las que se trabajó durante la experimentación. En este capítulo se explican los protocolos experimentales implementados, uno para las sesiones offline, durante las cuales se construyó el banco de datos y otro para las pruebas online.

5.1 CREACIÓN DEL BANCO DE DATOS

Las sesiones se realizaron en un ambiente iluminado con luz natural, cada voluntario se sentó cómodamente a una distancia de 60 cm de los estímulos visuales, luego de haber aplicado una solución multipropósito Renu® en cada electrodo, se le puso el casco Emotiv Epoc como se puede observar en la figura 5-1. Posteriormente el voluntario debía fijar su mirada en un estímulo por 30 segundos y luego descansar la vista por un minuto. Este proceso se repitió 3 veces por estímulo, lo que significa que los datos adquiridos correspondían a señales de 90 segundos por estímulo visual y con una frecuencia de muestreo de 128 Hz.




Figura 5-2. Procedimiento experimental para la adquisición de la base de datos.

Las sesiones se realizaron con 15 hombres con edades entre 20 y 35 años, sin ningún tipo de deficiencia motora y que nunca habían usado una interfaz cerebro computador. Cada sujeto fue informado por medio de un consentimiento escrito del propósito, la duración, y detalles del experimento. Este consentimiento escrito se encuentra en el Anexo.1.

5.2 SESIONES ON-LINE

Participaron de los experimentos Online 5 hombres mayores de edad, sin ningún tipo de deficiencia motora, que no participaron en las sesiones off-line y que nunca habían usado una interfaz cerebro computador. Cada sujeto fue informado por medio de un consentimiento escrito del propósito, la duración, y detalles del experimento. Las sesiones online se realizaron en un ambiente iluminado con luz natural, cada voluntario se sentó cómodamente a una distancia de 60 cm de los estímulos visuales y a 80 cm de la pantalla del computador. A cada voluntario se le presento la interfaz y se le explicó el funcionamiento de la misma, informándoles el objetivo del experimento “controlar el movimiento de una silla de ruedas dentro de un entorno 3D, por medio las señales eléctricas generadas por sus cerebros al observar unos estímulos visuales”.

Se desarrollaron dos pruebas online distintas para evaluar el desempeño del sistema cuando se le informaba al usuario qué comando debía ejecutar y cuando tenía la libertad de ejecutar cualquier comando. Las pruebas se denominan “Prueba Comandos” y “Prueba Laberinto” y se explican a continuación.

1. Prueba Comandos: En esta prueba se les explicó a los voluntarios la relación existente entre cada estímulo y los cuatro comandos posibles de locomoción que podían efectuar. Al iniciar la prueba el entorno 3D es cargado y mostrado en pantalla, se activan los estímulos visuales y se toman las señales EEG por 4 segundos, posteriormente se desactivan los estímulos visuales y se ejecuta el movimiento identificado por el sistema en la silla de ruedas virtual expuesta en pantalla, este ciclo se repite indefinidamente hasta que se presione el botón salida. Una vez que el usuario se ha familiarizado con el sistema se le indicó la serie de comandos que debía enviar al sistema, es decir que estímulo LED debía observar; en total cada usuario envió 16 comandos, cuatro veces cada uno de los cuatro comandos disponibles; y se registraron las veces que el sistema clasificó correctamente la señal y la animación de la silla de ruedas virtual realizó el movimiento correspondiente, también se registraron las muestras que fueron ignoradas y no se clasificaron en ningún movimiento.
2. Prueba Laberinto: En esta prueba se le explica al usuario que su objetivo es llevar una silla de ruedas virtual a la salida de un laberinto utilizando la actividad cerebral generada al observar cualquiera de los 4 estímulos como se hizo en la prueba anterior. Finalizada la explicación se inició la prueba por medio del botón “Prueba Laberinto” y el usuario debía mover la silla de ruedas virtual, como si estuviera sentado en ella (figura 5-2), y navegar a través de un laberinto para finalmente llegar a la salida. En esta prueba el usuario tenía la autonomía para decidir qué comandos ejecutar. Se registró el tiempo que cada usuario tardó en llegar a la meta.




Figura 5-3. Procedimiento experimental para la prueba laberinto.

5.3 INTERFAZ PRINCIPAL

La aplicación elaborada pone a disposición una interfaz cerebro-computador online funcional. En la interfaz gráfica se muestra inicialmente el entorno 3D, se crea una captura de las señales EEG por una ventana de tiempo establecida y luego se ejecuta cada una de las etapas necesarias para la clasificación de un comando, es decir se ejecutan las etapas de pre-procesamiento, procesamiento y clasificación para la señal EEG adquirida. Una vez clasificada la muestra, la interfaz simula el movimiento de una silla de ruedas correspondiente al comando clasificado.

En la figura 5.3 se puede apreciar el diseño de la interfaz principal, a continuación se explican los elementos que la componen y las funciones que desempeñan.




Figura 5-4. Interfaz principal online

La interfaz se compone de:

- 1) Botón Prueba Comandos: Este botón permite dar inicio a la prueba comandos, donde ejecuta el ciclo correspondiente a toda la implementación de la interfaz online, desde la etapa de adquisición EEG hasta la clasificación y ejecución del movimiento de la silla de ruedas.
- 2) Botón Prueba Laberinto: Este botón permite dar inicio a la prueba laberinto de la interfaz y ejecuta el ciclo correspondiente a toda la implementación de la interfaz online, desde la etapa de adquisición EEG hasta la clasificación y ejecución del movimiento de la silla de ruedas dentro de un laberinto.
- 3) Botón Salir: Permite cerrar todas las ventanas en ejecución y dar salida de la aplicación.
- 4) Grafica EEG: En esta parte de la interfaz se grafican las señales EEG correspondientes a la última muestra adquirida, para monitorear la señal.
- 5) Campo último comando: En este campo se lleva un registro del último comando de movimiento clasificado por la interfaz, donde 0, 1, 2, 3, 4 representan, ningún movimiento, giro de 90° hacia la izquierda, desplazamiento hacia adelante, giro de 90° hacia la derecha y desplazamiento hacia atrás, respectivamente.
- 6) Vector de Características: Este campo permite monitorear los datos de salida que entrega el algoritmo de extracción de características.

5.3.1 Ciclo de ejecución online

Como ya se mencionó luego de presionar el botón correspondiente a cualquiera de las dos pruebas online en la interfaz principal se ejecuta el ciclo online. La figura 5-4 muestra el diagrama de flujo asociado a este comportamiento.




Figura 5-5. Diagrama de flujo del ciclo online.

Inmediatamente después de accionar el botón “Prueba Comandos” se carga la ventana de visualización del entorno 3D que se puede apreciar en la figura 5-5. En esta ventana se ejecutarán los movimientos clasificados por la interfaz.



Figura 5-6. Ventana de visualización del entorno 3D prueba Comandos.

De igual manera después de accionar el botón “Prueba Laberinto” se carga la ventana de visualización del entorno 3D correspondiente que se puede apreciar en la figura 5-7. En esta ventana se ejecutaran los movimientos clasificados por la interfaz durante esta prueba.



Figura 5-7. Ventana de visualización del entorno 3D prueba Laberinto.

5.4 RESUMEN

La aplicación online soporta dos diferentes pruebas: la prueba comandos que tiene el propósito de evaluar el desempeño del sistema y contrastar los resultados obtenidos con los resultados del análisis offline; y la prueba laberinto que proporciona al usuario un ejemplo de aplicación que se podría implementar en el día a día de una persona con dificultades de locomoción.

6. PRUEBAS Y RESULTADOS

Para evaluar el funcionamiento del sistema y comparar los métodos de procesamiento implementados, se realizaron pruebas en modo off-line y on-line. A continuación se describen las especificaciones de cada configuración, los parámetros aplicados en cada método de procesamiento y los resultados obtenidos en las pruebas realizadas.

6.1 CONFIGURACIÓN DE LAS PRUEBAS OFF-LINE

En la fase de preprocesamiento de la señal, específicamente la implementación del filtro CAR, se tuvo en cuenta solo las señales adquiridas a través de diez canales: F3, F4, FC5, FC6, F7, F8, T7, T8, P7, P8, O1 y O2; y para el procesamiento restante, que corresponde a la extracción de características y clasificación, solo las adquiridas a través de los canales: P7, P8, O1 y O2.

En la fase de procesamiento, las señales se dividieron en muestras de 2, 3, 4, 5, 6 y 7 segundos, se compararon los resultados en cada caso, para identificar el tiempo mínimo requerido que garantizara un porcentaje de éxito del 80% o más.

6.2 RESULTADOS DE LAS PRUEBAS OFF-LINE

Después de aplicar el filtro CAR, que tiene como objetivo mejorar la relación señal a ruido de los datos adquiridos, se procede a extraer las características, usando tres métodos: el Índice Multivariante de Sincronización (MSI), la Combinación Mínima de Energía (MEC) y el Análisis de la Correlación Canónica (CCA); al aplicar estos métodos, se obtiene en los tres casos, cuatro características. Cada característica es un indicador de la similitud entre la señal adquirida y una de las 4 señales de referencia, donde cada señal de referencia representa la señal emitida por uno de los cuatro estímulos visuales y por lo tanto, tiene como frecuencia fundamental la frecuencia de parpadeo del estímulo visual que representa. A continuación se presentan los resultados obtenidos con todos los métodos de extracción de características y los diferentes clasificadores implementados, para una ventana de análisis de distintos tamaños.

6.2.1 Máxima Criterion

Como ya se mencionó, las tres técnicas de extracción de características entregan cuatro indicadores que proporcionan información sobre la similitud entre la señal de prueba y cuatro señales de referencia que representan las señales que emiten los estímulos visuales. De esta manera, la característica que tenga un mayor valor representa la mayor similitud entre la señal de prueba y una de las señales de referencia y por tanto, se asume que su frecuencia corresponde a la frecuencia fundamental de dicha señal de referencia, y se clasifica en dicha clase. Los resultados obtenidos aplicando este criterio para cada voluntario con una ventana de análisis de tres segundos, se consignan en la tabla 13.

Tabla 13. Comparación de las técnicas de extracción de características con máxima criterion.

Sujeto	Tasa de éxito (%)		
	MSI	MEC	CCA
#1	63	72	62
#2	65	71	71
#3	73	75	78
#4	65	77	65
#5	58	80	60
#6	53	78	50
#7	70	80	45
#8	74	71	67
#9	74	95	70
#10	95	94	57
#11	66	97	73
#12	73	78	77
#13	56	47	45
#14	63	61	54
#15	70	83	51
Promedio	68	77	62

Se observa que las características de mejor desempeño fueron las obtenidas con el método MEC, obteniendo porcentajes de éxito de hasta el 97% para un usuario y un porcentaje promedio de éxito del 77%, superando en un 11 y 15% a los métodos MSI y CCA respectivamente.

En la figura 6-1 se expone el desempeño de los cuatro metodos junto con el máxima criterion para muestras de diferente duración.




Figura 6-1. Desempeño de las técnicas de extracción de características usando máxima criterion, para diferentes tamaños de la ventana de análisis

Como era de esperarse la tasa de éxito aumenta con el tamaño de la ventana de análisis, gracias a que se dispone de mayor cantidad de información, este comportamiento se evidencia para todos los métodos, y además se mantiene un porcentaje mayor de éxito para el método MEC con respecto a MSI y CCA para todas las ventanas de análisis.

6.2.2 Clasificadores

Con el fin de mejorar el porcentaje de aciertos del sistema, se implementaron tres clasificadores: el clasificador Bayesiano, el método de los K vecinos más cercanos y una red neuronal artificial. Para el entrenamiento de estos tres clasificadores se destinaron los datos adquiridos en tres sujetos, es decir el 20% del total de los datos; el resto de datos se usó para validar el funcionamiento de las técnicas. En la tabla 14 se consignó el porcentaje de éxito obtenido con cada método de extracción de características trabajando en conjunto con cada clasificador para ventanas de análisis de 2, 3, 4, 5, 6 y 7 segundos. Por otra parte la figura 6-2 presenta gráficamente el promedio del porcentaje de éxito de cada método en relación a la desviación estándar.

Tabla 14. Comparación de los clasificadores.

Ventana de análisis (s)	Tasa de éxito (%)								
	MSI			MEC			CCA		
	Bayes	kNN	NNA	Bayes	kNN	NNA	Bayes	kNN	NNA
2	68	65	66	74	68	74	60	56	59
3	74	71	72	81	80	78	66	62	66
4	79	77	61	87	85	85	71	65	61
5	82	82	84	90	89	68	72	70	71
6	84	80	88	90	89	89	75	73	73
7	85	83	81	92	92	92	76	75	75




Figura 6-2. Desempeño de los métodos implementados vs la desviación estándar de los resultados obtenidos para una ventana de tres segundos.

Nuevamente el método de extracción de características MEC es el que entrega los mejores resultados; de manera que este método en trabajo conjunto con el clasificador bayesiano proporciona el porcentaje de éxito más alto, y además, la segunda menor desviación estándar, lo que se traduce en resultados poco dispersos. Por lo que usó para la configuración *on-line* del sistema.

Las señales cerebrales pueden verse contaminadas por actividad cerebral que no es de interés y no está relacionada con el procesamiento visual de los potenciales evocados, señales electromiográficas, señales electroculográficas, entre otras. Con el fin de detectar anticipadamente la presencia de señales contaminadas de mala calidad, que conllevan a bajos porcentajes de acierto, se estableció un indicador de baja calidad de las señales tal como se explica a continuación.

6.2.3 Indicador de señales con un pobre contenido de información

Para identificar los potenciales evocados después de aplicar el método de la Mínima Combinación de Energía (MEC), se encontró la relación, descrita por la ecuación (4.20), entre la potencia de la señal y la potencia del ruido presente en la señal, en cada una de las cuatro frecuencias de interés. Estos valores de relación señal a ruido (SNR) para cada frecuencia proveen información sobre la calidad de la señal, pues en caso de que el valor máximo de los cuatro calculados sea bajo, el contenido de interés es pobre en relación al ruido presente en la señal.

$$T = \frac{1}{N_S N_h} \sum_{l=1}^{N_S} \sum_{K=1}^{N_h} \frac{P_{k,l}}{\sigma_{k,l}^2} \quad (4.20)$$

Para evaluar la relación entre el valor máximo de SNR de cada muestra y la probabilidad de que sea clasificada con o sin éxito, se realizó la gráfica 6-2. Esta gráfica presenta el valor máximo de SNR de las 1800 muestras (con un tamaño de tres segundos) del banco de datos adquirido. Las muestras se clasificaron usando el máxima criterion, y en la gráfica se presenta el valor máximo de SNR en azul, si la muestra fue clasificada exitosamente, y en amarillo si por el contrario fue clasificada erróneamente. Adicionalmente aparece en la gráfica una línea que corresponde al valor promedio de los SNR graficados que pertenecen a muestras clasificadas erróneamente. Como era de esperarse, las muestras con mala clasificación presentan valores pequeños de SNR.




Figura 6-3. Valor máximo de SNR de todas las muestras del banco de datos, cuando fueron bien y mal clasificadas.

Para analizar el comportamiento del SNR en relación al tamaño de la muestra, se calculó el promedio del valor máximo de SNR de las muestras mal clasificadas, para diferentes tamaños de muestras, usando el banco de datos adquirido a partir de 15 sujetos. En la tabla 15 se consignaron los valores obtenidos, de los cuales se puede decir que el SNR promedio de las muestras mal clasificadas presenta poca variación respecto al tamaño de la muestra.

Tabla 15. Comparación de SNR para cada ventana de tiempo.

Ventana de análisis (s)	SNR Promedio
2	2.7
3	2.5
4	2.6
5	2.5
6	2.6
7	2.5

De lo anterior se puede concluir, que si la relación señal a ruido de la muestra es baja para todas las frecuencias de interés, la señal se encuentra muy contaminada y por tanto, aumenta la probabilidad de que el sistema la clasifique erróneamente.

Se estableció un umbral de 2.2 que indica que, en caso de que ninguno de los valores de relación señal a ruido de la muestra en las cuatro frecuencias de interés supere tal umbral, la muestra debe ser ignorada y se debe volver a capturar la señal para que el usuario ejecute de nuevo el comando. El valor establecido corresponde al décimo

percentil de los datos de SNR para un tamaño de muestra de dos segundos, que es la ventana de análisis implementada más pequeña y la que presenta los peores resultados, lo que quiere decir que en el peor de los casos el indicador de calidad de las muestras ignorará el 10% de las muestras.

En la tabla 16 se presentan los resultados obtenidos para diferentes ventanas de análisis, después de aplicar este criterio que pretende ignorar las señales severamente contaminadas. La mayor mejora se presentó para una ventana de análisis de tres segundos, para la cual se obtuvo una tasa de éxito 4% mayor a la obtenida antes de aplicar el criterio, a cambio de ignorar el 11% de las muestras totales. Mientras que en la tabla 17 se presenta el mismo análisis pero por voluntario, usando una ventana de tres segundos.

Tabla 16. Comparación de la clasificación con criterio del SNR para cada ventana de tiempo.

Ventana de análisis (s)	Tasa de éxito usando MEC (%)			Muestras ignoradas (%)
	Bayes	kNN	NNA	
2	77	72	76	10
3	85	84	81	11
4	89	88	87	10
5	91	92	69	8
6	92	91	91	7
7	95	95	94	7

Tabla 17. Comparación de la clasificación con criterio del SNR para cada voluntario.

Voluntario	Tasa de éxito usando MEC (%)			Muestras ignoradas (%)
	Bayes	kNN	NNA	
#1	87	81	81	16
#2	78	76	75	18
#3	85	87	83	7
#4	84	83	83	12
#5	75	75	77	10
#6	85	85	87	7
#7	75	70	69	8
#8	91	94	87	16
#9	93	92	86	3
#10	88	91	81	2
#11	85	86	84	0
#12	89	84	84	13
Promedio	85	84	81	11

6.3 RESULTADOS DE LAS PRUEBAS ON-LINE

Con base en los resultados de las pruebas off-line, se mantuvo la mejor configuración para las pruebas on-line; esto es, el uso del método MEC para la extracción de características y un clasificador Bayesiano, para la identificación de las muestras. El sistema no requiere que el usuario realice ningún tipo de entrenamiento, ya que el clasificador Bayesiano se modeló con un porcentaje del banco de datos obtenido en configuración off-line. Además se utilizó una ventana de cuatro segundos, debido a que de las pruebas off-line se encontró que se necesitaba una ventana igual o mayor a tres segundos para obtener una tasa de éxito superior al 80% (ver tabla 14). A continuación se presentan los resultados obtenidos para las dos pruebas realizadas online, en donde se trabajó con 5 voluntarios nuevos que no participaron en las pruebas de configuración off-line y que además nunca habían usado una interfaz cerebro computador.

6.3.1 Resultados prueba comandos

En la tabla 18 se muestran la tasa de éxito y el porcentaje de muestras ignoradas para los cinco voluntarios que participaron del experimento online prueba comandos, para la cual el usuario debía ejecutar la secuencia de comandos que se le indicaba, y por lo tanto no tenía que pensar qué comando ejecutar, a diferencia de la prueba laberinto, en la cual el usuario tenía libertad de ejecutar cualquier comando.

La tasa de éxito promedio fue del 86%, muy cercano al 87% obtenido en las pruebas off-line para esta combinación de algoritmos.

Mientras tanto en la tabla 19 se presenta la matriz de confusión obtenida, donde se especifica el porcentaje de aciertos y el porcentaje de muestras ignoradas para cada frecuencia, usando los resultados obtenidos de los cinco voluntarios. Se puede concluir que las frecuencias de 9 y 13 Hz son las que el sistema clasifica con mayor actividad, mientras que para la frecuencia de 15 Hz es que más erra. De esta manera, las frecuencias de 9 y 13 Hz se asignaron a los comandos que probablemente el usuario ejecutará con más frecuencia a la hora de navegar libremente con la silla de ruedas virtual, estos son el desplazamiento hacia adelante y el giro de 90° hacia la derecha (es tan probable como el giro hacia la izquierda, así que se escogió de manera aleatoria); y la frecuencia que el sistema peor reconoce se asignó al desplazamiento hacia atrás de la silla, el cual probablemente será el comando ejecutado con menor frecuencia.

Tabla 18. Tasa de éxito y tasa de error prueba comandos.

	Tasa de Éxito (%)	Muestras ignoradas (%)
Usuario 1	81.2	0
Usuario 2	93.7	0
Usuario 3	61.5	18.7
Usuario 4	100	0
Usuario 5	93.7	0
Promedio	86.1	3.7

Tabla 19. Matriz de confusión prueba comandos.

Esperado Obtenido	7 Hz	9 Hz	13 Hz	15 Hz	Muestras ignoradas
7 Hz	15	0	0	1	1
9 Hz	3	19	0	1	0
13 Hz	0	0	19	2	0
15 Hz	1	1	1	14	2
	78.9%	95%	95%	77.7%	

6.3.2 Resultados prueba laberinto

En la tabla 20 se muestra el tiempo que tardó cada voluntario en llegar a la meta del laberinto, el cual está directamente relacionado con la cantidad de comandos que tuvo que ejecutar debido a errores de clasificación del sistema y el tiempo adicional que toma repetir un comando cuando el sistema lo ignora por contaminación. Se puede observar la estrecha relación entre el tiempo que tardó cada voluntario y la rata de éxito del sistema obtenida en la prueba anterior para dicho voluntario. Esto puede estar relacionado con que los potenciales en estado estable se presentan de manera más contundente en algunos usuarios que en otros.

Tabla 20. Resultados de cada usuario en el laberinto.

	Tiempo en Laberinto (min)	Numero de comandos ejecutados	Rata de Éxito (%)
Usuario 1	4.13	20	100
Usuario 2	4.11	20	100
Usuario 3	6.68	33	80.3
Usuario 4	4.53	22	95.4
Usuario 5	4.92	25	90
Promedio	4.87	24	93.1

Todos los 5 voluntarios que ejecutaron la prueba laberinto pudieron terminar la prueba exitosamente, es decir, fueron capaces de salir del laberinto modulando las señales eléctricas de sus cerebro. La cantidad mínima de comandos para resolver el laberinto son 20, teniendo en cuenta que por cada comando hay 12 segundos (4 adquisición, 2 animación, 4 pausa, 2 offset encendido y apagado de estímulos) el tiempo mínimo teórico de solución del laberinto es de 4 minutos. Los 5 voluntarios tuvieron buenos tiempos. Dos de ellos lograron un recorrido perfecto de solo 20 comandos obteniendo 4.13 y 4.11 minutos respectivamente, tal que el sistema reconoció correctamente todos los comandos y no tuvieron que repetir o corregir ningún movimiento.

Otro indicador de desempeño del sistema es la llamada rata de transferencia de información (*ITR, del inglés Information Transfer Rate*). Esta medida indica la cantidad de información confiable recibida por el sistema por unidad de tiempo [32], y se calcula de acuerdo con la siguiente formula:

$$ITR(Bpm) = \frac{60}{T} * (\log_2 N + p \log_2 p + (1 - p) \log_2 (\frac{1 - p}{N - 1}))$$

Donde N es la cantidad de comandos, p corresponde a la tasa de éxito y T es el tiempo de detección. La ITR obtenida es de 18 Bits/min, la velocidad es alta para este sistema considerando que es de bajo costo usando un casco comercial como lo es el Emotiv EPOC.

6.4 RESUMEN

Se realizaron pruebas en configuración offline y online. En configuración offline se adquirieron las señales EEG de 15 sujetos que debían enfocar uno de los estímulos visuales por 30 segundos tres veces (proceso que se repetía para cada estímulo), y no recibían ningún tipo de realimentación por parte del sistema. Con estos datos se comparó el desempeño del sistema usando las diferentes técnicas de extracción de características y el clasificador máxima criterion para diferentes ventanas de análisis; y se obtuvo un porcentaje de aciertos máximo del 82% usando la herramienta MEC para una ventana de análisis de cuatro segundos. Luego se implementaron los tres clasificadores, de manera que las características obtenidas a partir de tres sujetos se usaron para el entrenamiento y los datos de los 12 sujetos restantes se usaron para validar y evaluar el funcionamiento de los clasificadores. Se comparó el desempeño de las diferentes combinaciones de tipos de características y clasificadores, y se encontró que el algoritmo MEC y el clasificador bayesiano entregaban los mejores resultados, tal que el desempeño del sistema usando estos métodos es del 87% para una ventana de análisis de cuatro segundos. Posteriormente se realizaron las pruebas en configuración online usando solo la técnica MEC para el cálculo de características y el clasificador bayesiano que se entrenó en configuración offline. Se realizaron dos tipos de pruebas: la prueba comandos y la prueba laberinto. En la primera el usuario debía transmitir el comando que se le indicaba y podía observar en la pantalla como había sido interpretado dicho comando y ejecutado en una silla de ruedas virtual. La segunda prueba permite que el usuario navegue a través de un laberinto con los comandos que sean de su elección hasta que salga del laberinto y llegue a una meta. Se trabajó con una ventana de análisis de cuatro segundos para ambas pruebas y en la primera se obtuvo una tasa de éxito del 86% y en la segunda del 93%.

7. CONCLUSIONES

El trabajo presenta el desarrollo una interfaz cerebro computador basada en el paradigma de potenciales de estado estable evocados visualmente; se validó su funcionamiento y se comparó el desempeño de diferentes técnicas de procesamiento de señales EEG para la implementación de este tipo de sistemas. Se puede concluir que:

Se desarrolló una plataforma hardware para generar estímulos visuales con las características necesarias para generar los potenciales de estado estable en las señales EEG. Los estímulos pueden generarse a 7.02, 9.07, 13.15 y 15.2 Hz, las cuatro frecuencias se encuentran en el rango de las bajas frecuencias, para garantizar gran amplitud del potencial.

Se implementaron y compararon las técnicas MEC, MSI y CCA para la extracción de características de las señales EEG, siendo el método MEC el que presentó el mejor desempeño. Esto se debe a que el método MEC atenúa al máximo las señales que capturan los electrodos que no corresponden a los potenciales en estado estable esperados y posteriormente detecta la presencia de los potenciales.

Se implementaron y compararon los clasificadores Bayesiano, kNN y RNA para la discriminación de las señales EEG, siendo el clasificador Bayesiano el que presentó el mejor desempeño.

Se implementó una opción de rechazo mediante un índice que establece la calidad de las señales que aprovecha la información que se genera durante el cálculo de las características por el método MEC. De este modo, no se introduce un procesamiento adicional, y el sistema ahorra el tiempo de procesamiento de esa señal.

Una vez establecida las mejores técnicas para extracción de características y de clasificación; esto es, el método MEC y el clasificador Bayesiano, respectivamente. Se realizaron pruebas off-line y on-line. En el primer caso se alcanzó un porcentaje de éxito del 87% con una ventana de cuatro segundos a 12 sujetos de prueba. En la configuración online se alcanzó un porcentaje promedio de éxito del 86% al estimular por un tiempo de cuatro segundos a cinco sujetos de prueba diferentes a los 12 sujetos anteriores; así mismo, se obtuvo una ITR de 18 (Bits/min).

El sistema permite el comando de una silla de ruedas virtual a partir de la modulación de la actividad cerebral del usuario, el sistema está restringido a cuatro comandos y la ejecución de estos se efectúa cada 10 segundos.

8. TRABAJO FUTURO

- Los trabajos futuros están orientados a la adecuación de la interfaz cerebro-computador para ser implementada en sistemas embebidos como Raspberry pi o incluso un Smartphone, para así aumentar el impacto y los alcances del sistema acercándose a una solución final que pueda ser parte del día a día de cualquier persona.
- Adecuación de una silla de ruedas eléctrica real para ser implementada junto al sistema elaborado, la silla debe tener sensorización e inteligencia suficiente para tomar decisiones y proteger al usuario en movimientos peligrosos.
- Explorar el desempeño del sistema usando matrices LED de otro color y patrones de parpadeo diferente, ya que pueden generar potenciales evocados de mayor magnitud y de esta manera mejorar la probabilidad de éxito del sistema.
- Ampliar el número de clases a discriminar por el sistema, para dar más opciones al usuario que le permitan girar hacia la derecha o hacia izquierda con ángulos de diferentes dimensiones. Además se podría implementar una aplicación con un teclado virtual o un brazo robótico de varios grados de libertad.
- Implementar el sistema en un casco de código abierto como Open Bci, para tener más libertad en la adquisición de las señales y la elaboración de aplicaciones, tal que se pueden modificar los códigos que vienen de fábrica con el casco.

REFERENCIAS

- [1] Departamento Administrativo Nacional de Estadística, “Censo general 2005,” *Dane*, pp. 1–6, 2010.
- [2] R. Singla, “Comparison of SSVEP Signal Classification Techniques Using SVM and ANN Models for BCI Applications,” *Int. J. Inf. Electron. Eng.*, vol. 4, no. 1, pp. 6–10, 2014.
- [3] J. Muñoz, O. Henao, J. F. López, and J. F. Villada, “BKI: Brain Kinect Interface, a new hybrid BCI for rehabilitation,” in *Games for Health*, Wiesbaden: Springer Fachmedien Wiesbaden, 2013, pp. 233–245.
- [4] S. E. N. Barrera, Luis Carlos, H. Loaiza, “Comando de un cursor en 2d por señales EEG,” *Vasa*, p. 75, 2014.
- [5] V. Ibero, a D. L. Recursos, and M. La A, “Libro de Actas,” *VII Congr. Iberoam. Tecnol. Apoyo a la Discapac.*, p. 280, 2013.
- [6] D. Mateo and L. López, “Trabajo de grado para optar al título de Ingenieros Biomédicos Jairo Antonio Cuartas Molina Candidato a Magister,” 2013.
- [7] R. Ortner, B. Z. Allison, G. Korisek, H. Gaggel, and G. Pfurtscheller, “An SSVEP BCI to control a hand orthosis for persons with tetraplegia,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 19, no. 1, pp. 1–5, 2011.
- [8] L. Ko, S. Lin, and W. Liang, “Development of SSVEP-based BCI using Common Frequency Pattern to Enhance System Performance,” 2014.
- [9] “VOG-ENHANCED ICA FOR SSVEP RESPONSE DETECTION FROM CONSUMER-GRADE EEG Mohammad Reza Haji Samadi , Neil Cooke Interactive Systems Engineering Research Group , University of Birmingham , U . K .,” pp. 2025–2029.
- [10] R. Wang, W. Wu, K. Iramina, and S. Ge, “The Combination of CCA and PSDA Detection Methods in a SSVEP-BCI System,” pp. 2424–2427, 2014.
- [11] L. Zhao, P. Yuan, L. Xiao, Q. Meng, D. Hu, and H. Shen, “Research on SSVEP feature extraction based on HHT,” *Proc. - 2010 7th Int. Conf. Fuzzy Syst. Knowl. Discov. FSKD 2010*, vol. 5, no. Fskd, pp. 2220–2223, 2010.
- [12] H. Jian and K. Tang, “Improving Classification Accuracy of SSVEP based BCI using RBF SVM with Signal Quality Evaluation,” vol. 1, pp. 302–306, 2014.
- [13] D. Aminaka, S. Makino, and T. M. Rutkowski, “Chromatic SSVEP BCI Paradigm Targeting the Higher Frequency EEG Responses,” 2014.
- [14] J. Evelio, C. Aristizábal, G. Psi, D. Universidad, G. Gama, and D. Universidad, “STEADY

STATE VISUALLY EVOKED POTENTIALS BASED BRAIN COMPUTER INTERFACE SYSTEM,” vol. 25, no. 1, pp. 120–125, 2014.

- [15] J. Castillo, “Interface cérebro computador baseada em ssvep e erd para o comando de um veículo autônomo,” 2014.
- [16] L. F. Nicolas-Alonso and J. Gomez-Gil, “Brain computer interfaces, a review,” *Sensors*, vol. 12, no. 2, pp. 1211–1279, 2012.
- [17] E. A. Larsen and A. I. Wang, “Classification of EEG Signals in a Brain- Computer Interface System,” *Nor. Univ. Sci. Technol.*, no. June, pp. 1–72, 2011.
- [18] R. Q. Quiroga, “Quantitative analysis of EEG signals : Time-frequency methods and Chaos theory Quantitative Analyse von EEG-Signalen : Zeit-Frequenz-Methoden und Chaos-Theorie,” *Inst. Physiol. Univ. Lubeck Inst. Signal Process. Univ. Lubeck*, vol. 1032, pp. 254–7, 1998.
- [19] S. Sanei and J. a. Chambers, *EEG Signal Processing*, vol. 1, no. 11. 2007.
- [20] S. Lee, Y. Shin, S. Woo, K. Kim, and H. Lee, “Review of Wireless Brain-Computer Interface Systems,” *Brain-Computer Interface Syst. - Recent Prog. Futur. Prospect.*, 2013.
- [21] D. Zhu, J. Bieger, G. Garcia Molina, and R. M. Aarts, “A survey of stimulation methods used in SSVEP-based BCIs,” *Comput. Intell. Neurosci.*, vol. 2010, 2010.
- [22] Z. Wu and D. Yao, “A Study on SSVEP-Based BCI,” *J. Electron. Sci. Technol. China*, vol. 7, no. 1, pp. 7–11, 2009.
- [23] Emotiv Systems, “Emotiv EPOC (Brain Computer Interface & Scientific Contextual EEG),” 2014.
- [24] C. Brunner, G. Andreoni, L. Bianchi, B. Blankertz, C. Breitwieser, S. Kanoh, I. P. Susila, and B. Venthur, “BCI Software Platforms,” *Towar. Pract. Brain-Computer Interfaces*, pp. 303–331, 2013.
- [25] A. Delorme, “MATLAB-based tools for BCI research,” *Brain-Computer Interfaces*, pp. 241–259, 2010.
- [26] A. E. Hassanien and A. T. Azar, Eds., *Brain-Computer Interfaces*, vol. 74. Cham: Springer International Publishing, 2015.
- [27] “Arduino Store - community and electronics.” [Online]. Available: <https://store.arduino.cc/product/GBX00066>. [Accessed: 29-Jan-2016].
- [28] A. Szalowski and D. Picovici, “Investigating the robustness of constant and variable period graphics in eliciting steady state visual evoked potential signals using Emotiv EPOC, MATLAB, and Adobe after effects,” in *2015 26th Irish Signals and Systems Conference*

(ISSC), 2015, pp. 1–8.

- [29] Dell Inc. NASDAQ, “Dell OptiPlex 9020 Mini Tower Owner ’ s Manual,” 2013.
- [30] K. A. Ludwig, R. M. Miriani, N. B. Langhals, M. D. Joseph, D. J. Anderson, and D. R. Kipke, “Using a Common Average Reference to Improve Cortical Neuron Recordings From Microelectrode Arrays,” *J. Neurophysiol.*, vol. 101, no. 3, pp. 1679–1689, Mar. 2009.
- [31] Y. Wang, R. Wang, X. Gao, B. Hong, and S. Gao, “A practical VEP-based brain-computer interface.,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 14, no. 2, pp. 234–9, 2006.
- [32] W. Nan, C. M. Wong, B. Wang, F. Wan, P. U. Mak, P. I. Mak, and M. I. Vai, “A comparison of minimum energy combination and canonical correlation analysis for SSVEP detection,” *2011 5th Int. IEEE/EMBS Conf. Neural Eng. NER 2011*, no. 3, pp. 469–472, 2011.
- [33] O. Friman, I. Volosyak, and A. Gräser, “Multiple channel detection of steady-state visual evoked potentials for brain-computer interfaces,” *IEEE Trans. Biomed. Eng.*, vol. 54, no. 4, pp. 742–750, 2007.
- [34] D. J. Hand and K. Yu, “Idiot’s Bayes: Not So Stupid after All?,” *Int. Stat. Rev. / Rev. Int. Stat.*, vol. 69, no. 3, p. 385, Dec. 2001.
- [35] G. Pires, M. Castelo-Branco, and U. Nunes, “Visual P300-based BCI to steer a wheelchair: A Bayesian approach,” in *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2008, pp. 658–661.

ANEXOS

Anexo.1 Consentimiento escrito entregado a los voluntarios.



INTERFAZ CEREBRO COMPUTADOR BASADA EN POTENCIALES DE ESTADO ESTABLE EVOCADOS VISUALMENTE PARA EL CONTROL DE MOVIMIENTO DE UN DISPOSITIVO VIRTUAL

Consentimiento informado

El Grupo de Investigación PSI de la Universidad del Valle se encuentra desarrollando el proyecto de investigación “Interfaz Cerebro Computador Basada en Potenciales de Estado Estable Evocados Visualmente para el Control de Movimiento de un Dispositivo Virtual” el cual tiene como propósito desarrollar una interfaz cerebro computador que permita la interacción del usuario con un dispositivo externo a partir de la interpretación de su actividad cerebral.

En esta investigación participarán los estudiantes de ingeniería electrónica Johan Leandro Porras y María Estefanía Rengifo y como directores los profesores Humberto Loaiza y Sandra Nope. Para el desarrollo del proyecto se espera contar con al menos la participación de 20 voluntarios. Le estamos solicitando autorización para hacer mediciones de su actividad cerebral mientras observa una fuente de luz parpadeante y así nos permita analizar los datos que son de gran importancia para el desarrollo de una interfaz cerebro computador. Si lo desea puede conservar una copia del presente consentimiento informado, en caso de participar en el experimento.

El tiempo de participación es de aproximadamente 30 minutos incluyendo los periodos de descanso. Cada sesión tiene una duración de 30 segundos, después de los cuales puede descansar por un minuto o por el tiempo que considere

necesario para atenuar la fatiga visual. En total se realizarán 12 sesiones. En caso de que sienta mucha fatiga visual, o por cualquier motivo desee retirarse del experimento, por favor informárselo al investigador para dar por terminado el experimento y su participación en el proyecto. Después de tomar los datos de los participantes se realizará la implementación de algoritmos y técnicas para interpretarlos.

La participación en el proyecto puede producir incomodidad y fatiga visual si el sujeto de prueba se expone prolongadamente pero no traerá ningún riesgo contra su salud, ni atenta contra su integridad moral. Como parte de los beneficios que tiene el desarrollo de esta investigación es aportar experiencia y conocimiento en el desarrollo interfaces computador, las cuales son sistemas útiles para las personas que padecen de deficiencias motoras. Es importante mencionar que no existe ninguna compensación o pago por la participación, ni tampoco implicará ningún tipo de gasto para usted. Es por ello que su participación es voluntaria.

La información que sea recolectada será manejada de forma confidencial, por tanto sólo el equipo de investigación tendrá acceso a ella. No se utilizarán nombres ni documentos de identificación. Sólo códigos que serán usados por el equipo de investigación.

Usted y cada participante podrá solicitar explicación sobre el procedimiento que se lleva a cabo durante el experimento y sobre el proyecto en general. Los investigadores se comprometen una vez finalizado el proyecto mostrar resultados sobre el desempeño obtenido con la interfaz a la comunidad que le interese conocerlos.

Consentimiento:

Entiendo el propósito de la investigación y comprendo cuál es mi participación. Autorizo que se conecte un dispositivo en mi cuero cabelludo para la toma de datos de mis señales cerebrales mientras oriento mi mirada a una fuente de luz parpadeante.

Autorizo utilizar los resultados obtenidos en la presente investigación, en estudios similares futuros, previa aprobación del Comité de Ética de la Universidad del Valle.

Nombre _____

Firma _____

Para cualquier información adicional que requiera sobre esta investigación puede ponerse en contacto en la Universidad del Valle con: María Estefanía Rengifo, teléfono celular: 3004765691, correo electrónico: maria.rengifo.bedoya@correounivalle.edu.co o con Johan Leandro Porras, teléfono celular: 3163263831, correo electrónico: johan.porras@correounivalle.edu.co, o con

Humberto Loaiza, correo electrónico: Humberto.loaiza@correounivalle.edu.co o con Sandra Nope, correo electrónico: Sandra.nope@correounivalle.edu.co. O a través del correo electrónico del Comité de Ética Humana de la Facultad de Salud – Universidad del Valle: eticasalud@correounivalle.edu.co y Teléfono 518 5677

Testigo No. 1

Testigo No. 2

Fecha de diligenciamiento: _____

