



Universidad Autónoma de Querétaro
 Facultad de Informática
 Doctorado En Ciencias de la Computación

DISEÑO DE ALGORITMOS BASADOS EN INTELIGENCIA COLECTIVA ANIMAL
 PARA EL DISEÑO DE INTERFACES CEREBRALES BASADAS EN NEURO-
 MECANISMOS POR EVENTOS VISUALES

Opción de titulación
Tesis

Que como parte de los requisitos para obtener el Grado de
 Doctorado en Ciencias de la Computación

Presenta:

M.C. Santiago Miguel Fernández Fraga

Dirigido por:

Dr. Marco Antonio Aceves Fernández

Dr. Marco Antonio Aceves Fernández
 Presidente

Firma

Dr. Jesús Carlos Pedraza Ortega
 Secretario

Firma

Dr. Juan Manuel Ramos Arreguín
 Vocal

Firma

Dr. Saúl Tovar Arriaga
 Suplente

Firma

Dr. Arturo González Gutiérrez
 Suplente

Firma

M.I.S.D. Juan Salvador Hernández
 Valerio Director de la Facultad de
 Informática

Firma

Dra. Ma. Guadalupe Flavia Loarca Piña
 Director de Investigación y Posgrado

RESUMEN

Las interfaces cerebrales (BCI, por sus siglas en inglés Brain Computer Interface) se basa en el uso de la actividad cerebral de una persona para generar acciones de control en dispositivos electrónicos; las funciones básicas de dichos sistemas son medir la actividad cerebral, procesarla para obtener características de interés y, una vez obtenida, interactuar con el entorno de la manera deseada por el usuario. Para ello, se registra y procesa la actividad cerebral de la persona con el fin de diferenciar entre diferentes patrones de señal, asociados con cambios en la actividad cerebral tanto voluntariamente como de forma inducida. Esta tecnología está orientada principalmente a personas con algún tipo de discapacidad de movimiento, parcial o total o con algún tipo de parálisis, ya que la generación de acciones de control sin tener que realizar ningún tipo de movimiento por parte de la persona, hace que las interfaces cerebrales se utilicen para mejorar su calidad de vida.

El desarrollo de los sistemas BCI se basa principalmente en la información obtenida mediante el procesamiento de las señales cerebrales. Además de la obtención de señales, los pasos de extracción y selección de características son vitales para el desarrollo de aplicaciones ya que se necesita para extraer información significativa de la señal cerebral. Un factor esencial para el funcionamiento exitoso de los sistemas BCI son los métodos utilizados para procesar las señales cerebrales.

El presente trabajo presenta la implementación de algoritmos de inteligencia colectiva animal, los cuales son capaces de producir soluciones de bajo costo computacional para diversos problemas complejos y de optimización. Se prestará el algoritmo de optimización de colonia de hormigas propuesto por *Dorigo et al.* en 1996, el cual se inspira en el comportamiento de forrajeo de algunas especies de hormigas, que depositan feromonas en el suelo con el fin de hacer alguna tendencia favorable que debe seguir otros miembros de la colonia que aumenta la probabilidad de que otras hormigas sigan el mismo camino resultando en una forma óptima desde el nido hasta la fuente de alimento. Los biólogos han demostrado que muchos de los comportamientos observados en el nivel de colonia de insectos sociales pueden explicarse por modelos bastante simples en los que sólo la comunicación está presente. La idea detrás de los algoritmos de hormigas es utilizar alguna forma de comunicación artificial para coordinar las sociedades de agentes artificiales.

El algoritmo de optimización de colonia de hormigas se ha utilizado en el procesamiento de datos biomédicos como metodología para optimizar las señales cerebrales mejorar las características de esas señales y obtener un mejor desempeño en el desarrollo de los sistemas BCI. La metodología presentada se basará en los sistemas BCI basados en potenciales evocados visuales de estado estacionario, estos sistemas se caracterizan por el uso de estímulos sensibles a los procesos dinámicos de la parte occipital de la corteza cerebral.

(Palabras clave: algoritmos de inteligencia colectiva animal, inteligencia de enjambre, optimización por colonia de hormigas, optimización por enjambre de partículas BCI, ACO, PSO)

SUMMARY

The Brain Computer Interface (BCI) is based upon the use of a person's brain activity to generate control actions on electronic devices; the basic functions of such systems are to measure brain activity, process it to obtain features of interest and, once obtained, to interact with the environment in the manner desired by the user. To do this, the person's brain activity is recorded and processed in order to differentiate between different signal patterns, associated with changes in brain activity both voluntarily and in an induced manner. This technology is oriented mainly to people with some type of movement disability, partial or total or with some kind of paralysis, since the generation of control actions without having to make any kind of movement by the person, makes the Brain interfaces are used to improve their quality of life.

The development of BCI systems is mainly based on information obtained through the processing of brain signals. In addition to obtaining signals, the extraction and feature selection steps are vital for application development, as it is needed to extract meaningful information from the brain signal. An essential factor for the successful operation of BCI systems are the methods used to process brain signals.

The present work presents the implementation of collective animal intelligence algorithms, which are able to produce solutions of low computational cost for various complex problems and optimization. The ant colony optimization algorithm proposed by *Dorigo et al.* in 1996 will be provided, which is inspired by the foraging behavior of some ant species that put pheromones in the soil in order to make some favorable trends that must follow other members of the colony that increases the likelihood that other ants will follow the same path resulting in an optimal form from the nest to the food source. Biologists have shown that simple models in which can explain many of the behaviors observed at the level of social insect colony only communication is present. The idea behind ant algorithms is to use some form of artificial communication to coordinate artificial agent societies.

The ant colony optimization algorithm has been used in biomedical data processing as a methodology to optimize brain signals to improve the characteristics of these signals and to obtain better performance in the development of BCI systems. The methodology presented will be based on BCI systems based on visual evoked potentials of steady state; these systems are characterized by the use of sensitive stimuli to the dynamic processes of the occipital part of the cerebral cortex.

(Keywords: animal collective intelligence algorithms, swarm intelligence, ant colony optimization, particle swarm optimization BCI, ACO, PSO)

DEDICATORIAS

A mi Madre, Esposa e Hijos

Que tuvieron el amor y la paciencia que me conllevó a este reto personal

A la memoria de Padre[†]

Una especial dedicatoria a Dr. Jaime Rangel Mondragón[†] que siempre me inspiró
y alentó a dedicarme a investigar

*“Nunca consideres el estudio como una obligación, sino como una oportunidad
para penetrar en el bello y maravilloso mundo del saber”*

Albert Einstein (1879-1955)

AGRADECIMIENTOS

Al Instituto Tecnológico de Querétaro, a la Universidad Autónoma de Querétaro, al Instituto Tecnológico Nacional de México a través del Programa para el Desarrollo Profesional Docente (PRODEP) que me dieron la oportunidad de realizar mis estudios de Doctorado.

A mis Director de Tesis Marco Antonio Aceves Fernández, mis maestros Arturo Gutierrez González, Emilio Vargas Soto, Efrén Gorrostieta Hurtado, Jesús Carlos Pedraza, Juan Manuel Ramos Arreguín, Juvenal Rodríguez Reséndiz y Saúl Tovar Arriaga, que siempre fueron excelentes guías y consejeros durante todo mi proceso doctoral

A mis Amigos Carlos Andrés de la Parra Dorador y Guillermo Fernández Romero por su paciencia y apoyo incondicional.

A mis compañeros de generación, Daniel García y Elías por su compañerismo y apoyo.

Mi más sincera gratitud.

“Los líderes no nacen, se hacen, están hechos por el esfuerzo duro, que es el precio que todos nosotros debemos pagar para alcanzar cualquier meta que valga la pena”

Vince Lombardi (1913-1970)

TABLA DE CONTENIDO

1. INTRODUCCIÓN	1
1.1. Interfaces Cerebrales	1
1.2. Inteligencia colectiva	3
1.3. Justificación.....	6
1.4. Descripción del problema.....	6
1.5. Hipótesis	10
1.6. Objetivo General	10
1.7. Objetivo Particular	10
2. MARCO TEÓRICO	12
2.1. Proceso eléctrico de las neuronas	12
2.2. Tecnología de Electroencefalograma.....	14
2.3. Señales de Electroencefalograma	15
2.4. Ritmos Cerebrales.....	16
2.5. Sistema Internacional 10-20.....	20
2.6. Topología Cerebral.....	22
2.7. Modelo BCI	26
2.8. Problemas de optimización	29
2.9. Metaheurística.....	30
2.10. Computación Evolutiva	31
2.11. Inteligencia de enjambre	33
2.11.1. Fundamentos	34
3. METODOLOGÍA	38
3.1. Protocolo de pruebas	38

3.2.	Materiales y equipamiento	39
3.3.	Sistemas BCI basados en SSVEP (BCI-SSVEP).....	41
3.4.	Metodologías de Experimentos para sistemas BCI-SSVEP.....	44
3.4.1.	Estímulos visuales repetitivos.....	44
3.4.2.	Estímulos visuales por parpadeo.....	47
3.4.3.	Búsqueda Visual con Imágenes Naturales	50
3.4.4.	Discriminación Visual.....	51
3.4.5.	Otras pruebas.....	53
3.5.	Algoritmos de procesamiento de señales para sistemas BCI-SSVEP	55
3.5.1.	Canonical Correlation Analysis (CCA)	60
3.5.2.	Empirical Mode Decomposition (EMD)	61
3.5.3.	Fast Fourier Transform (FFT)	64
3.5.4.	Independent Components Analysis (ICA).....	66
3.5.5.	Multivariate Synchronization Index (MSI)	70
3.5.6.	Principal Component Analysis (PCA)	72
3.5.7.	Power Spectral Density (PSD).....	74
3.5.8.	Wavelet Transform (WT)	74
3.6.	Algoritmos de inteligencia de enjambre.....	78
3.6.1.	Algoritmos de Optimización de Colonia de Hormigas.....	78
3.6.2.	Sistema de hormigas (AS).....	80
3.6.3.	Algoritmos de Optimización de Enjambre de Partículas (PSO)	81
4.	RESULTADOS Y DISCUSIÓN	84
4.1.	Experimentación	84
4.2.	Modelo Propuesto	84
4.3.	Algoritmos	87

4.3.1. Algoritmo de Sistema de Hormigas (AS)	88
4.3.2. Algoritmo de Optimización por Enjambre de Partículas (PSO).....	104
4.3.3. Discusión	124
5. CONCLUSIONES	126
6. REFERENCIAS	128
APÉNDICE A	141
APÉNDICE B	144
APÉNDICE C	167
APÉNDICE D	174

ÍNDICE DE FIGURAS

1.1 Modelo BCI. (Shih et al. 2012)	1
1.2 Comportamientos colectivos en la naturaleza.....	4
1.3 Patrones de actividad cerebral, (Amiri, 2013).....	8
1.4 Áreas de aplicación de los sistemas BCI (Nicolas-Alonso y Gómez-Gil, 2012).	10
2.1 Componentes de la neurona (De la Torre, 2012)	12
2.2 Generación de potenciales post-sinápticos (Kuzovkin, 2013).	13
2.3 señal eléctrica a partir de dos electrodos (Maarten De Vos, 2009)	15
2.4 Conjunto de señales EEG	15
2.5 Las 5 bandas de frecuencias principales y su relación entre sí.....	16
2.6 Representación de las frecuencias de los ritmos cerebrales, (Sudhakaran, 2012)	17
2.7 Intensidad de la de la señal con referente a las frecuencias de los ritmos cerebrales (Kennerly, 2004).	19
2.8 (a) Identificación de las partes del cerebro. (b) Ubicación de electrodos en el Sistema Internacional de Sociedades de Electroencefalografía 10-20 (Olivas, 2010)	20
2.9 Identificación de electrodos. (a) EEG Emotiv Epoc+ (b) EEG Emotiv Epoc+ con el Sistema Internacional 10-20.	21
2.10 Relación de regiones y ritmos cerebrales.....	21
2.11 (a) Sistema Invasivo, (Schalk, 2011). (b) Sistema No Invasivo, (MedicalExpo, 2015)	22
2.12 Relación de procesos y/o actividades cerebrales y su ubicación de los electrodos en el cuero cabelludo. (Walker J. 2007).....	25
2.13 Diagrama de bloques de los sistemas BCI.....	26
2.14 Modelo funcional de los Sistemas BCI propuesto por Mason y Birch (2003). 27	
2.15 Taxonomía de la Computación Evolutiva	33
2.16 Representación de stigmergy y auto-organización por una colonia de hormigas, (Lewis, 2015).....	36

3.1 Electroencefalograma marca EMOTIV modelo EPOC+ (Emotiv 2014).....	40
3.2 Software Emotive Xavier TestBench	41
3.3 Software EEGLAB.....	41
3.4(a) Sección transversal de un ojo humano. (b) vista esquemática de la retina incluyendo receptores de luz de conos y bastones, (adaptado de la Enciclopedia Británica, 1994-Shubert de 2006).....	42
3.5 Tiempo de entrenamiento vs ITR, (García 2008)	43
3.6 SSVEP Amplitud promedio en función de la frecuencia de estimulación, (García 2008).	43
3.7 Frecuencias de estímulos. Pantalla de 60 Hz en su frecuencia de actualización	44
3.8 Dispositivos de Leds para estímulos visuales	45
3.9 Estímulos gráficos individuales.	45
3.10 Estímulos de patrón inverso.....	46
3.11 Configuración inicial prueba Light and Dark.....	47
3.12 Configuración experimento “Command icon Flickered”	49
3.13 Configuración experimento “Square flickered”	49
3.14 Configuración de la prueba “Four Square”.	50
3.15 Configuración de la prueba de Búsqueda Visual con Imágenes Naturales...	51
3.16 Configuración de la prueba de las 5 cajas.....	52
3.17 Configuración de intervalos de la prueba de las 5 cajas	52
3.18 Identificación de eventos, prueba de las 5 cajas.	53
3.19. Pruebas adicionales para SSVEP	54
3.20 Mezcla de señales independientes con PDF no Gaussiana.....	68
3.21 Identificación de los elementos de $x = As$ para señales EEG.....	69
3.22 Descomposición de sub-bandas.	76
3.23 Representación de la optimización del “forrajeo” a través del tiempo	79
3.24 Representación de un enjambre de partículas	82
3.25 Optimización de enjambre de partículas. (a) Wahab, 2015 (b) Biswas, 2016.	82
4.1 Modelo ICA para BCI	85

4.2 Diagrama de flujo del modelo propuesto.....	86
4.3 Esquema de optimización ACO.....	86
4.4 Esquema de Optimización PSO.....	87
4.5 Serie de tiempo y su proyección.....	87
4.6 Esquema del proceso AS, (Johann Dréo, 2006).	88
4.7 La ruta de desplazamiento del algoritmo ACO.....	89
4.8 Diagrama de Flujo de la Implementación del algoritmo AS.....	90
4.9 Señales EEG originales. Representación de toda la prueba.....	91
4.10 Señales EEG originales. Segmento de 5 s.....	91
4.11 Señales optimizadas. (a) Representación de toda la prueba. (b) Segmento de 5 s.	91
4.12 Costo Computacional de AS. (a) 10 Iteraciones. (b) 5 Iteraciones.....	92
4.13 Distancia total recorrida. (a) 10 Iteraciones. (b) 5 Iteraciones.....	93
4.14 Modelo ICA-AS.....	93
4.15 Representación de las mezclas.....	94
4.16 Función de densidad de probabilidad.....	94
4.17 Componentes Independientes ICA-ACO.....	95
4.18 Señal original vs señal reconstruida, mezcla O1-O2.....	96
4.19 Señal original vs señal reconstruida, mezcla O1-ACO.....	96
4.20 Señal original vs señal reconstruida, mezcla O2-ACO.....	97
4.21 Histograma PDF normalizado de los componentes.	98
4.22 PSD de los canales y componentes.....	99
4.23 Representación del PSD. Señales originales y componentes.....	100
4.24 Identificación de la frecuencia de estímulo.....	100
4.25 Correlación de señales originales ICA-ACO.....	102
4.26 Correlación de señales reconstruidas ICA-ACO.....	103
4.27 Comparativo señales originales vs señales optimizadas ICA-ACO.....	104
4.28 Diagrama de Flujo de la Implementación del algoritmo PSO.....	105
4.29 Señales original vs optimizadas. Representación de toda la prueba.	106
4.30 Señales originales vs optimizadas. Representación de un segmento de 5 s.	106

4.31 Desempeño PSO para segmentos de 5 s.	107
4.32 Modelo ICA-PSO.....	108
4.33 Mezcla de señales.....	108
4.34 Función de densidad de probabilidad.....	109
4.35 Componentes Independientes ICA-PSO.....	109
4.36 Componentes Independientes ICA-PSO.....	110
4.37 Reconstrucción de las señales con la mezcla O1-O2	111
4.38 Reconstrucción de las señales con la mezcla O1-PSO-O1.....	111
4.39 Reconstrucción de las señales con la mezcla O1-PSO-O2.....	112
4.40 Reconstrucción de las señales con la mezcla O2-PSO-O1.....	112
4.41 Reconstrucción de las señales con la mezcla O2-PSO-O2.....	113
4.42 Histogramas de los componentes Mezcla O1-O2.	113
4.43(a) Mezcla O1-PSO-O1. (b) Mezcla O1-PSO2. (c) Mezcla O2-PSO-O1. (d) Mezcla O2-PSO-O2	114
4.44 PSD de los electrodos y los componentes independientes. (a) Mezcla O1-O2.	115
4.45 Representación del PSD. (a) Señales originales y señales optimizadas....	116
4.46 Identificación de la frecuencia de estímulo.....	117
4.47 Identificación de la frecuencia de estímulo para las mezclas O1, O2 y O1-PSO.	117
4.48 Identificación de la frecuencia de estímulo para las mezclas O2-PSO	118
4.49 Correlación de señales originales ICA-PSO.....	120
4.50 Correlación de señales originales ICA-PSO.....	121
4.51 Comparativo señales originales vs señales optimizadas Modelo ICA-PSO	122
4.52 Comparativo señales reconstruidas vs señales optimizadas Modelo ICA-PSO	123
4.53 Desempeño del Modelo ICA-PSO.....	123
4.54 Totales del desempeño del Modelo ICA-PSOI	123

ÍNDICE DE TABLAS

1.1 Señales electrofisiológicas	8
2.1 Rangos de frecuencia básicos y tipos de actividades correspondientes.....	20
2.2 Relación de la colocación de los electrodos basados en el sistema Internacional 10-20 y su utilización en el estudio de los diferentes sistemas BCI.	25
2.3 Definición funcional de un Sistema BCI de Mason y Birch.....	27
2.4 Algoritmos basados en insectos y sus técnicas de desarrollo.....	37
3.1 Especificaciones técnicas EMOTIV modelo EPOC+ (Emotiv 2014).....	40
3.2 Métodos de pre-procesamiento de señales utilizados en BCI-SSVEP.....	56
3.3 Métodos de extracción de características de señales utilizados en BCI-SSVEP	58
3.4 Métodos de clasificación de características de señales utilizados en BCI-SSVEP	60
3.5 Familias Wavelet.....	77
3.6 Bandas de frecuencias de los diferentes niveles de descomposición de DWT.	77
3.7 Algoritmos basados en colonia de Hormigas	80
4.1 Correlación de señales del modelo ICA-ACO	101
4.2 desempeño de ICA-ACO.....	104
4.3 Correlación de señales del modelo ICA-PSO.....	119

1. INTRODUCCIÓN

1.1. Interfaces Cerebrales

Una Interface Computadora Cerebro (BCI, por sus siglas en inglés *Brain Computer Interface*), también conocida como Interface Cerebro Máquina (BMI, por sus siglas en inglés *Brain Machine Interface*) o Interface Cerebro Computadora (ICC), es un sistema que traduce la actividad electrofisiológica o la tasa metabólica de un sistema nervioso orgánico en señales que pueden ser medibles por un dispositivo electromecánico, es decir que tiene por objeto proporcionar un canal de comunicación no-muscular para el envío de comandos al mundo exterior utilizando la actividad eléctrica del cerebro, la cual al ser medible puede ser procesada, por lo cual permite la interacción entre el cerebro humano y una computadora. Entre las diversas aplicaciones de los sistemas BCI la más importante es la capacidad para controlar dispositivos externos por medio de la actividad eléctrica del cerebro, Figura 1.1 (Wolpaw *et al.*, 2000).




Figura 1.1 Modelo BCI. (Shih *et al.* 2012)

El origen de las tecnologías BCI nació con el descubrimiento de la naturaleza eléctrica del cerebro (Richard Caton, 1875). Hans Berger (1924) consiguió registrar la actividad cerebral mediante la electroencefalografía, siendo primero en registrar un electroencefalograma (EEG, por sus siglas en inglés *Electroencefalogram*) de un cerebro humano. Berger consiguió clasificar las diferentes ondas cerebrales, por ello las ondas Alfa (8-12Hz) también se denominan ondas Berger (Sanei y Chambers 2013).

En 1969 Fetz del Centro de Investigación de Primates Regional y el Departamento de Fisiología y Biofísica de la Universidad de Washington, Escuela de Medicina en Seattle, mostraron por primera vez que los monos podían aprender a controlar un brazo robot por medio de la actividad neuronal.

En 1970 se inicia la investigación de los primeros dispositivos BCI en la Universidad de California con una beca de la National Science Foundation y un contrato con DARPA.

En 1980 Apostolos Georgopoulos en la Universidad Johns Hopkins encontró una relación matemática entre las respuestas eléctricas de las neuronas de monos *macacos rhesus* y de un motor; en la misma época Lawrence Farwell y Emanuel Donchin desarrollaron una interfaz cerebro computadora basada en señales de EEG.

En los 90's se ha producido un rápido desarrollo en los sistemas BCI los cuales han sido capaces de captar señales complejas de córtex cerebral mediante la grabación del conjunto de las señales neuronales y el uso de éstos para controlar dispositivos externos. Grupos de investigación destacados: Richard Andersen, John Donoghue, Phillip Kennedy, Yang Dan, Miguel Nicolelis y Andrew Schwartz. El campo de investigación de los sistemas BCI durante la época de los 90's se centró principalmente en fines médicos, como la implantación de prótesis neuronales para poder recuperar la audición, vista o movilidad dañadas en un individuo.

En la primera década del siglo XXI la investigación además de fines médicos, se centró también en la industria de los videojuegos y se introdujeron en el mercado las primeras interfaces cerebro computadora no invasivas. Jessica Bayliss en el

2000 de la Universidad de Rochester mostró que los voluntarios que llevan cascos de realidad virtual podrían controlar elementos en un mundo virtual con lecturas de las ondas cerebrales P300 (llamada así por un pico de amplitud que aparece en el EEG aproximadamente unos 300 ms después de haberse producido un estímulo auditivo o visual poco frecuente). Posteriormente Bin He y colaboradores demostró la capacidad de una BCI basada en EEG para controlar el vuelo de un helicóptero virtual en el espacio de 3 dimensiones.

En la segunda mitad de la década del siglo XXI surgen empresas como Mindball, NeuroSky y Mattel dedicadas al desarrollo de aplicaciones relacionadas con juegos y empresas como Guger Technologies, Emotiv systems que han desarrollado modelos básicos de BCI como plataformas de desarrollo (Wolpaw *et al.*, 2012; Guger *et al.*, 2015).

Las tecnologías BCI, basada en sistemas de inteligencia artificial, implica el uso de dispositivos alámbricos y/o inalámbricos, que detectan las ondas cerebrales tanto en el nivel consciente como en el no consciente. Esta tecnología de procesamiento neuronal hace posible que las computadoras puedan interactuar directamente con el cerebro humano.

1.2. Inteligencia colectiva

La inteligencia colectiva es una forma de inteligencia que surge de la colaboración de muchos individuos, generalmente de una misma especie. Un enjambre es un gran número de agentes homogéneos, que interactúan localmente entre sí, y en su entorno, no cuenta con un control central que genere un comportamiento emergente. En las últimas décadas, los biólogos y científicos naturales han estado estudiando el comportamiento de los insectos sociales, debido a la increíble eficiencia de estos sistemas de enjambre naturales (Ahmed y Glasgow, 2012).


Las interacciones sociales entre individuos de enjambre pueden ser directas o indirectas. Los ejemplos de la interacción directa son a través del contacto visual o de audio, como la “Danza de las abejas”. La interacción indirecta ocurre cuando un individuo cambia el medio ambiente y los demás individuos responden al nuevo

entorno; como los rastros de feromonas de las hormigas que se depositan en su camino para buscar fuentes de alimentos. A finales de los años 80, se proponen las ideas científicas de estos sistemas de enjambre natural para el campo de la Inteligencia Artificial (Torres C.E.T, 2014).

La inteligencia colectiva o *Inteligencia de Enjambre* (SI, por sus siglas en inglés, *Swarm Intelligence*) se puede definir como una rama de la Inteligencia Artificial que se utiliza para modelar el comportamiento colectivo de enjambres sociales en la naturaleza; como las colonias de hormigas, abejas y bandadas de aves (Figura 1.2). Aunque estos agentes (insectos o individuos del enjambre) son relativamente poco sofisticados y con capacidades limitadas, al interactuar con ciertos patrones de comportamiento pueden lograr cooperativamente realizar tareas necesarias para su supervivencia.



(a)



(b)



Figura 1.2 Comportamientos colectivos en la naturaleza.

(a) Parvada de aves (Opusteno.rs, 2016). (b) Cardumen de peces (Christopher Swann, 1973). (c) enjambre de abejas (Sánchez Bravo, 2013). (d). Colonia de Hormigas (Mirón López, 2015).

La expresión "Swarm Intelligence" fue introducida por primera vez por Gerardo Beni, Suzanne Hackwood y Jing Wang en 1989 en el marco de optimización global como un conjunto de algoritmos para controlar enjambre robótico.

En 1991, el algoritmo de Optimización por Colonia de Hormigas (ACO, por sus siglas en inglés, *Ant Colony Optimization*) fue presentado como una solución de optimización combinatoria (CO, por sus siglas en inglés *Combinatory Optimization*) a problemas NP-duros (Dorigo y Stützle, 2004).

En 1995, la Optimización de Enjambre de Partículas (PSO, por sus siglas en inglés *Particle Swarm Optimization*) fue introducido por Eberhart y Kennedy en 1995 y fue pensado primero para simular al ave que se reúne en comportamiento social, posterior mente se ha utilizado para resolver problemas de permutaciones, calendarización de procesos, optimización de tráfico (Clerc, 2004, 2006; Moraglio *et al.* 2007)

A finales de los años 90, estos dos algoritmos de inteligencia enjambre empezaron a ir más allá de un interés científico puro y para entrar en el reino de las aplicaciones del mundo real (Eberhart *et al.*, 2001).

El Algoritmo de Colonia de Abejas Artificial (ABC, por sus siglas en inglés, *Artificial Bee Colony*) fue propuesto por Karaboga en el 2005 como nuevo miembro de la familia de algoritmos de inteligencia enjambre (Ahmed y Glasgow, 2012).

Recientemente ha llamado la atención de los investigadores que trabajan en problemas relacionados con la bioinformática en todo el mundo (Bonabeau *et al* 2001; Engelbrecht, 2005; Mitra y Hayashi 2006; Yang *et al.*, 2013; Zhang *et al.*, 2014). Los algoritmos que pertenecen a este campo están motivados por el comportamiento colectivo de un grupo de insectos sociales (como abejas, termitas y avispas). Estos insectos con una capacidad individual muy limitada pueden conjuntamente (cooperativamente) realizar muchas tareas complejas necesarias para su supervivencia. Durante los últimos años se ha producido un lento pero constante aumento de los trabajos de investigación que informan sobre el éxito de

la búsqueda basada en SI, la agrupación y los métodos de minería de datos aplicados al campo de la biología computacional (Das *et al.*, 2008).

1.3. Justificación

En los últimos años se han desarrollado, en el campo de la inteligencia artificial, tecnologías que permitan pasar por alto los canales de comunicación convencionales (es decir, los músculos o del habla) entre el cerebro de un usuario y una computadora. Los sistemas BCI monitorean la actividad cerebral del usuario y traduce sus intenciones en órdenes sin activar ningún músculo o nervio periférico (Millán *et al.*, 2010).

Un sistema BCI puede proporcionar una nueva forma de comunicación para usuarios especiales que no se pueden comunicar a través de vías normales. Puede enviar comandos, controlados por la actividad cerebral y que se distingue por el procesamiento de señales EEG (Amiri *et al.*, 2013). Los sistemas BCI han demostrado su aplicabilidad en varios contextos: la conducción de un robot o silla de ruedas, prótesis de funcionamiento, la selección de cartas de un teclado virtual, navegación en Internet o en realidades virtuales, el control de los juegos de computadora, y algunos otros. Este tipo de sistemas es una forma natural para aumentar las capacidades humanas al proporcionar un nuevo enlace de interacción con el mundo exterior y es especialmente relevante como una ayuda para las personas con discapacidad. El principio central de un sistema BCI es la capacidad de distinguir los diferentes patrones de actividad cerebral, cada uno asociado a una intención particular o a una tarea (Millán *et al.*, 2010).

El desarrollo de nuevos algoritmos que permitan optimizar el procesamiento de señales cerebrales mejorará el diseño del desarrollo de las interfaces cerebrales permitiendo avanzar en la búsqueda de soluciones para ayudar a dar una mejor calidad de vida a las personas con discapacidad y sus familias.

1.4. Descripción del problema

Existen varias técnicas para medir la actividad cerebral, pero debido a su bajo costo y portabilidad el EEG se ha utilizado en gran medida tanto en aplicaciones clínicas

y de investigación. El análisis cuantitativo y la interpretación de las señales EEG permiten la comprensión de la función cerebral, permitiendo primeramente el diagnóstico de estados disfuncionales en neurología, psiquiatría y psicofarmacología y el desarrollo de nuevas tecnologías que permitan asistir a personas con discapacidad motriz. Una de las aplicaciones de la investigación de EEG está en los sistemas de BCI.

Los sistemas BCI es una tecnología que permite controlar dispositivos electrónicos y/o mecánicos por medio de las ondas cerebrales. El cerebro genera señales eléctricas a través de las conexiones neuronales, esas señales eléctricas pueden ser detectadas por equipos especializados y pueden ser identificadas, y medidas para posteriormente manipularlas desde el exterior para controlar algún dispositivo.

Se han desarrollado sistemas BCI basados en los diferentes patrones de actividad cerebral generados por el EEG, la mayoría de las investigaciones se han centrado en los sistemas BCI basados en actividades sensomotoras y potenciales corticales lentos (SCP, por sus siglas en inglés *Slow Cortical Potentials*) (Bashashati *et al.*, 2007). Los sistemas BCI basados en actividades P300 y potenciales por eventos visuales de estado estable (SSVEP, por sus siglas en inglés *Steady State Visually Evoked Potential*) tienen la ventaja de tener una mayor precisión y una mayor Tasa de Transferencia de Información (ITR, por sus siglas en inglés *Information Transfer Rate*). Además requieren menor número de canales de EEG y menor tiempo de entrenamiento (Amiri *et al.*, 2013).

Los elementos principales para la selección las actividades sensomotoras para el diseño de sistemas BCI son el ITR y el tiempo de entrenamiento requerido. La Tabla 1.1 y la Figura 1.3 muestra una comparación general de los principales patrones de actividad cerebral del EEG: Desincronización/Sincronización de Eventos Relacionados (ERD/ERS, por sus siglas en inglés *Event Related Desynchronization/Synchronization*), SCP, P300 y SSVEP con respecto al tiempo de entrenamiento y a su ITR (Amiri *et al.*, 2013).

Señales Electrofisiológicas	Entrenamiento	ITR bits/min
ERD/ERS	SI	3-35
SCP	SI	5-12
P300	NO	20-25
SSVEP	NO	66-100

Tabla 1.1 Señales electrofisiológicas

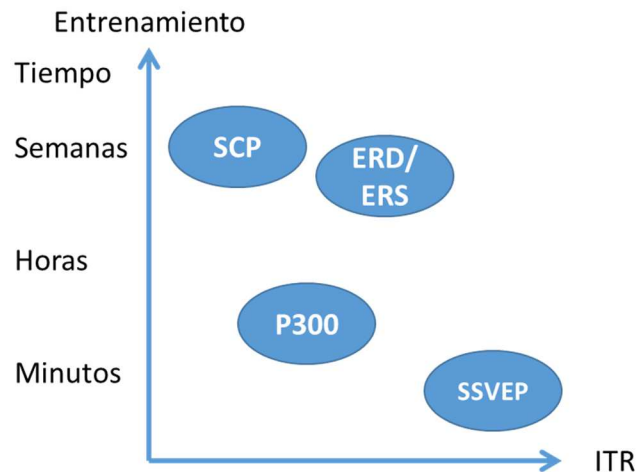


Figura 1.3 Patrones de actividad cerebral, (Amiri, 2013)

Los sistemas BCI ofrecen a sus usuarios nuevos canales de comunicación y de control sin ninguna intervención de los nervios periféricos y los músculos. Por lo tanto, muchas investigaciones se centran en la creación de aplicaciones BCI, con la esperanza de que esta tecnología pudiera ser útil para las personas con discapacidades motoras severas.

El campo de las aplicaciones BCI se ha desarrollado gracias a los avances significativos en el campo de la BCI basado en EEG. Las señales de EEG son utilizadas por la mayoría de las aplicaciones BCI, ya que ofrecen una calidad de señal aceptable que combina un bajo costo y accesibilidad de uso. El desarrollo de aplicaciones BCI, permitirá el acceso a aplicaciones tecnológicas a personas con discapacidad parcial o total o para proyectos de especializados con base a la demanda del mercado (Nicolas-Alonso y Gómez-Gil, 2012).

Las principales poblaciones objetivo para las aplicaciones BCI se dividen en tres clases. El primer grupo CLIS (por sus siglas en inglés *Complete Locked-In State*) incluye a personas que han perdido todo el control motor, que se encuentran en fase terminal de Esclerosis Lateral Amiotrófica (ALS) o sufren de parálisis cerebral severa. El segundo grupo LIS (por sus siglas en inglés *Locked-In State*) comprende a personas que están casi completamente paralizadas pero con el movimiento voluntario residual, como el movimiento de los ojos, parpadeo de los ojos o contracciones nerviosas con el labio. El tercer grupo de usuarios potenciales incluye personas con capacidades sanas y los que tienen el control neuromuscular, sobre todo de habla y/o control de la mano. Los sistemas BCI tienen poco que ofrecer al tercer grupo, ya que puede enviar la misma información mucho más rápida y fácilmente a través de otras interfaces (Nicolas-Alonso y Gómez-Gil, 2012).

A pesar de esto, los sistemas BCI se utilizan cada vez más por personas sanas en neuromercadeo (*neuromarketing*) y en los videojuegos como una herramienta para revelar la información afectiva de los usuarios, que no pueden ser reportados tan fácilmente a través de interfaces convencionales. Del mismo modo los sistemas BCI se pueden utilizar para algunas personas que sufren de trastornos neurológicos como la esquizofrenia o la depresión. El nivel de deterioro de la población objetivo potencial está relacionado con el rendimiento de un sistema BCI. Kübler y Birbaumer en el 2008 informaron de una fuerte correlación entre el deterioro físico y el rendimiento BCI. Personas con CLIS no pudieron controlar un sistema BCI (Kübler y Birbaumer, 2008).

La regulación cerebral de contribuciones voluntarias para la comunicación sólo es posible en pacientes LIS. Sin embargo, teniendo en cuenta sólo los pacientes LIS, esta relación entre deterioro físico y el rendimiento BCI desaparecieron (Nicolas-Alonso y Gómez-Gil, 2012). Figura 1.4 muestra una relación entre las capacidades de las poblaciones objetivo y las áreas de aplicación de los sistemas BCI, Eje horizontal: la tasa de transferencia de información podría estar en relación con el control de las aplicaciones. Eje Vertical: grado de discapacidad de las personas.

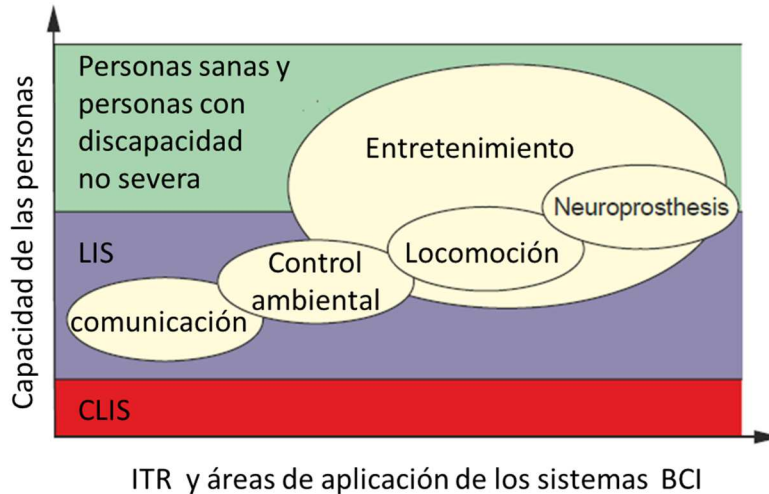


Figura 1.4 Áreas de aplicación de los sistemas BCI (Nicolas-Alonso y Gómez-Gil, 2012).

Independientemente del grupo de personas objetivos, el desarrollo de aplicaciones tiende a centrarse en aquellas que requieren menor tiempo en la interpretación de la intención de la persona y la ejecución del sistema de control (aplicaciones en tiempo real). Por ello se requieren sistemas BCI más rápidos, con una tasa de error menor y de un desempeño más eficiente.

1.5. Hipótesis

Es factible implementar algoritmos de optimización de inteligencia de enjambre para el procesamiento de señales de electroencefalograma basadas en neuro-mecanismos por eventos visuales para el diseño de interfaces cerebrales y mejorar el desempeño en las aplicaciones de sistemas de control.

1.6. Objetivo General

Proponer e implementar algoritmos de optimización de inteligencia de enjambre para el procesamiento de señales de electroencefalograma basadas en neuro-mecanismos por eventos visuales para el mejoramiento en el diseño de interfaces cerebrales.

1.7. Objetivo Particular

Establecer un marco de referencia de los algoritmos basados en inteligencia colectiva animal para la solución de problemas de optimización, principalmente en

la implementación de algoritmos de colonia de hormigas como elemento del post procesamiento de las señales EEG para el mejoramiento del desempeño de los sistemas BCI. Así mismo se desarrollarán: un protocolo de pruebas para la obtención de señales de EEG en seres humanos basado en el marco teórico de la ética en la investigación científica, un sistema de pruebas basadas en potenciales por evento para la obtención de señales EEG, generar un banco de señales para ser utilizados por otros investigadores, generar un mapa de la topología cerebral con relación su ubicación espacial en un EEG y los neuro-mecanismos basados en eventos.

2. MARCO TEÓRICO

2.1. Proceso eléctrico de las neuronas

El cerebro humano está formado por células especializadas llamadas neuronas. Las neuronas se componen de un cuerpo celular, un núcleo, las dendritas y un axón, como se muestra en la Figura 2.1 (De la Torre 2012).




Figura 2.1 Componentes de la neurona (De la Torre, 2012)

Las neuronas son células eléctricamente excitables, procesan y transmiten información vía señales químicas y eléctricas. Las señales eléctricas se generan por cambios en la carga eléctrica de la membrana de la neurona que cubre a toda la célula. Las neuronas tienen un potencial eléctrico en reposo, el cual es la diferencia de potencial entre el interior de la célula y el espacio extracelular. El potencial en reposo fluctúa como resultado de los impulsos que llegan de otras neuronas a través de las sinapsis. La sinapsis es una unión funcional intercelular especializada entre neuronas, donde se lleva a cabo la transmisión del impulso nervioso, el cual se inicia con una descarga química que origina una corriente eléctrica en la membrana de la célula (De la Escalera, 2010). La membrana de la célula contiene canales iónicos donde iones de Sodio (Na^+), Potasio (K^+), Cloruro (Cl^-) y Calcio (Ca^{2+}) se concentran durante los procesos químicos en la célula. La concentración de iones crea diferencias de potencial en la membrana. Los cambios en la tensión en la membrana generan potenciales post-sinápticos los cuales causan el flujo eléctrico a lo largo de la membrana y las dendritas (Escobar 2003; Lerma, 2010).

Cuando la diferencia de potencial es sumada en la zona de activación del axón alcanza el rango de los -43 mV, se dispara el axón mediante la generación de un potencial de acción en los $+30$ mV que va a lo largo del axón para liberar los transmisores en el final de la misma (Figura 2.2). Cuando la diferencia de potencial es sumada y está por debajo de éste umbral, el axón descansa (Kuzovkin, 2013; Lerma, 2010; Escobar 2003).




Figura 2.2 Generación de potenciales post-sinápticos (Kuzovkin, 2013).

A pesar del hecho de que la mayor parte de las corrientes eléctricas permanecen dentro de la corteza cerebral, una fracción pequeña penetra en el cuero cabelludo, lo que provoca que diferentes partes del cuero cabelludo tengan diferentes potenciales eléctricos. Estas diferencias, varían en amplitudes de $10-100$ μ V las cuales son detectadas por electrodos. Existen diferentes métodos para registrar la actividad cerebral con base en las condiciones del estado (vigilia, sueño, etc.):

- Electroencefalograma (EEG)
- Electrocardiografía (ECoG)
- Magneto encefalografía (MEG)
- Electromiografía (EMG)
- Espectroscopia de infrarrojo cercano (NIRS)
- Tomografía por emisión de positrones (PET)

- Imágenes de resonancia magnética funcional (fMRI).

La ECoG es una técnica invasiva, es decir, requiere de una intervención para la colocación de electrodos en la superficie cortical ($2.2 \Omega m$). Por su parte, las técnicas MEG, PET NIRS y fMRI requieren de instalaciones y equipos de mayor costo. La EMG se relaciona con la contracción de los músculos y patrones de onda única. EEG es una técnica sencilla, no invasiva, portátil y de bajo costo; por ello, el método más empleado para el registro de la actividad cerebral en las interfaces cerebrales. El presente trabajo se enfocará en el uso de la tecnología EEG.

2.2. Tecnología de Electroencefalograma

Existen diferentes tipos de neuronas: sensitivas, motoras e interneuronas, y hay alrededor de 20 tipos principales de picos que generan actividad eléctrica cerebral. La mayoría de estos picos son patrones periódicos. Este hecho hace que sea razonable descomponer las señales del EEG en un conjunto de frecuencias armónicas, las cuales se describirán más adelante.

Mediante la observación de las diferencias entre las señales eléctricas procedentes de los diferentes lugares en el cuero cabelludo, se puede monitorear la actividad eléctrica cerebral y ver qué partes del cerebro son eléctricamente activas durante diferentes tipos de actividades, y qué tan alto es el potencial eléctrico de la actividad.

El EEG lee potenciales post-sinápticos, que son relativamente continuos (un potencial persiste hasta 100 ms). Los potenciales de acción son muy breves (1 ms) y su aportación eléctrica es pequeña, por lo que no se puede realizar un seguimiento de estos en el EEG (Kuzovkin, 2013).

Por medio de varios electrodos colocados en partes estratégicas del cuero cabelludo, podemos leer las diferencias de potenciales que existen entre ellos. Por lo general, hay uno o varios electrodos de referencia, que se colocan en las zonas más estables de actividad eléctrica, como la nariz o los oídos. Dos electrodos en las zonas del cuero cabelludo con diferentes potenciales eléctricos producen una señal eléctrica (Figura 2.3).




Figura 2.3 señal eléctrica a partir de dos electrodos (Maarten De Vos, 2009)

2.3. Señales de Electroencefalograma

Una señal de EEG se compone de una serie de potenciales eléctricos (μV) que fluctúan a través del tiempo en diferentes canales. Cada canal representa un electrodo colocado en el cuero cabelludo. Cada equipo EEG tiene una cierta velocidad de muestreo a cuantificar, la cual indica el número de cambios por segundo que una señal de salida puede tener (Figura 2.4).

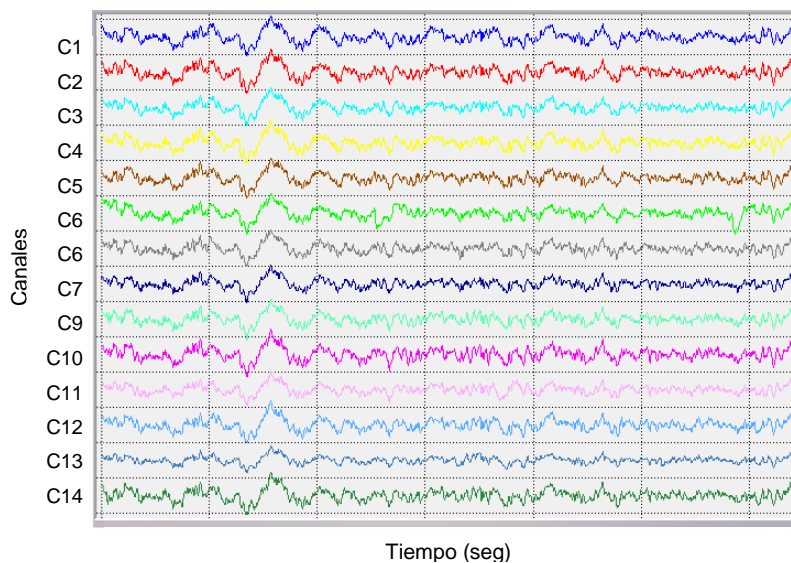


Figura 2.4 Conjunto de señales EEG

Las neuronas se disparan periódicamente y, dependiendo del tipo de actividad, la periodicidad del disparo cambia. Cuando la región del cerebro está implicada en un cierto tipo de actividad, todas las neuronas en esa región cambian con la misma periodicidad y esas fluctuaciones conjuntas se presentan en la señal (Kuzovkin, 2013). El criterio de normalidad es difícil de definir, debido a la variación entre

individuos, así como al estado de alerta y a la edad, ya que estas variables fisiológicas, tienen una relación muy estrecha con las características del EEG. La amplitud de las señales, se encuentran en el rango de 0 a 300 mV con un ancho de banda de 0.5 a 100 Hz. La mayor parte del tiempo, son asíncronas y no tiene un patrón. La aparición de patrones, se asocia con la existencia de patologías cerebrales o con ciertas ondas de funcionamiento normal.

2.4. Ritmos Cerebrales

De acuerdo a la frecuencia, las ondas cerebrales se clasifican en varios grupos llamados *ritmos cerebrales* (Figura 2.5 y Figura 2.6), las cuales corresponden a ciertas actividades en específicas (Tabla 2.1). La Figura 2.7 muestra la variación de la potencia de las señales con referente a las frecuencias de los ritmos cerebrales, las áreas verdes representan la actividad media, las zonas amarillo/naranja/rojo representan una actividad superior a la media, las áreas turquesa/azul representan una actividad inferior a la media (Kennerly, 2004).




Figura 2.5 Las 5 bandas de frecuencias principales y su relación entre sí.




Figura 2.6 Representación de las frecuencias de los ritmos cerebrales, (Sudhakaran, 2012)

Ritmo Cerebrales Beta (β): Queda definido entre los 13 Hz hasta los 30 Hz localizándose en las partes frontal y parietal del cerebro. Está asociado con un elevado nivel de concentración, atención y con la resolución de problemas. Se caracteriza por tener una distribución simétrica cuando no se está realizando ninguna actividad motora. Sin embargo, en el caso de realizar un movimiento se atenúa de manera que se rompe la distribución simétrica y esta acción de atenuación puede servir de base de estudio para este tipo de bio-señales (Martínez, 2014).

Ritmos Cerebrales Alfa (α): También llamadas Ondas de Berger, se encuentran en la región occipital del cerebro y su frecuencia varía entre los 8 y 13 Hz. La amplitud de estos ritmos se incrementa al cerrar los ojos o estar en un estado de relajación, y se atenúa al abrir los ojos o hacer un esfuerzo mental. La frecuencia de los ritmos alfa (α) puede ser inferior a 8 Hz en los niños jóvenes lo que puede hacer que se confundan con los ritmos theta (θ). Los ritmos alfa pueden ser útiles para determinar el grado de cansancio mental ya que están relacionados con el esfuerzo mental. Dentro del mismo rango de frecuencias que los ritmos alfa, se puede encontrar también los ritmos mu (μ). Aunque están localizados en el mismo rango de frecuencia existen importantes diferencias fisiológicas entre ellos. Al contrario que los ritmos alfa (α), los ritmos mu (μ) están muy relacionados con las actividades motrices (Martínez, 2014).

Ritmos Cerebrales Theta (θ): Se extiende de los 4 a los 8 Hz. Este rango de frecuencia se ha asociado con actividades como la meditación o la creación. Normalmente, los ritmos theta (θ) se observan solamente en niños jóvenes pero también es posible encontrarlos en niños más mayores o adultos en estado de somnolencia o meditación. Se generan tras la interacción entre los lóbulos temporal y frontal (Martínez, 2014).

Ritmos Cerebrales Delta (δ): Se sitúan entre los 0.5 y los 4 Hz y la amplitud de las señales que se encuentran en esta banda decrece con la edad. Los ritmos delta sólo pueden ser observados en adultos cuando se encuentran en estado de sueño profundo y son totalmente inusuales en estado de vigilia. Debido a su baja frecuencia, es fácil confundir este tipo de señales con artefactos producidos por el movimiento de los músculos del cuello o la mandíbula (Martínez, 2014).

Ritmos Cerebrales Gamma (γ): Pertenecen al rango de frecuencias entre los 30 y 100 Hz. La presencia de ritmos gamma en la actividad cerebral de un adulto sano está relacionada con ciertas funciones motoras o percepciones. Se ha demostrado científicamente una relación en los seres humanos entre las actividades motoras y las ondas gamma (γ) durante la contracción muscular, lo que sugiere que existe una correlación entre la actividad gamma o beta y la fuerza ejercida por los

músculos. De la misma forma hay evidencias sobre el papel de la actividad gamma en la percepción de estímulos, tanto visuales como auditivos. En el diseño de BCI basados en EEG, los ritmos gamma (γ) se usan con menos frecuencia ya que los artefactos como la EMG o electro-oculograma (EOG) afectan en mayor medida a este tipo de ritmos. No obstante, este rango de frecuencias está atrayendo una atención creciente porque, en comparación a las señales beta y alfa tradicionales, la actividad gamma (γ) podría aumentar la tasa de transferencia de información (Martínez, 2014).

Ritmos Cerebrales Mu (μ): Es un tipo de onda similar a la alfa (de 8-13Hz) que aparece sobre la corteza cerebral y que se atenúa con el movimiento e incluso con la sola intención de moverse (Martínez, 2014).

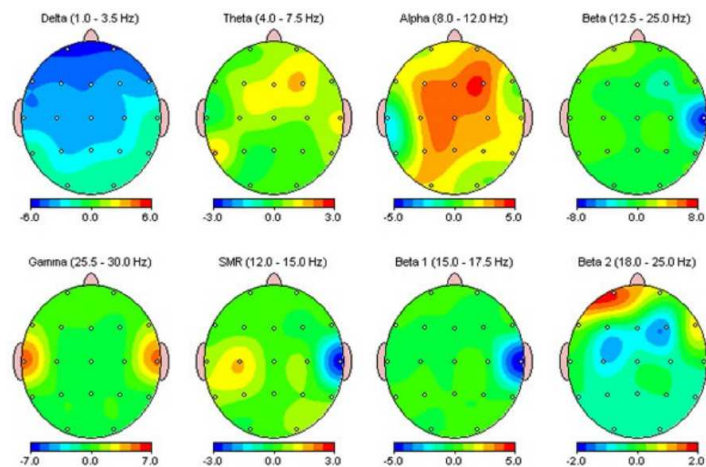


Figura 2.7 Intensidad de la de la señal con referente a las frecuencias de los ritmos cerebrales (Kennerly, 2004).

Nombre	Rango de frecuencia (Hz)	Estado	Tipo de Actividad
Delta (δ)	Hasta 4	Subconsciente	<ul style="list-style-type: none"> Onda lenta del sueño en adultos Actividad cerebral Bebés Tareas de atención continua
Theta (θ)	4-8	Subconsciente	<ul style="list-style-type: none"> La actividad cerebral de los niños pequeños Somnolencia o excitación marcha en vacío Reprimir una respuesta o acción
Alfa (α)	8-13	Subconsciente	<ul style="list-style-type: none"> Relajación al despertar Los ojos están cerrados Inhibición de la áreas de la corteza que no están en uso, desempeña un papel activo en la coordinación de la red y de la comunicación
Mu (μ)	8-13	Consciente	<ul style="list-style-type: none"> Aparece en las neuronas en reposo responsables de la actividad motora
Beta (β)	13-30	Consciente	<ul style="list-style-type: none"> Estado de alerta Activo, el pensamiento ansioso, concentración Trabajar
Gamma (γ)	30-100+	Consciente	<ul style="list-style-type: none"> Procesamiento sensorial Cross-modal (percepción que combina dos sentidos diferentes, como el sonido y la vista) Aparece durante la memoria a corto plazo, reconocimiento de objetos, sonidos o sensaciones táctiles Estado de stress y confusión

Tabla 2.1 Rangos de frecuencia básicos y tipos de actividades correspondientes

2.5. Sistema Internacional 10-20

Para poder captar todas las señales cerebrales se utiliza una maya de electrodos basada en el Sistema Internacional de Sociedades de Electroencefalografía 10-20; sistema definido para la colocación de electrodos sobre el cuero cabelludo, denominado así porque los electrodos están espaciados entre el 10% y el 20% de la distancia total entre puntos reconocibles del cerebro Figura 2.8 (Schalk y Mellinger, 2010).




Figura 2.8 (a) Identificación de las partes del cerebro. (b) Ubicación de electrodos en el Sistema Internacional de Sociedades de Electroencefalografía 10-20 (Olivas, 2010)

Las marcas de referencia son A1 (nación) A2 (inión) el resto de los electrodos se identifican por una letra que indica la zona sobre la cual se obtiene la actividad eléctrica: “F” (lóbulo frontal), “P” (lóbulo parietal), “T” (lóbulo temporal) “O” (lóbulo occipital), “C” (lóbulo central), “Fp” (polo frontal). El número se utiliza para identificar el hemisferio cerebral, los electrodos ubicados en el lado izquierdo se denotan con números impares y los del lado derecho con números pares (Figura 2.8b y Figura 2.9). El sufijo “Z” indica la línea central del cerebro. La Figura 2.10 muestra la relación entre las diferentes zonas del cerebro y los ritmos cerebrales (Schalk y Mellinger, 2010).

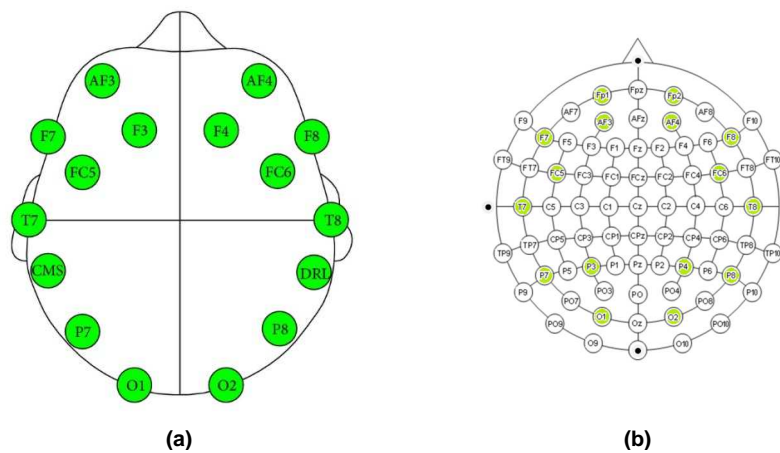


Figura 2.9 Identificación de electrodos. (a) EEG Emotiv EPOC+ (b) EEG Emotiv EPOC+ con el Sistema Internacional 10-20.




Figura 2.10 Relación de regiones y ritmos cerebrales

2.6. Topología Cerebral

Los estados cerebrales son el resultado de diferentes patrones de interacción neural. Estos patrones conducen a las ondas que se caracterizan por diferentes amplitudes y frecuencias. El cerebro humano presenta actividad eléctrica debido a dos causas. La primera es interna, esto es, debido a su funcionamiento involuntario como el control de la respiración, digestión etc. y por voluntad del individuo, al mover su cuerpo, hablar o pensar, etc. La segunda causa de la actividad cerebral es la aparición de estímulos externos, a través de algún sentido corporal; solo estos últimos son parte del desarrollo del presente trabajo.

Haider *et al.* (2010) clasifican a los sistemas BCI de acuerdo a su implementación en:

- Sistemas Invasivos: Es decir, son implantados directamente en el cerebro y su principal aplicación es en el área de prótesis para devolver el movimiento a alguna extremidad.
- Sistemas No Invasivos: La adquisición de las señales se realiza empleando electrodos, colocados en la superficie del cuero cabelludo.

La Figura 2.11a representa la implementación de electrodos directamente en el cerebro (sistema invasivo), la Figura 2.11b muestra una gorra para EEG basada en el Sistema Internacional 10-20 (no invasivo). El presente trabajo se centrará en los sistemas no invasivos.




Figura 2.11 (a) Sistema Invasivo, (Schalk, 2011). (b) Sistema No Invasivo, (MedicalExpo, 2015)

Cervantes (2008) clasifica a los sistemas BCI de acuerdo a la adquisición de las señales en:

- Sistemas BCI Endógenos: o sistemas basados en ritmos cerebrales, dependen de la capacidad del usuario para controlar su actividad electrofisiológica, como puede ser la amplitud del EEG en una banda de frecuencia específica sobre un área concreta de la corteza cerebral. Podemos clasificar a los sistemas endógenos en sistemas BCI basados en imágenes motoras (ritmos sensoriomotores) o en sistemas BCI basados en potenciales corticales lentos (SCP, por sus siglas en inglés *Slow Cortical Potentials*). Los sistemas endógenos requieren de un período de entrenamiento intensivo.

Un BCI basado en imágenes motoras o ritmos sensor-motores. Se basa en un paradigma de dos o más clases de imágenes motoras (MI, por sus siglas en inglés *Motors Imaginary*), movimiento de la mano derecha o izquierda, de los pies, de la lengua, etc. u otras tareas cerebrales como rotación de un cubo, realización de cálculos aritméticos, etc. Este tipo de tareas mentales producen cambios en la amplitud de los ritmos sensoriomotores μ y β , registrados sobre la zona somato sensorial y motora de la corteza cerebral (Figura 2.10). Estos ritmos presentan variaciones tanto para la ejecución de un movimiento real como para la imaginación de un movimiento o la preparación al mismo. Un BCI basado en SCP implica cambios lentos de voltaje generados sobre la corteza cerebral, con una duración variable entre 0.5 s y 10 s. Se asocian típicamente con el movimiento y otras funciones que implican una activación cortical. Se ha demostrado que las personas pueden aprender a controlar estos potenciales.

- Sistemas BCI Exógenos: Son sistemas basados en potenciales relacionados con eventos (ERP, por sus siglas en inglés *Evoked Related Potentials*) dependen de la actividad electrofisiológica evocada por estímulos externos y no necesitan de una etapa intensiva de entrenamiento. Podemos clasificar a los sistemas BCI exógenos en sistemas basados en potenciales por eventos P300, basados en potenciales por eventos visuales (VEP, por sus siglas en inglés *Visual Evoked Potentials*), basado en potenciales por eventos visuales de estado estacionario

(SSVEP, por sus siglas en inglés *Steady-State Evoked Potentials*) o sistemas basados en potenciales por eventos auditivos (AEP, por sus siglas en inglés *Auditive Evoked Potentials*).

Los sistemas BCI basado en P300 habitualmente, se presentan a la persona un conjunto de estímulos de los que solo unos pocos tienen relación con la intención de la persona. De esta forma, los estímulos de interés, al ser no frecuentes y estar mezclados con otros estímulos mucho más comunes, provocan la aparición de un potencial P300 en la actividad cerebral de la persona. Dicho potencial se observa principalmente en las zonas central y parietal de la corteza cerebral (Figura 2.10).

Los sistemas BCI basados en VEP y SSVEP se detectan en el EEG registrado sobre la zona visual de la corteza cerebral tras haberse aplicado un estímulo visual al usuario. Estos potenciales se hacen estables si la tasa de presentación del estímulo visual está por encima de 6 Hz. Cuando la persona enfoca su mirada en una imagen que parpadea a una frecuencia determinada, es posible detectar dicha frecuencia analizando el espectro de la señal EEG, ya que aumenta la amplitud del SSVEP en la frecuencia de la imagen parpadeante y en su segundo y tercer armónico.

Los sistemas BCI basados en AEP se detectan en el EEG registrado sobre la zona auditiva de la corteza cerebral presentando al usuario fuentes de sonidos a diferentes frecuencias, el usuario al concentrarse en alguno de ellos, genera un potencial de la misma frecuencia que el estímulo. El presente trabajo se enfoca en los sistemas SSVEP.

La actividad cerebral está relacionada con algunos procesos por parte del usuario, dichos procesos están relacionados con los diferentes ritmos cerebrales en las diferentes áreas del cerebro (Tabla 2.1). La Figura 2.12 muestra la relación de estos procesos con su ubicación en la corteza cerebral y su relación con el sistema internacional 10-20; esta topología es propuesta por Walker (2007). La Tabla 2.2

2.7. Modelo BCI

Las funciones básicas de los sistemas BCI consisten en medir la actividad cerebral, procesarla para obtener características de interés, y, una vez obtenidas interactuar con el entorno de la forma deseada por el usuario. Modularmente lo podemos representar en: módulo de adquisición de las señales de la actividad cerebral; módulo de procesamiento de las señales el cual se encarga de recolectar la señal resultante, de medir la actividad cerebral y aplicar filtros (análisis de señales) para decodificar el proceso neurofisiológico que refleja la intención del usuario; y por último la aplicación, módulo encargado de materializar la interacción del usuario con el entorno (Figura 2.13).

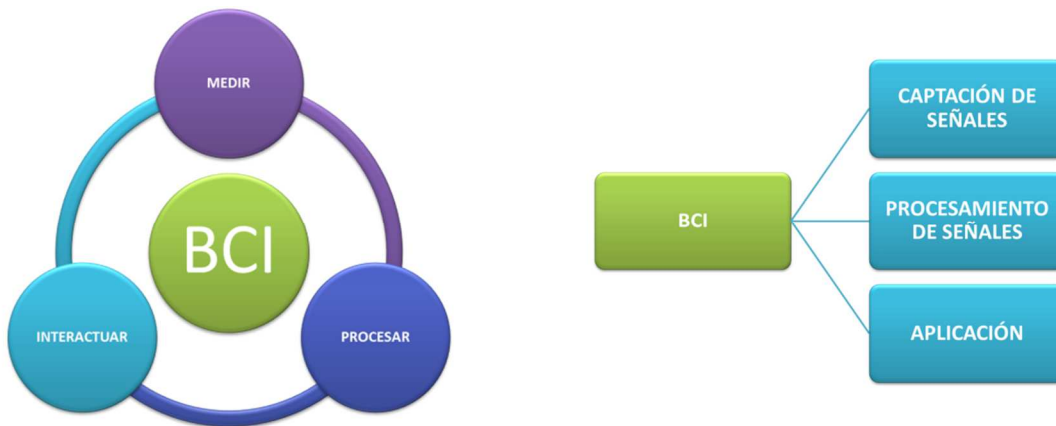


Figura 2.13 Diagrama de bloques de los sistemas BCI

Los sistemas BCI, deben cumplir con cuatro criterios (Pfurtscheller *et al.*, 2010):

1. Directo: El sistema debe basarse en la actividad registrada directamente del cerebro.
2. El control intencional: Al menos una señal del cerebro grabable, que puede ser intencional modulada, debe proporcionar la entrada al BCI (potenciales eléctricos, campos magnéticos o cambios hemodinámicos).
3. Procesamiento en tiempo real: El procesamiento de la señal debe ocurrir en línea y obtener una comunicación o señal de control.
4. Retroalimentación: la persona debe obtener información sobre el éxito o el fracaso de su(s) esfuerzos de comunicación o control.

El procesamiento de señales es una parte importante del diseño de una BCI, ya que se necesita en la extracción de la información significativa de la señal del cerebro. Un factor esencial para el éxito del funcionamiento de los sistemas BCI son los métodos utilizados para procesar las señales del cerebro. Analizar una señal consiste en aplicar un algoritmo que extrae información en forma de parámetros, que resultan útiles para describirla, o conocer algún aspecto de ella. Mason y Birch (2003) propusieron un modelo funcional de un sistema BCI basado en ERP (Figura 2.14, Tabla 2.3).

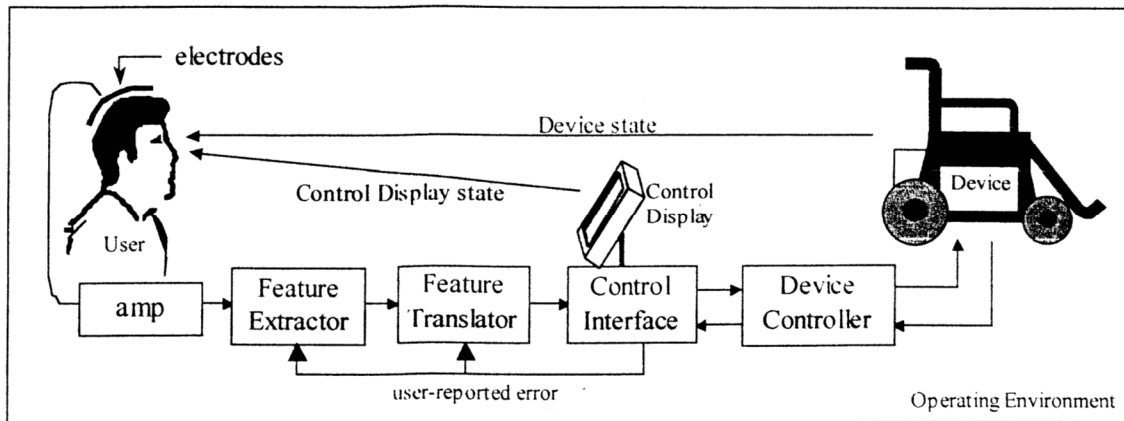


Figura 2.14 Modelo funcional de los Sistemas BCI propuesto por Mason y Birch (2003).

COMPONENTE	DESCRIPCIÓN FUNCIONAL
Usuario (User)	Es la persona que controla el dispositivo en el sistema BCI
Electrodos (Electrodes)	Concierten los estados cerebrales del usuario en señales eléctricas
Amp	Funciona como amplificador y filtro pase-banda para las señales eléctricas provenientes del cerebro del usuario
Extracción de características (Feature Generator)	Transforma las señales amplificadas en características de valor que corresponden al subyacente mecanismo neurológico seleccionado para el control por parte del usuario
Traducción de características (Feature Translator)	Convierte la características en un vector en control de señales lógicas
Control Interface	Traduce las señales de control en señales de control simétricas que son apropiadas para un dispositivo en particular
Dispositivo de control (Device Controller)	Dispositivo de control

Tabla 2.3 Definición funcional de un Sistema BCI de Mason y Birch

Bashashati *et al.* (2007) realizan un estudio donde se complementan las etapas Generador de Características y Traductor de Características, propuestas por Mason y Birch (2003).

El procesamiento de señales es la parte más importante en el desarrollo de los sistemas BCI. Se han desarrollado diferentes metodologías y/o técnicas con base a las etapas funcionales del modelo propuesto por Bashashati *et al.* (2007)

Por ejemplo, algunas técnicas para la etapa pre-procesamiento son: SL (Surface Laplacian), ICA (Independent Component Analysis), Filtro de Kalman, CAR (Common Average Referencing), CSP (Common Spatial Patterns).

Para la etapa de extracción de características se han desarrollado las metodologías de CCA (Cross-Correlation Analysis), TRF (Time–frequency representation), SDA (Stepwise Discriminant analysis), Linear Discriminant Analysis (LDA), para señales P300, y SP (Spectral Parameters) y CCA para SSVEP. Así mismo, máquina de soporte de vectores (Support Vector Machine), algunas Redes Neuronales, Nearest Neighbor classifiers, k Nearest Neighbors. (Bashashati *et al.*, 2007; Lotte *et al.*, 2007).

En la etapa de selección/reducción de dimensionalidad GA se pueden mencionar como técnicas las siguientes: (Genetic Algorithm), PCA (Principal Component Analysis), ICA (Independent Component Analysis), DSLVQ (Distinctive Sensitive Learning Vector Quantization), SVM (Support Vector Machine), SDA (Stepwise Discriminant Analysis) (Nicolas-Alonso y Gómez-Gil, 2012)

Por otro lado, para la etapa de clasificación de características de las señales de BCI se pueden enumerar: Metodologías basadas en Redes Neuronales, lógica difusa, Variaciones del filtro de Kalman, regresiones lineales, no lineales y cuadráticas para la etapa de clasificación de características. (Lotte *et al.*, 2007).

Finalmente para la etapa de post-procesamiento los métodos ERN (Event-Related Negativity) NEC (Nased Error Correction), SA-UK (Successive averaging unknown

output state), HGA (Hybrid-Binary Genetic Algorithm) (Bashashati *et al.*, 2007; Alwasiti *et al.*, 2010; Mason y Birch 2003).

2.8. Problemas de optimización

Una de las aplicaciones más comunes de la inteligencia artificial es la búsqueda de la solución óptima en problemas de alta complejidad, tanto en espacios continuos como discretos (Muñoz *et al.*, 2008). Los problemas de optimización son de gran importancia tanto para el mundo industrial, así como para el mundo científico. Ejemplos de problemas de optimización prácticas incluyen la programación de trenes, horarios, optimización de la forma, el diseño de redes de telecomunicaciones, y los problemas de la biología computacional (Merkle y Blum, 2008). Un algoritmo de optimización es un método numérico que encuentra un valor $\theta_i \in R^n$, donde R^n es un espacio n -dimensional de búsqueda, que minimiza o maximiza una función $J(\theta)$, por medio de la selección sistemática de valores de la variable θ_i posiblemente con algunas restricciones. La variable θ_i puede ser un escalar o un vector de valores discretos o continuos llamados funciones factibles, mientras que $J(\theta)$ es llamada *función objetivo*. Una solución factible que minimiza o maximiza la función objetivo es llamada una *solución óptima*. Un tipo de problemas de optimización son aquellos que requieren combinaciones de valores, y se le denomina de optimización combinatoria (Muñoz *et al.*, 2008).

En general, cualquier problema de optimización P puede ser descrito como una tupla $P = (S, \Omega, f)$, donde:

S es el espacio de búsqueda definida sobre un conjunto finito de variables de decisión discretas, un conjunto Ω de restricciones entre las variables y una función objetivo $f: S \rightarrow R^+$ que asigna un valor positivo del costo de cada elemento (o solución) de S . El espacio de búsqueda S está definido como sigue: Dado un conjunto discreto de variables $X_i, i = 1, \dots, n$ con valores $v_i^j \in D_i = \{v_i^1, \dots, v_i^{|D_i|}\}$, $i = 1, \dots, n$. La asignación de un valor V_i^j a una variable X_i es dado por $X_i \leftarrow V_i^j$. En el caso en que estas variables tengan dominios discretos hablaremos de,

optimización discreta, y en el caso de los dominios continuos P se llama un problema de *optimización continua* (Socha y Dorigo, 2008).

El objetivo es encontrar una solución $s \in S$, que satisfaga todas las restricciones del conjunto Ω , tal que $f(s) \leq f(s')$, $\forall s' \in S$ (en caso de querer minimizar la función objetivo), o $f(s) \geq f(s')$, $\forall s' \in S$ (en caso de que la función objetivo debe ser maximizada). En los problemas de la vida real el objetivo es comúnmente optimizar varias funciones objetivo al mismo tiempo. Esta forma de optimización se etiqueta *optimización multi-objetivo* (Dorigo y Blum 2005; Blum y Li, 2005).

Los problemas de optimización surgen en multitud de situaciones diferentes, que pueden ir desde el cálculo de rutas de una flota de transporte o la planificación de los horarios de vuelo del personal aéreo hasta el diseño de programas de computadora o la programación de inteligencia artificial (Bretón y Fernández, 2000). Presentamos algunos ejemplos de problemas de optimización a los cuales se les han implementado diferentes tipos de algoritmos para su solución. Estos algoritmos proponen encontrar para cada instancia de un problema de optimización de tamaño finito una solución óptima en un tiempo acotado.

2.9. Metaheurística

El término *metaheurística* fue introducido por Glover (1986), y deriva de la composición de dos palabras griegas. El sufijo “*meta*” significa “más allá de, en un nivel superior”, y “*heurística*” deriva del verbo *heuriskein* ($\epsilon\upsilon\ \rho\iota\sigma\kappa\epsilon\iota\nu$) que significa “encontrar, descubrir”. Existen muchas definiciones de metaheurística, para este trabajo se adopta la formulada por I.H. Osman *et al* (1996) “*Una metaheurística se define formalmente como un proceso de generación iterativo el cual guía a una heurística subordinada combinando inteligentemente diferentes conceptos para explorar y explotar el espacio de búsqueda, son utilizadas estrategias de aprendizaje para estructurar la información con el objetivo de encontrar eficientemente soluciones casi óptimas*”.

Se puede decir que las metaheurística son estrategias de alto nivel para explorar espacios de búsqueda usando diferentes métodos. Además es de gran importancia

que exista un balance dinámico entre diversificación e intensificación. El término diversificación generalmente se refiere a la exploración del espacio de búsqueda (promover al proceso de búsqueda a examinar regiones no visitadas del espacio de búsqueda, para generar soluciones que difieran de manera significativa de las soluciones ya vistas), mientras que el término intensificación se refiere a la explotación de la experiencia de búsqueda acumulada (enfocar la búsqueda en examinar soluciones que pertenezcan a la vecindad de las mejores soluciones encontradas) (Arito, 2010, Gendreau y Potvin, 2010; Voß *et al.*, 2012).

Las metaheurísticas incorporan conceptos de muchos y diversos campos como la genética, la biología, la inteligencia artificial, las matemáticas, la física y la neurología, entre otras (Arito, 2010). Algunos ejemplos de metaheurísticas son: Algoritmos Evolutivos (Holland 1975; Bäck, 1996, 1997; Harikumar 2004; Ocaik, 2008, González 2010), Simulated Annealing (Kirkpatrick, 1983; Corono 1987; Selim; 1991; Jeon, 2002; Bouleimen, 2003), Búsqueda Tabú (Osman, 1993; Glover y Laguna, 1997; da Conceicao Cunha, 2004; Saidi-Mehrabad, 2007), Búsqueda Local Iterativa (Stützle, 1999; Den Besten, 2001; Lourenço, 2002; Lourenço *et al.*, 2010), Inteligencia de Enjambre (Bonabeau *et al.* 1999; Engelbrecht, 2006; Dorigo *et al.*, 2008; Karaboga y Akay 2009; Derrac *et al.*, 2011; Panigrahi, 2011; Chang y Huang, 2012), entre otras.

2.10. Computación Evolutiva

Según Hertz y Kobler (2000), las técnicas utilizadas para resolver problemas complejos de optimización combinatoria han evolucionado progresivamente de métodos constructivos a métodos de búsqueda local y finalmente a algoritmos basados en poblaciones (Muñoz *et al.*, 2008). Estos últimos proveen buenas soluciones al utilizar un método constructivo para la obtención de la población inicial, y una técnica de búsqueda local para mejorar la solución de la población. A estos métodos se les conocen como *algoritmos de computación evolutiva* (EC, por sus siglas en inglés *Evolutionary Computation*) (Muñoz *et al.*, 2008).

Los algoritmos de EC comprenden un conjunto de técnicas iterativas que manejan una población de individuos que son evolucionados (modificados) mediante una

serie de reglas que han sido claramente especificadas. En cada iteración hay periodos de auto adaptación, los cuales implican cambios en el individuo; son alternados con periodos de cooperación, lo que implica el intercambio de información entre individuos. EC representa un amplio grupo de técnicas, básicamente dividida en dos ramas: los algoritmos evolutivos (EA, por sus siglas en inglés *Evolutionary Algorithms*) y la inteligencia de enjambres (SI, por sus siglas en inglés *Swarm Intelligence*).

Los EA corresponden a un grupo de técnicas estocásticas que utilizan los conceptos de evolución biológica. Actúan sobre una población de soluciones potenciales aplicando los principios de diversidad de individuos y supervivencia del más fuerte para producir mejores aproximaciones a una solución. SI corresponde a un grupo de técnicas que están basadas en el estudio del comportamiento colectivo en sistemas auto organizados y descentralizados (distribuidos). Estos sistemas están conformados típicamente por una población de agentes computacionales simples capaces de percibir y modificar su ambiente de manera local. Tal capacidad hace posible la comunicación entre los individuos, que detectan los cambios en el ambiente generado por el comportamiento de sus semejantes. Aunque normalmente no hay una estructura centralizada de control que dictamina cómo los agentes deben comportarse, las interacciones locales entre los agentes usualmente llevan a la emergencia de un comportamiento global (Muñoz *et al.*, 2008). La Figura 2.15 muestra la taxonomía de EC basada en Muñoz *et al.*, (2008) y Ab Wahab *et al.*, (2015).

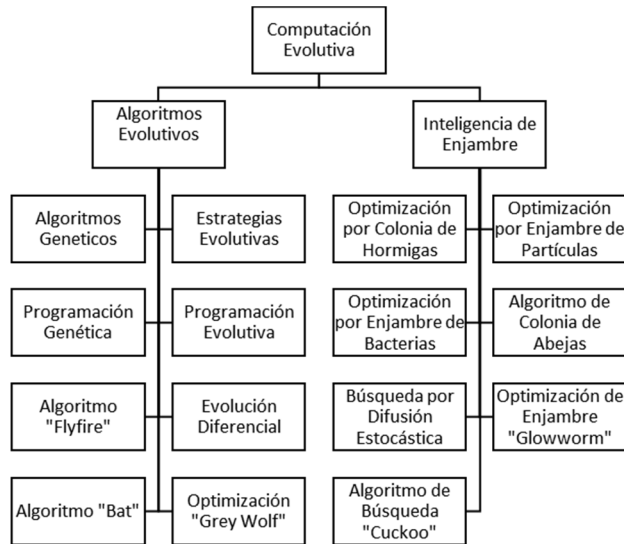


Figura 2.15 Taxonomía de la Computación Evolutiva

2.11. Inteligencia de enjambre

La Inteligencia de enjambre (SI) es un comportamiento colectivo de los sistemas descentralizados, autónomos organizados naturales o artificiales (Beni y Wang, 1989). Sin embargo el término enjambre se utiliza de manera general para referirse cualquier colección restringida de agentes o personas que interactúan entre sí. (Mishra *et al.*, 2013).

La SI permite resolver problemas a través de múltiples interacciones de simples unidades de procesamiento de información. El concepto de un enjambre sugiere multiplicidad, estocasticidad, aleatoriedad y desorden, y el concepto de inteligencia sugiere que el método de resolución de problemas es de alguna manera exitosa.

Las unidades de procesamiento de información que componen un enjambre pueden ser insectos, aves o seres humanos; pueden ser elementos de una matriz, robots, o estaciones de trabajo independientes. Su acoplamiento puede tener una amplia gama de características, pero debe haber interacción entre las unidades (Zomaya, 2006).

Los algoritmos basados en enjambres han surgido recientemente como una familia de algoritmos basados en poblaciones de la naturaleza, son capaces de producir, a bajo costo y rápido soluciones robustas a varios problemas complejos y de optimización (Panigrahi, 2011; Blum y Merkle, 2008).

2.11.1. Fundamentos

Los agentes individuales de un enjambre se comportan sin supervisión y cada uno de estos agentes tiene un comportamiento estocástico debido a su percepción del entorno. Las normas locales, sin ninguna relación con el patrón global, y las interacciones entre los agentes auto-organizados conducen a la aparición de la inteligencia colectiva SI. La SI trabaja en dos principios básicos: la *auto-organización* y el *stigmergy* (Mishra *et al.*, 2013).

Bonabeau *et al.* en 1999 define la *auto-organización* en el SI como "un conjunto de mecanismos dinámicos mediante el cual las estructuras aparecen en el nivel global de un sistema de interacciones de sus componentes de nivel inferior". Un sistema auto-organizado se puede caracterizar por tres parámetros:

- La estructura emergiendo de un estado inicial homogéneo, por ejemplo, forraje, senderos, arquitectura de nido.
- La multi-estabilidad en la coexistencia de muchos estados estables, por ejemplo, hormigas hazañas sólo uno de dos fuentes de alimentación idénticas.
- Las transiciones de estado como un cambio espectacular del comportamiento del sistema, por ejemplo, las termitas pasar de un no coordinado a una fase coordinado sólo si su densidad es superior al valor del umbral.

Las reglas que especifican las interacciones entre las unidades constituyentes del sistema se ejecutarán sobre la base de la información puramente local, sin hacer referencia a la tendencia global, que es una propiedad emergente del sistema en lugar de una propiedad impuesta al sistema por una influencia externa pedido.

Bonabeau *et al.* (1999) interpretaron la auto-organización en enjambres a través de cuatro características:

- Retroalimentación positiva.- el propio comportamiento promueve la creación de estructuras convenientes.
- Retroalimentación negativa.- contrapesa la retroalimentación positiva y ayuda a estabilizar el patrón colectivo.
- Fluctuaciones.- como paseos aleatorios, errores, cambiar de tarea al azar entre los individuos del enjambre son vitales para la creatividad y la innovación. La aleatoriedad es a menudo crucial para estructuras emergentes, ya que permite el descubrimiento de nuevas soluciones.
- Múltiples interacciones.- ya que los agentes en el enjambre utilizan la información proveniente de los otros agentes de manera que la información y los datos se extienden a toda la red.

Los insectos sociales alcanzan la auto-organización por medio de la comunicación o interacción social, mencionada anteriormente. La comunicación directa: a través contacto visual, “*antennation*” (contacto químico), “*trophallaxis*” (comida o intercambio líquido), etc. La comunicación indirecta: dos individuos interactúan indirectamente cuando uno de ellos modifica el medio ambiente y el otro responde al nuevo entorno en un momento posterior, a lo cual se le denomina “*Stigmergy*” (Mishra A.K. *et al.*, 2013).

El término “*stigmergy*” fue introducido por Pierre-Paul Grassé a finales de 1950. *Stigmergy* se asocia con dos palabras “*estigma*” y “*ergon*” (estigma (sting) + ergon (work) = "estimulación por el trabajo"). *Stigmergy* se basa en el principio de que, un entorno sirve como una memoria de estado de trabajo donde el trabajo no depende de agentes específicos. Por lo tanto, la coordinación de las tareas y la regulación de las construcciones no dependen directamente de los trabajadores, sino del propio entorno. El trabajador no dirige su trabajo, pero se guía por el entorno (Figura 2.16) *stigmergy* tiene las siguientes características:

- El trabajo como agente de modificación de la interacción indirecta del medio ambiente.
- Trabajar en la modificación del medio ambiente sirve como memoria externa.
- El trabajo puede ser continuado por cualquier individuo.

- Las mismas reglas simples de comportamiento pueden crear diferentes entornos en función del estado del medio ambiente.

En pocas palabras, stigmergy significa comunicación a través de signos o señales colocadas en el medio ambiente por una entidad, que afectan el comportamiento de otras entidades que se encuentran con ellos.



Figura 2.16 Representación de stigmergy y auto-organización por una colonia de hormigas, (Lewis, 2015).

Para considerar que un enjambre tiene un comportamiento inteligente, (Millonas, 1994) define cinco principios que se deben cumplir:

1. El principio de proximidad: El enjambre debe ser capaz de hacer simples cálculos de espacio y tiempo.
2. El principio de calidad: El enjambre debe ser capaz de responder a factores de calidad en el entorno tales como la calidad de los productos alimenticios o la seguridad de ubicación.
3. El principio de respuesta diversa: El enjambre no debe destinar todos sus recursos a lo largo de los canales excesivamente estrechos y debe distribuir los recursos en muchos nodos.
4. El principio de estabilidad: El enjambre no debe cambiar su modo de comportamiento sobre cada fluctuación del medio ambiente.
5. El principio de adaptabilidad: El enjambre debe ser capaz de cambiar el modo de comportamiento cuando el costo de la energía es superior al costo computacional. (Kennedy *et al.*, 2001).

La Tabla 2.4 muestra algunos algoritmos de SI basados en diferentes elementos de la naturaleza.

No.	Nombre del Algoritmo	Año de desarrollo	Autor(es)	Técnica
1	Ant colony optimization (ACO)	1992	Marco Dorigo	Hormigas
2	Particle Swarm Optimization (PSO)	1995	Kennedy & Eberhart	Enjambres
3	Artificial Immune System	2002	De Castro y Von Zuben's; Nicosia y Cutello's	Estructura y función del sistema inmune
4	Artificial Bee Colony (ABC)	2005	Karaboga	Abejas de miel
5	Altruism	2006	Foster KR, Wenseleers T, Ratnieks LW	Reglas de Hamilton
6	River formation Dynamics (RFD)	2007	Gradient version of ACO	En base a la forma en la que el agua forma los ríos por la erosión de la tierra y el depósito de sedimentos.
7	Firefly Algorithm (FA)	2008	Yang Xin-she	Comportamiento de parpadeo de las luciérnagas.
8	Cuckoo Search (CS)	2009	Yang Xin-she y Deb Suash	Imita el comportamiento de crianza de algunas especies de lechuzas
9	Gravitational Search Algorithm (GSA)	2009	Rashedi, Nezamabadi-pour y Saryazdi	Con base a la ley de la gravedad y la noción de interacción masiva
10	Intelligent Water Drops (IWD)	2009	Shah-Hosseini Hamed	Inspirado por los ríos naturales y cómo encuentran caminos casi óptimos a su destino.
11	Charged System Search (CSS)	2010	Kaveh A. y Talatahari S.	Principios de física y mecánica

Tabla 2.4 Algoritmos basados en insectos y sus técnicas de desarrollo.

3. METODOLOGÍA

3.1. Protocolo de pruebas

Toda investigación en seres humanos debiera realizarse de acuerdo con tres principios éticos básicos: respeto por las personas, beneficencia y justicia (Council for International Organizations of Medical Sciences, 2002).

El respeto por las personas incluye, a lo menos, dos consideraciones éticas fundamentales: Respeto por la autonomía, que implica que las personas capaces de deliberar sobre sus decisiones sean tratadas con respeto por su capacidad de autodeterminación; y la protección de las personas con autonomía disminuida o deteriorada, que implica que se debe proporcionar seguridad contra daño o abuso a todas las personas dependientes o vulnerables.

La beneficencia se refiere a la obligación ética de maximizar el beneficio y minimizar el daño. Este principio da lugar a pautas que establecen que los riesgos de la investigación sean razonables a la luz de los beneficios esperados, que el diseño de la investigación sea válido y que los investigadores sean competentes para conducir la investigación y para proteger el bienestar de los sujetos de investigación. Además, la beneficencia prohíbe causar daño deliberado a las personas; este aspecto de la beneficencia a veces se expresa como un principio separado, no maleficencia (no causar daño).

La justicia se refiere a la obligación ética de tratar a cada persona de acuerdo con lo que se considera moralmente correcto y apropiado, dar a cada uno lo debido. En la ética de la investigación en seres humanos el principio se refiere, especialmente, a la justicia distributiva, que establece la distribución equitativa de cargas y beneficios al participar en investigación. Diferencias en la distribución de cargas y beneficios se justifican sólo si se basan en distinciones moralmente relevantes entre las personas; una de estas distinciones es la vulnerabilidad. El término "vulnerabilidad" alude a una incapacidad sustancial para proteger intereses propios, debido a impedimentos como falta de capacidad para dar consentimiento informado, falta de medios alternativos para conseguir atención médica u otras necesidades de alto costo, o ser un miembro subordinado de un grupo jerárquico. Por tanto, se

debiera hacer especial referencia a la protección de los derechos y bienestar de las personas vulnerables (Council for International Organizations of Medical Sciences, 2002).

A través de la historia se han desarrollado varios códigos y pautas internacionales para la protección de los seres humanos en el desarrollo de la investigación científica: Código de Núremberg, 1947; Declaración de Helsinki, 1964; Consejo de Organizaciones Internacionales de las Ciencias Médicas, 1993; Buenas Prácticas Clínicas, 2001; Buenas Prácticas Clínicas, versión 2005 (Arellano *et al.*, 2014). En México la responsabilidad gubernamental se deriva del derecho constitucional a la protección de la salud. Este derecho se establece específicamente con respecto a la investigación biomédica en la Ley General de Salud, Título Quinto, “Investigaciones para la Salud,” y se complementa con el Reglamento de la Ley General de Salud en Materia de Investigación para la Salud de la Secretaría de Salud. Tanto la Ley General de Salud como el Reglamento de la Ley General de Salud en Materia de Investigación para la Salud establecen, la regulación y la supervisión de la investigación biomédica, bajo el control de comisiones de investigación, ética, y de bioseguridad (Arellano *et al.*, 2014).

En el Apéndice “B” se anexa el “*Protocolo de Adquisición de Datos por Medio de Electroencefalograma para la Generación de Información que Permita el Desarrollo de Interfaces Cerebrales*”, la guía de preparación de pruebas de señales de EEG así como la base de datos obtenida durante los experimentos realizados bajo dicho protocolo. Dichos documentos se desarrollaron con base a los lineamientos de la ética en la investigación científica propuesto por Arellano *et al.*, (2014).

3.2. Materiales y equipamiento

Para el desarrollo del presente trabajo se utilizó un electroencefalograma (Figura 3.1); la Tabla 3.1 muestra sus especificaciones técnicas. El equipo cuenta con las normas de seguridad eléctrica y compatibilidad electromagnética Class B, ETSI EN 300 440-2 V1.4.1; EN 301 489-1; EN 301 489-3; AS/NZS CISPR22:2009; AS/NZS 4268:2008; FCC CFR 47 Part 15C (identifiers XUEEPOC01,XUE-USB01), así como las normas de seguridad EN 60950-1:2006, IEC 60950-1:2005

(2nd Edition) AS/NZS 60950.1:2003 including amendments 1, 2 & 3, CB Certificate JPTUV-029914 (TUV Rheinland) (Brain Computer Interface & Scientific Contextual EEG Reference, 2014).



Figura 3.1 Electroencefalograma marca EMOTIV modelo EPOC+ (Emotiv 2014).

	EEG HEADSET
Number of channels	14 (plus CMS/DRL references, P3/P4 locations)
Channel names (International 10-20 locations)	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Sampling method	Sequential sampling. Single ADC
Sampling rate	128 SPS (2048 Hz internal)
Resolution	14 bits 1 LSB = 0.51 μ V (16 bit ADC, 2 bits instrumental noise floor discarded)
Bandwidth	0.2 - 45Hz, digital notch filters at 50Hz and 60Hz
Filtering	Built in digital 5th order Sinc filter
Dynamic range (input referred)	8400 μ V (pp)
Coupling mode	AC coupled
Connectivity	Proprietary wireless, 2.4GHz band
Power	LiPoly
Battery life (typical)	12 hours
Impedance Measurement	Real-time contact quality using patented system

Tabla 3.1 Especificaciones técnicas EMOTIV modelo EPOC+ (Emotiv 2014).

Para la adquisición de datos se utilizó el software Emotive Xavier TestBench V3.0.0.22-2014 (Figura 3.2). Se utilizó MATLAB R2016b V9.1.0.441655 de 64 bits para el procesamiento de las señales y la implementación de los modelos. Para la representación de gráficos de señales EEG, se utilizó EEGLAB V13.6.5b (Figura 3.3). El equipo de cómputo utilizado para el desarrollo del trabajo se utilizó una computadora portátil marca HP modelo ENVY m4 con procesador Intel Core

i5-3210M a 2.50 GHz con 6 GB de memoria RAM bajo el sistema operativo Windows 8.1 de 64 bits.

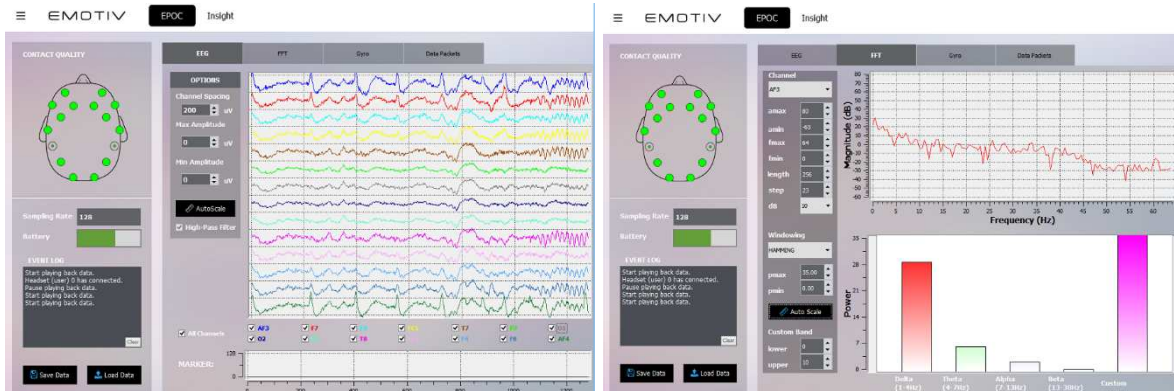


Figura 3.2 Software Emotive Xavier TestBench

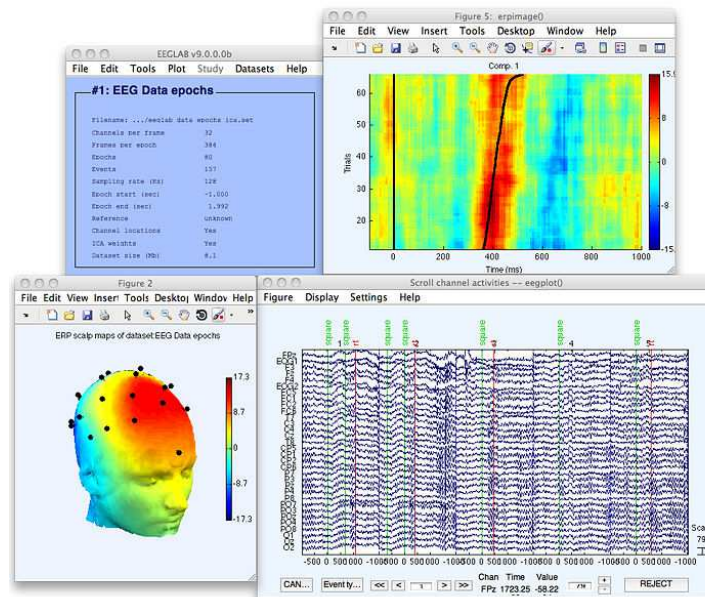


Figura 3.3 Software EEGLAB

3.3. Sistemas BCI basados en SSVEP (BCI-SSVEP)

La retina del ojo humano contiene células conos y bastones. Las células bastones detectan la cantidad de luz y las células como distinguen el color. Hay tres tipos de células cono y se etiquetan convencionalmente como conos largos (L) cortos (S) y mediano (M) de acuerdo con las longitudes de onda de los picos de sus

sensibilidades espectrales (Figura 3.4). Las células S, M y L son sensibles al azul (longitud de onda corta), verde (longitud de onda media) y rojo (longitud de onda larga) de luz, respectivamente. El cerebro combina la información de cada uno de las células de cono para dar diferentes percepciones de diferentes colores; esta condición es la que hace fuerte a los sistemas BCI-SSVEP (Singla *et al.*, 2013).

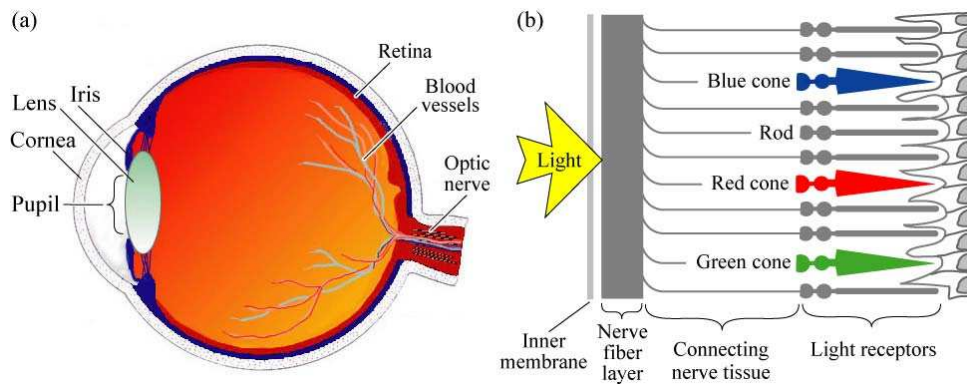


Figura 3.4(a) Sección transversal de un ojo humano. (b) vista esquemática de la retina incluyendo receptores de luz de conos y bastones, (adaptado de la Enciclopedia Británica, 1994-Shubert de 2006)

En neurología, SSVEP son señales que son respuestas naturales a la estimulación visual en frecuencias específicas. Cuando la retina es excitado por un estímulo visual que van desde 3.5 Hz a 75 Hz (Beverina *et al.*, 2003), el cerebro genera la actividad eléctrica en las mismas o múltiples frecuencias del estímulo visual. SSVEP son útiles en la investigación debido a la excelente relación señal-ruido (Regan *et al.*, 1989) y la inmunidad con respecto a los artefactos (parpadeo, movimiento de articulaciones, etc.) (Misulis *et al.*, 1994), que proporcionan un medio para caracterizar las frecuencias preferidas de procesos dinámicos neo-corticales. Alguna ventaja sobre otros sistemas BCI, se incluye una mayor relación señal/ruido, (SNR, por sus siglas en inglés *Signal to Noise Ratio*) y un ITR más rápida de información (Liu, 2013). Adicionalmente no requiere de un entrenamiento intensivo (García, 2008) y requiere un menor número de canales de EEG para el desarrollo de aplicaciones, Figura 3.5.




Figura 3.5 Tiempo de entrenamiento vs ITR, (García 2008)

En los sistemas BCI basados SSVEP, el estímulo visual se le presenta al usuario modulado a diferentes frecuencias simultáneamente. Cada patrón se asocia con una acción en un dispositivo de salida. Cuando el usuario se centra la atención en un cierto patrón, la correspondiente frecuencia de la estimulación, o el armónico, dominante aparece en la representación espectral de las señales de EEG registrada en los sitios occipitales del cerebro (Figura 2.10). La acción asociada a la frecuencia dominante se lleva a cabo (García, 2008).

La amplitud de la SSVEP no es la misma para diferentes frecuencias de estimulación o de diferentes temas. De hecho, la mayor amplitud SSVEP se produce, en promedio, a una frecuencia de estimulación de alrededor de 15 Hz, Figura 3.6 (García, 2008).

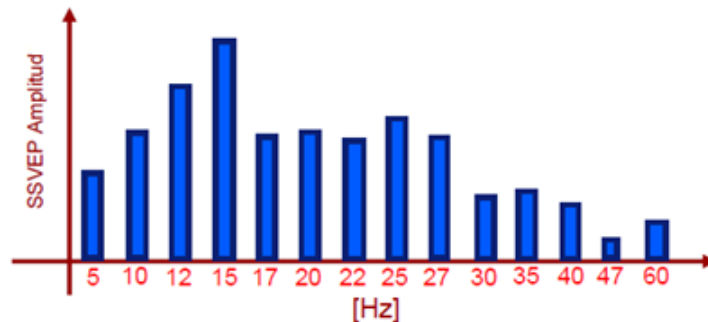


Figura 3.6 SSVEP Amplitud promedio en función de la frecuencia de estimulación, (García 2008).

Las pruebas para el desarrollo de sistemas BCI basados en SSVEP necesitan reproducir un estímulo (parpadeo) a una frecuencia constante. Se utiliza la pantalla de la computadora como dispositivo de parpadeo. Por lo tanto, un objeto de

parpadeo ("objetivo") está representado por una forma que cambia de color a una frecuencia constante o un objeto que aparece/desaparece de repente. Para que el SSVEP funcione, este cambio de color/objeto debe ocurrir a intervalos precisos. Por tanto, es necesario volver a dibujar los objetivos de una manera sincronizada con la pantalla. Esto significa, que las frecuencias que se pueden conseguir dependen de la frecuencia de actualización de la pantalla. En la práctica, sólo las frecuencias que son divisiones enteras de frecuencia de actualización de la base de la pantalla serán posible utilizar. (Renard *et al.*, 2010).

En una pantalla tipo CRT o LCD con frecuencia de actualización de 60 Hz, será posible utilizar las frecuencias de 30, 20, 15, 12, 10 Hz y menores. En una pantalla de 50 Hz, será posible utilizar frecuencias de 25, 16, 66, 12.5, 10 Hz o más bajas (Figura 3.7).




Figura 3.7 Frecuencias de estímulos. Pantalla de 60 Hz en su frecuencia de actualización

3.4. Metodologías de Experimentos para sistemas BCI-SSVEP

3.4.1. Estímulos visuales repetitivos

En las investigaciones BCI-SSVEP, existen tres categorías principales de estímulos visuales repetitivos (RVS, por sus siglas en inglés *Repetitive Visual Stimulus*):

- Estímulos de Luz: Se representa utilizando fuentes de luz tales como LED, luces fluorescentes, y luces-Xe, que son moduladas a una frecuencia especificada. Estos dispositivos son generalmente accionados por un circuito electrónico dedicado, lo que les permite hacer con precisión cualquier secuencia de iluminación o de forma de onda (Figura 3.8). La intensidad (luminancia integrada de tiempo) del estímulo luminoso se mide en "visión fotópica", candelas sobre segundo por metro cuadrado ($cd/s\ m^2$ o nits/s) debido a los cambios de luminancia de luz a través del tiempo. Un parámetro importante para cuantificar

la fuerza del estímulo es la profundidad de modulación que se define como $L_{max} - L_{min} / (L_{max} \times L_{min})$, donde L_{min} , L_{max} son el mínimo y máximo de luminancia, respectivamente (Zhu *et al.*, 2010)



Figura 3.8 Dispositivos de Leds para estímulos visuales

- Estímulos Gráficos Individuales: Son algunas figuras geométricas (por ejemplo, un rectángulo, un cuadrado o una flecha) que se representan en la pantalla de una computadora que aparecen y desaparecen de a un segundo plano en un ángulo determinado (Figura 3.9). La tasa de estimulación se indica como el número de ciclos completos por segundo, normalmente se hace referencia simplemente como la frecuencia del estímulo (Zhu *et al.*, 2010).




Figura 3.9 Estímulos gráficos individuales.

- Estímulos de Patrón Inverso: se representan en una pantalla por alternancia oscilatoria de los patrones gráficos, por ejemplo, tableros de ajedrez. Se componen de al menos dos patrones que se alternan en un número especificado de alternancias por segundo. Con frecuencia los patrones usados incluyen tableros de ajedrez y las cajas de línea (Figura 3.10). Los patrones son generalmente de color en blanco y negro. Un estímulo de tablero de ajedrez se caracteriza por el ángulo subtendido visual de cada baldosa (frecuencia espacial), el número de reversiones por segundo, la luminancia media, el tamaño del campo, y el contraste del patrón. Vale la pena señalar que los estímulos gráficos individuales podrían ser vistos como un caso especial del modelo de estímulos de inversión en el que el gráfico es el primer patrón y el segundo patrón es el fondo. Una diferencia importante es que los estímulos gráficos individuales provocan una respuesta SSVEP a la frecuencia de un ciclo completo (por ejemplo, dos alternancias), mientras que el patrón real de estímulos de inversión provoca una respuesta SSVEP a la frecuencia de una alternancia. Todos los estímulos visuales repetitivos tienen diversas propiedades tales como la frecuencia, el color y el contraste. Tanto el tipo y las propiedades de los estímulos afectan a la respuesta SSVEP (Zhu *et al.*, 2010).




Figura 3.10 Estímulos de patrón inverso.

3.4.2. Estímulos visuales por parpadeo

- Light and Dark: En esta prueba el parpadeo de los objetivos se consiguen por el cambio entre dos colores. La prueba puede utilizar cualquier par de colores. Con el fin de lograr una mejor respuesta a SSVEP se recomienda utilizar colores contrastantes (por ejemplo, rojo y negro). El escenario básico utiliza tres frecuencias de estimulación, sin embargo es factible utilizar más frecuencias. El procesamiento de la señal EEG consiste en establecer ciclos pequeños durante un periodo de tiempo para posteriormente extraer las amplitudes de las ondas cerebrales en cada una de las bandas de frecuencia estimuladas. El escenario de entrenamiento presentará una ventana que muestra (por defecto) tres cuadros llamados “objetivos de entrenamiento”. Se añade un cuadro adicional para representar un objeto sin estimulación, el cual no parpadeará en ningún momento del experimento (Figura 3.11) (Renard et al., 2010).




Figura 3.11 Configuración inicial prueba Light and Dark

Durante el entrenamiento, los períodos de estimulación (cuando los objetivos parpadean, cada uno a su frecuencia predefinida) se repetirán con períodos de descanso (sin parpadeo) entre ellos. Antes de cada período de estimulación, uno de los cuadrados estará marcado con una flecha amarilla. El sujeto debe enfocar su atención visual en el cuadrado marcado durante todo el período de estimulación. Cada cuadrado estará marcado varias veces durante todo el experimento. La duración del período de estimulación de la estimulación es 7 s, la duración del período de descanso es de 4 s, el retardo de parpadeo entre la

aparición de la flecha que marca el cuadrado para estimular y el comienzo del parpadeo es de 1 s.

El tamaño del objetivo se administra como una proporción con el tamaño de la vista de la pantalla. Un tamaño de 0.5:0.1 significa que el objetivo será un rectángulo con una anchura igual a un medio de la anchura de la ventana gráfica y altura igual a 1/10 de la altura de la ventana gráfica. La ventana gráfica, es decir, el área utilizada para la visualización, es la plaza más grande que se ajusta a la ventana, esto significa que un objetivo con misma anchura y relación altura siempre será un cuadrado. Las posiciones de la mitad de los objetivos son $N + 1$ objetivos, teniendo en cuenta N como el número de frecuencias (Renard et al., 2010).

- Square Flickered: En 2012 Zhang *et al.* proponen el "*Command icon Flickered*" para la extracción de características en los sistemas BCI-SSVEP basados en LASSO (por sus siglas en inglés *Least Absolute Shrinkage and Selection Operator*). En 2014 utilizan un experimento similar, "*Square Flickered Experiment*" para determinar el momento óptimo de la longitud de la ventana de tiempo (TWL, por sus siglas en inglés *Time Window Length*) para estimar los componentes de frecuencia dominante en las señales de EEG en BCI-SSVEP. Durante ambos experimentos los sujetos fueron sentados en una silla cómoda a una distancia de 50 cm de un monitor estándar CRT de 17 pulgadas (con una frecuencia de actualización de 85 Hz y una resolución de pantalla de 1024x768). En el primer experimento utilizaron iconos de comandos, como estímulos (Figura 3.12). La primera fila se muestra cuatro iconos de comandos ('Volumen ON', 'Volumen +', 'Volumen -', 'Volumen OFF'). Las frecuencias de los cuatro cuadrados parpadeantes en la segunda fila fueron 6.1, 7.1, 8.5 y 10.6 Hz que corresponden a los cuatro comandos, respectivamente. Estos cuatro comandos podrían utilizarse para ajustar el volumen de un dispositivo (Zhang *et al.*, 2012). En el segundo experimento, utilizan cuadrados rojos que fueron presentados en la pantalla (Figura 3.13), los estímulos parpadearon a los 6, 7, 8.5 y 10.6 Hz, respectivamente. Cada sujeto realizó seis pruebas y cada ejecución contenía cuatro tareas. En cada tarea, la señal objetivo se mostraba por primera vez

durante 1 s. A continuación, se indicaba al sujeto centrar la atención en el estímulo durante 4 s. (Zhang *et al.*, 2014).




Figura 3.12 Configuración experimento "Command icon Flickered"




Figura 3.13 Configuración experimento "Square flickered"

- Four Square: Este experimento se puede presentar por medio de en un conjunto de LED o en un monitor LCD. En el monitor LCD se tiene la flexibilidad en el cambio del color de las barras de parpadeo. Cuatro colores: verde, rojo, azul y violeta se incluyeron en el experimento; el color de fondo seleccionado fue negro.

Se seleccionaron cuatro frecuencias 7, 9, 11 y 13 Hz, en el rango de baja frecuencia, ya que la tasa de actualización del monitor LCD es de 60 Hz y velocidad de los escalones altos de amplitud se obtienen en las frecuencias más bajas. Los estímulos visuales eran cuadrados (4 cm x 4 cm) y se colocaron en cuatro esquinas de la pantalla (Figura 3.14) los colores en la prueba cambiaron entre rojo, verde, azul y violeta. La información recolectada se realizó para todas las cuatro frecuencias en sesiones separadas. El intervalo entre las sesiones fue de 10 minutos. Inicialmente se pidió a los sujetos que cierren los ojos para el registro de 2 minutos de señal de línea de base y luego se da 5 minutos para adaptarse al estímulo parpadeo colocado delante de ellos (Singla *et al.*, 2013).




Figura 3.14 Configuración de la prueba "Four Square".

3.4.3. Búsqueda Visual con Imágenes Naturales

En esta prueba, el usuario está buscando el estímulo en una serie de imágenes naturales en blanco de 800x600 píxeles, que se presentan en el centro de la pantalla de 1366x768 píxeles de fondo negro. El estímulo es un círculo amarillo con un porcentaje de la pantalla del 4%.

El estímulo aparece entre 8 y 16 segundos después del inicio de la imagen en una ubicación aleatoria dentro de la imagen, el sujeto no tiene que realizar ninguna acción para los estímulos sólo aparecen localizar su posición en la pantalla en él. Una pantalla oscura con una duración de 3000 ms sustituye a 1000 ms después de la imagen y la prueba se repite cinco veces. La configuración de las pantallas de la

prueba se muestran en la Figuras 3.15a, 3.15b, 3.15c, pantalla inicial, pantalla de espera y pantalla con estímulo, respectivamente (Dimigen *et al.*, 2011).



Figura 3.15 Configuración de la prueba de Búsqueda Visual con Imágenes Naturales.

3.4.4. Discriminación Visual

En esta prueba, que es la obtención de datos relacionados con los estímulos en las señales del cerebro durante un ejercicio de atención simple. La prueba de “las cinco cajas” propuesta por Makeig *et al.* (1999) busca encontrar la diferencia entre los estímulos relacionados con el cuidado y sin relación a la atención. A diferencia de las pruebas visuales descritas anteriormente, el sujeto debe discriminar entre diferentes tipos de estímulos que se le presentan a alta velocidad.

En esta prueba se utiliza una pantalla LCD, los usuarios fijan su vista en una cruz, que se encuentra por encima de cinco cajas que se exhiben constantemente (Figura 3.16). Cada bloque de prueba es de 76 s, los estímulos son una serie de círculos rojos que se presentan brevemente en cualquiera de las cinco cajas en un orden aleatorio. Las cajas son de color azul y una es de color verde. La ubicación de ésta última es al azar durante los períodos de prueba. Los estímulos que se producen dentro de ésta caja (verde) son *estímulos atendidos*, los estímulos dentro de las cajas azules son conocidos como *estímulos no atendidos*.

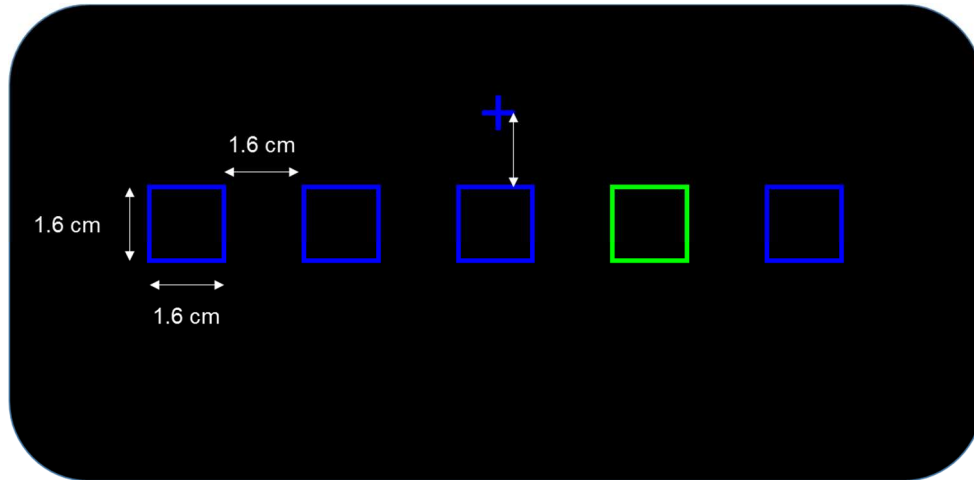


Figura 3.16 Configuración de la prueba de las 5 cajas

Se le pide al usuario a concentrarse cada vez que un disco aparece en la caja verde. (Townsend 1994). Los contornos de los cuadros son de 1.6 cm y se muestran sobre un fondo negro en ángulos de visión horizontal de $0^\circ \pm 2.7^\circ$ y $5.5^\circ \pm$ fijación. En cada bloque de prueba se presentan 100 estímulos en total: 20 atendidos 80 no atendidos, cada uno se muestra durante 117 ms para uno de los cinco asientos vacíos en una secuencia pseudo-aleatoria con intervalos entre estímulos (ISIS) de 250 a 1000 ms, Figura 3.17. Los estímulos se presentan al sujeto en una posición aleatoria a 250 ms, 500 ms, 750 ms y 1 s. La Figura 3.18a muestra la configuración inicial de la prueba, en cada bloque de prueba se presentan 100 estímulos en total: 20 atendidos (eventos) 80 no atendidos (Figura 3.18c y Figura 3.18b respectivamente). El último estímulo permanece 200 ms en la pantalla antes de desaparecer (Makeig *et al.*, 1999; Townsend *et al.*, 2001).




Figura 3.17 Configuración de intervalos de la prueba de las 5 cajas




Figura 3.18 Identificación de eventos, prueba de las 5 cajas.

La prueba de las 5 cajas se puede configurar en las siguientes variantes:

- Discriminación Simple: Círculos rojos en 5 cajas. 120 (25%) eventos atendidos, 480 (75%) eventos no atendidos.
- Discriminación Compuesta: Cuadros rellenos en su color original. 120 (25%) eventos atendidos, 480 (75%) eventos no atendidos
- Discriminación Combinada: Esta prueba considera las dos variantes anteriores la mitad de los estímulos son círculos sobre cajas y la mitad sobre cajas rellenas, los estímulos atendidos siguen siendo círculo rojos. 35 (25%) eventos atendidos 105 (75%) eventos no atendidos.


3.4.5. Otras pruebas

Existen otras pruebas para SSVEP, como la prueba de clasificación (Beverina *et al.*, 2003) en la cual el sujeto tiene que enfocar su atención en el símbolo parpadeante izquierda, después de 2 s en el centro de la pantalla y finalmente durante 20 s en el símbolo intermitente izquierdo (Figura 3.19a). Para comprobar el momento exacto en que el sujeto cambia de dirección, tiene que pulsar uno de los tres botones de acuerdo con la luz parpadeante que el sujeto está mirando. Los Anillos de Newton se basan en la estimulación visual de las inversiones de movimiento y en la atención selectiva basada en estado estacionario en los sistemas BCI. El "estado estacionario" de las respuestas cerebrales fueron provocados por los movimientos de espejo, que oscila en dos direcciones opuestas (Ding *et al.*, 2006; Xie *et al.*, 2012.). Los anillos de Newton, que es un patrón de interferencia óptica que existe en el mundo natural, se adoptaron como la plantilla para la estimulación de inversión del movimiento, Figura 3.19b (Xie *et al.*, 2012). Por último la prueba de *estímulos de video* propuesta por Acqualagna *et al.*, (2015) en el cual los participantes tienen


que ver una serie de 51 vídeos, dividido en tres series (20 + 15 + 16 videos). Entre cada serie, hay un descanso de 10 minutos, para dar a los participantes la oportunidad de relajarse y estirarse. Cada video tenía una longitud de 114 s, seguidos de una pausa de 5 s. Cada video comenzó con una cruz de fijación en el centro de la pantalla que se muestra durante 3 s. Con el fin de minimizar los artefactos, los participantes fueron instruidos para no mover los ojos durante la presentación del video y evitar el parpadeo lo más posible. Seis imágenes de textura en niveles de gris se eligieron como base para la generación de estímulos (Figura 3.19c). Cada figura es de tamaño 512x512 píxeles y todas tienen la misma luminancia media las imágenes de textura fueron estacionarias espacialmente a la misma distancia. Entonces la calidad de la textura de cada imagen se degradó en seis niveles diferentes.



(a)



(b)



(c)

Figura 3.19. Pruebas adicionales para SSVEP

3.5. Algoritmos de procesamiento de señales para sistemas BCI-SSVEP

Los sistemas BCI-SSVEP han ganado terreno en la investigación de las áreas de neurobiología y neuro-informática debido a su mayor relación SNR y un ITR de mayor velocidad que otras técnicas, así mismo, no requieren de un entrenamiento intensivo (Bin *et al.*, 2009).

De acuerdo con el método de modulación y de la función utilizada para la clasificación, hay dos tipos de BCI-SSVEP: Los *SSVEP-frecuencia* que utilizan estímulos visuales con frecuencias distintas, y detectan objetivos mediante la comprobación de los picos espectrales en el espectro registrado. El número de los estímulos es siempre igual al número de objetivos. Los *SSVEP-fase* utilizan estímulos visuales con la misma frecuencia pero diferentes fases. Estos sistemas identifican objetivos mediante la comparación del desfase de las fases entre los elementos del SSVEP y una señal de referencia (Liu *et al.*, 2013). Los sistemas BCI-SSVEP también se pueden clasificar en síncronos o asíncronos, con referente a la forma en que se presentan los estímulos, en los síncronos los estímulos se presentan de manera periódica, siempre con el mismo tiempo de desfase entre eventos, en el caso de los asíncronos los estímulos se presentan de manera aleatoria.

En este trabajo, se realiza una revisión de los algoritmos utilizados para los sistemas BCI basados en SSVEP como una guía de referencia de las técnicas utilizadas recientemente; nos centramos en el pre-procesamiento de datos, la extracción de características y clasificación de elementos los cuales se muestran en la Tabla 3.2, Tabla 3.3 y Tabla 3.4 respectivamente.

Método		Descripción	Año	Referencias
Basados en Filtrado de Frecuencias		Los filtros están diseñados de acuerdo a las características de frecuencia de las señales relacionadas.		
	Filtro Pasa Banda	Se utiliza un filtro de paso de banda. El rango de frecuencia está diseñado de acuerdo con las frecuencias de estimulación o de sus armónicos. Un filtro de banda-bajo es fácil de implementar, pero podría ser demasiado estrictos para explicar las señales variables en el tiempo.	2012 2010 2011 2011 2010, 2013 2010 2008 2012 2011 2013 2012	H. C. Chang <i>et al</i> 29-35 Hz P. L. Lee <i>et al</i> 29.25-33.25Hz S. M. T. Muller <i>et al</i> 3-60 Hz S. M. Müller <i>et al</i> 3-100 Hz P. F. Diez <i>et al</i> 32-45 Hz Z. Zhang <i>et al</i> 3-40 Hz R. Ren <i>et al</i> 1-30 Hz Z. Zhang <i>et al</i> 3-45 Hz Y. Zhang <i>et al</i> 5-50 Hz S. M. T. Müller <i>et al</i> 3-60 Hz Y. Zhang <i>et al</i> 5-35 Hz

			2010 2010 2010 2012	H. C. Chang <i>et al</i> H. T. Wang <i>et al</i> L. Zhao <i>et al</i> Y. Punsawad <i>et al</i>	12-16 Hz 8-24 Hz 10-30 Hz 5-40 Hz
	Filtro Notch	Se utiliza por lo general para eliminar la interferencia de línea de potencia.	2011 2010	S. M. Müller <i>et al</i> H. T. Wang <i>et al</i>	50 Hz
Basados en Filtrado espacial		El filtrado espacial combina las señales de diferentes canales para magnificar las respuestas del SSVEP o reducir la interferencia de ruido. Las señales procedentes de múltiples canales se ven menos afectadas por el ruido que las señales de un sistema unipolar o bipolar. La técnica de filtrado espacial puede también ser utilizada para extraer características.			
	MEC Minimum Energy Combination	Se utiliza para cancelar señales de ruido. Similar con MCC, que se basa en un modelo entre SSVEP y las ondas estándar de seno-coseno con ruido.	2007 2010 2010 2011 2011 2011	O. Friman <i>et al</i> I. Volosyak <i>et al</i> H. Golle <i>et al</i> I. Volosyak <i>et al</i> Wenya <i>et al</i> N. Chumerin <i>et al</i>	
	MCC Maximum Contrast Combination	El método MCC tiene como objetivo maximizar la relación entre SSVEP y las señales de fondo. El principio es similar al MEC, pero el objetivo de la función que se utiliza para el cálculo del filtro los coeficientes de ponderación son diferentes.	2010 2010 2011	G. García-Molina <i>et al</i> D. H. Zhu <i>et al</i> D. Zhu <i>et al</i>	
	PCA Principal Component Analysis	Es utilizado para descomponer la señal del SSVEP en sus componentes como respuesta a las actividades cerebrales. Se objetivo es reducir la dimensión de los datos originales. Se requieren otros métodos para la extracción de características	2009	S. Pouryazdian <i>et al</i>	
	ACSP Analytic Common Spatial Pattern	Método de patrones espaciales basado en la representación analítica de señales. Se refleja tanto la amplitud y la fase de información de SSVEP. Basado en el método CSP	2012	O. Falzon <i>et al</i>	
	CAR Common Average Reference	En éste método el valor medio de todos los electrodos se resta del canal de interés para hacer obtener la señal de referencia más cercana.	2010 2013	S. M. T. Müller <i>et al</i> S. M. T. Müller <i>et al</i>	
	CCA Canonical Correlation Analysis	Calcula la relación entre dos conjuntos de datos de múltiples variables después de las combinaciones lineales de los datos originales.	2009 2006 2011	G. Y. Bin <i>et al</i> Z. L. Lin <i>et al</i> Y. Li <i>et al</i>	
	MCC + CCA		2010	N. Y. Wang <i>et al</i>	
	KCCA	Basado en CCA, para proyectar datos en un espacio de alta dimensión	2006	Z. M. Zhang <i>et al</i>	
	Multiway CCA	Utiliza la optimización de las señales de referencia después de los ajustes. Incrementa considerablemente el tiempo computacional	2011	Y. Zhang <i>et al</i>	
	p-CCA	La información de fase es utilizada en la señal de referencia	2011	J. Pan <i>et al</i>	

Tabla 3.2 Métodos de pre-procesamiento de señales utilizados en BCI-SSVEP

Método		Descripción	Año	Referencias
Basados en Transformada de Fourier		Comúnmente utilizado para el análisis del espectro de la potencia o de frases de las señales SSVEP. Es fácil de implementar y consume tiempo de cálculo pequeño. Sin embargo, fue diseñado originalmente para señales estacionarias lineales		
	FFT Fast Fourier Transform	Algoritmo computacional rápido para obtener la DFT (Discrete Fourier Transform). Por lo general, se utiliza en segmentos de datos largos para la estimación de la energía, la cual podría influir en el desarrollo de aplicaciones prácticas. Las frecuencias de estimación disponibles pueden ser limitadas debido a que la resolución de frecuencia se limita a una longitud de segmento de datos dado.	2008 2009 2010 2010 2011 2011 2011 2012 2012 2013	G. R. Muller-Putz <i>et al</i> M. T. Al-Maqtari <i>et al</i> C. M. Wong <i>et al</i> H. T. Wang <i>et al</i> P. F. Diez <i>et al</i> C. M. Wong <i>et al</i> C. Jia <i>et al</i> T. Punsawad <i>et al</i> H. J. Hwang <i>et al</i> P. F. Diez <i>et al</i>
	DFT Discrete Fourier Transform	El tiempo de computo es mayor que el del FFT	2010 2011 2011	M. A. Lopez-Gordo <i>et al</i> R. Ortner <i>et al</i> P. G. D. Angel <i>et al</i>
Basados en Transformada Wavelet		Puede ser visto como un análisis de Fourier de ventana ajustable. En comparación con transformada de Fourier, tiene buena resolución de tiempo y frecuencia y es adecuado para el procesamiento de señales no estacionarias. Sin embargo, aún no es mejor para el procesamiento de señales no lineal		
	Wavelet packet decomposition	Es una extensión de la transformada wavelet. Se descompone la señal en un árbol de paquete de ondas. No es mejor para procesamiento de señales no lineales	2010 2011	Y. Bian <i>et al</i> Y. Bian <i>et al</i>
	CWT Continuos Wavelet Transform	Transformada Continua Wavelet	2010	Z. Zhang <i>et al</i>
EEDM + MFD Ensemble Empirical Mode Decomposition + Matched Filter Detector		EEDM fue desarrollada para superar el problema de la mezcla de EMD. Es adecuado para el procesamiento de señales no estacionarias a costa de mayor tiempo de cálculo. MFD se utiliza para estimar el poder mediante el cálculo del producto interno entre los pasos y las señales sinusoidales complejas normalizadas.	2012	P- L- Lee <i>et al</i>
EMD Empirical Mode Decomposition			2011	Chi-Hsun <i>et al</i>
EMD + rGZC Empirical mode decomposition + Refined generalized zero crossing		Después de aplicar la descomposición por EMD, el rGZC se utiliza para calcular la frecuencia instantánea. EMD se puede utilizar para reducir el ruido no relacionado con SSVEP.	2011	C. H. Wu <i>et al</i>
EMD + Quadrature Detection Method		Se basa en el modelo MFD	2009	C. H. Wu <i>et al</i>
HT Hilbert Transform		Se utiliza para calcular las fases del SSVEP después de filtrado espacial con MEC. Se necesita una longitud de datos más corto que para el método de Fourier.	2010 2010	G. Garcia-Molina <i>et al</i> D H. Zhu <i>et al</i>
HHT Hilbert-Huang Transform		Es la combinación de EMD y HT. Como EMD, es adecuado para el procesamiento no estacionario y las señales no lineales con segmentos de datos más cortos a costa de mayor tiempo de cálculo	2010	L. Zhao <i>et al</i>
MCC + HT Máximum Constrast Combination + HT		La estimación de la potencia a la frecuencia se calcula después de que los datos originales se filtran por el método de MCC. Entonces, HT se utiliza para calcular las fases de señales.	2011	D. Zhu <i>et al</i>
MCC + CCA			2010	N. Y. Wang <i>et al</i>
MEC Minimum Energy Combination		Las SSVEP son filtradas por el método MEC, y entonces la potencia estimada en cada frecuencia se calcula como una estimación de las variables de función. Se puede hacer un mejor uso con las señales de diferentes canales.	2007 2010 2010 2011	O. Friman <i>et al</i> I. Volosyak <i>et al</i> H. Cecotti <i>et al</i> I. Volosyak <i>et al</i>
MEC + Auto-regressive estimation		MEC se utiliza para calcular la estimación de la potencia de la frecuencia de la señal. El modelo auto-regresivo se emplea para estimar la potencia del ruido	2010 2011	H. Gollee <i>et al</i> N. Chumerin <i>et al</i>

ACSP Analytic Common Spatial Pattern	El método analítico patrón espacial común se aplica a SSVEP codificados en fase. Es una mejora de CSP.	2012	O. Falzon <i>et al</i>
Basados en CCA	Método eficaz para el cálculo de la relación entre dos conjuntos de datos de múltiples variables. Solo se utiliza el coeficiente máximo.		
	CCA	Después de combinaciones lineales de los datos originales, las nuevas señales se utilizan para calcular el coeficiente de correlación. Tiene mejor precisión de clasificación que la de método PSDA	2006 2009 2011 2012 2014 2014 2015 Z. L. Lin <i>et al</i> G. Y. Bin <i>et al</i> Wenya <i>et al</i> Zhang <i>et al</i> Castillo-García <i>et al</i> Jian <i>et al</i> Cao <i>et al</i>
	KCCA	El núcleo se utiliza para proyectar los datos en un espacio de mayor dimensión y mejorar el tradicional CCA de los cuales se supone que los dos conjuntos de datos estén relacionados linealmente.	2012 Z. M. Zhang <i>et al</i>
	Multiway CCA	Se utiliza para optimizar las señales de referencia después del ajuste, pero esto aumenta el tiempo de cálculo.	2011 Y. Zhang <i>et al</i>
	p-CCA	La información de la fase es usada en la señal de referencia	2011 J. Pan <i>et al</i>
SFT Spectralm F-Test	La prueba F-Espectral se lleva a cabo para la extracción de características. Es necesario un análisis espectral de potencia para construir el modelo de prueba. Una de las propuestas de dos pruebas no se necesita una señal de referencia, por lo que es mejor para su utilización directa	2010 2011 2013	M. T. Müller, <i>et al</i> M. T. Müller, <i>et al</i> M. T. Müller, <i>et al</i>
CCA + FFT	FFT se utiliza para confirmar los signos de vectores de ponderación calculados por la CCA para el SSVEP codificado en fase.	2011	Y. Li <i>et al</i>
PCA + High order statistics + Auto-regressive estimation	El método de las estadísticas de alto orden se utiliza para confirmar componentes SSVEP relacionadas y no relacionadas descompuestos por el PCA. Posteriormente el modo auto-regresivo se utiliza para el análisis de la densidad espectral de potencia.	2009	S. Pouryazdian <i>et al</i>
PCC0 Principal Component C0 Complexity	La complejidad C0 se utiliza para detectar el estado inactivo y el estado de trabajo (estado SSVEP) cuando se combina con el método PCA.	2008	R. Ren <i>et al</i>
SDFSs Stepping Delay Flickering Sequence	Seis secuencias de retardo de parpadeo se utilizan para formar una codificación de fase	2012	H. C. Chang <i>et al</i>
Time-locked Epoch-Average Process	Aplicación SSVEP. El cálculo se basa en la transformada de Fourier. Calcula el pico de amplitud entre los pasos y las señales de referencia para un módulo de fase codificado.	2010	P. L. Lee <i>et al</i>
MFD Matched Filter Detection	MFD se utiliza para estimar la potencia mediante el cálculo del producto interno entre SSVEP y las señales sinusoidales complejas normalizadas. Se necesita menos tiempo de cálculo en comparación con otros métodos. Su modelo de cálculo es similar a la de CCA pero adecuado para las señales de un solo canal.	2010	H. C. Chang <i>et al</i>
LASSO Least Absolute Shrinkage and Selection Operator	Se asume que SSVEP es un modelo de regresión lineal estándar de señales de estimulación. La hipótesis es bastante similar a la de la MEC o MCC.	2012 2015	Y. Zhang <i>et al</i> Cao <i>et al</i>

Tabla 3.3 Métodos de extracción de características de señales utilizados en BCI-SSVEP

Phase Detection	Los signos de los coeficientes de peso se usan para reconocer diferentes objetivos de SSVEP codificado en fase.	2011	Y. Li <i>et al</i>
ACL Assisted Closed Loop		2013	Fernandez-Vargas <i>et al</i>
CSP Common Spatial Patern		2013 2015	Song <i>et al</i> Acqualagna <i>et al</i>
DSLQ Distinctive Sensitive Learning Vector Quantization		2005 2008	Müller-Putz <i>et al</i> Müller-Putz <i>et al</i>
MSI Multivariate Synchronization Index		2014	Y. Zhang <i>et al</i>
SC Stability Coefficient		2008	Nan <i>et al</i>
SD Sequence Detection		1943 2015	Wald Cao <i>et al</i>
PSDA Power Spectral Density-Based Analysis		1998 2000 2003 2005 2006 2014	Liavas <i>et al</i> Middendorf <i>et al</i> Gao <i>et al</i> Lalor <i>et al</i> Mukesh <i>et al</i> Castillo-García <i>et al</i>
ICA Independent Component analysis		2000 2000 2002 2002 2004 2006	Vigário <i>et al.</i> Jung <i>et al</i> Tang <i>et al</i> Jung <i>et al</i> Ungureanu <i>et al</i> Sholz

Tabla 3.4 Métodos de clasificación de características de señales utilizados en BCI-SSVEP

3.5.1. Canonical Correlation Analysis (CCA)

Propuesto por Hotelling en 1936, CCA es un método estadístico multivariado para medir la relación lineal entre dos variables multidimensionales. Este método ha sido ampliamente utilizado en sistemas BCI porque es altamente eficiente, fácil de implementar y no requiere calibración (Borga, 2001; Bin *et al.*, 2009; Karhunen *et al.*, 2012; Castillo-García *et al.* 2014; Jian *et al.*, 2014; Zhang *et al.*, 2014; Cao *et al.*, 2015). Lin *et al.* (2006) utilizaron CCA por primera vez para detectar la frecuencia de referencia en los sistemas BCI-SSVEP (Zhang *et al.*, 2011).

El método CCA utiliza información de la covarianza de los canales, que tiende a aumentar el SNR y reduce el coste computacional para sistemas en línea. CCA refleja la relación de correlación entre las señales de respuesta EEG y la serie de Fourier clásica a la frecuencia del estímulo y sus armónicos (Cao *et al.*, 2015).

Considere la señal de origen SSVEP como una serie de tiempo. X que representa las señales obtenidas de múltiples canales de EEG, Y es la señal de referencia con una frecuencia de estímulo f_i que se puede descomponer en la serie de Fourier de sus armónicos ($\sin(2\pi ft)$, $\cos(2\pi ft)$, $\sin(4\pi ft)$...)

$$Y = \begin{cases} \sin(2\pi f_i t) \\ \cos(2\pi f_i t) \\ \vdots \\ \sin(2\pi N_h f_i t) \\ \cos(2\pi N_h f_i t) \end{cases} \quad t = \frac{1}{F_s}, \frac{2}{F_s}, \dots, \frac{T}{F_s} \quad (1)$$

N es el número de estímulos y h es el número de armónicos de la frecuencia objetivo, F_s es la frecuencia de muestreo y T es el número de puntos de la señal. El algoritmo encuentra un par de combinaciones lineales, $x = X^T W_x$ y $y = X^T W_y$ para X y Y para maximizar la correlación entre las dos variables canónicas, x y y para resolver el problema de optimización:

$$\max_{W_x, W_y} \rho(x, y) = \frac{E[x^T y]}{\sqrt{E[x^T x]E[y^T y]}} = \frac{E[W_x^T X Y^T W_y]}{\sqrt{E[W_x^T X X^T W_x]E[W_y^T Y Y^T W_y]}} \quad (2)$$

La correlación canónica ρ se utiliza como coeficiente de CCA obtenido con la señal de referencia de frecuencia f_i (Jian *et al.*, 2014; Cao *et al.*, 2015). Esto genera el coeficiente de correlación máximo $\rho(f_i)$. La clasificación de la regla de decisión CCA se describe como

$$f_{target} = \max_{f_i} \rho(f_i) \quad (3)$$

3.5.2. Empirical Mode Decomposition (EMD)

EMD es un método adaptativo introducido para analizar señales no lineales y no estacionarias. Consiste en una separación local y totalmente controlada por datos de una señal en oscilaciones rápidas y lentas (Torres *et al.*, 2011). Las señales de EEG se caracterizan generalmente como una suma de potenciales post-sinápticos de un número muy grande de neuronas, que crean patrones oscilatorios distribuidos y es posible registrar alrededor del cuero cabelludo. Esos patrones en los rangos de frecuencias conocidas pueden ser monitoreados y clasificados en sincronía a un estímulo dado a los sujetos (Wu *et al.*, 2011).

EMD es un poderoso enfoque basado en datos para extraer señales significativas modificadas estocásticamente en muchas aplicaciones, incluyendo la medición de la presión sanguínea (Huang *et al.*, 1998), la monitorización de la frecuencia cardiaca y el electrocardiograma (Balocchi *et al.*, 2004) Hipertensión (Huang *et al.*, 1998), atención espacial visual (Liang *et al.*, 2005) y BCI (Wu *et al.*, 2011).

EMD utiliza el conocimiento empírico de las oscilaciones intrínsecas a una serie temporal para representarlas como una superposición de componentes con frecuencias instantáneas bien definidas. Estos componentes se llaman Funciones de Modo Intrínseco (IMF, por sus siglas en inglés *Intrinsic Mode Functions*) (Rutkowski *et al.*, 2008). El enfoque EMD intenta descomponer secuencialmente una señal en un número finito de FMI mediante la realización iterativa de un *proceso de recorrimiento*. Cada FMI representa una simple señal de oscilación, es una función analítica, autoconstruida, bien definida, impulsada por datos, cuyas amplitudes y frecuencias varían con el tiempo (Wu *et al.*, 2011).

La técnica de encontrar IMFs corresponde por lo tanto a encontrar señales de banda limitada. También corresponde a la eliminación de ondas de conducción de la señal, lo que garantiza que la frecuencia instantánea no tendrá fluctuaciones causadas por una forma de onda asimétrica. IMF en cada ciclo se define por cero cruces (zero crossing). Cada FMI sólo implica un modo de oscilación, por lo que no se permiten ondas complejas de conducción. El IMF no se limita a ser una señal de banda estrecha, como sería en la descomposición tradicional de Fourier o Wavelets, de hecho puede ser modulada tanto en amplitud como en frecuencia al mismo tiempo y también puede ser no estacionaria o no lineal. Un IMF es particularmente útil para presentar las características locales de señales no estacionarias (Rutkowski *et al.*, 2008; Wu *et al.*, 2011; Rosas-Cholula *et al.*, 2013;).

EMD considera un vector \vec{x} de tamaño $1 \times N$, donde N is el número de puntos de cada canal obtenido de EEG. El proceso de descomposición de cada EEG en un conjunto de IMF a través del proceso de recorrimiento que se basa en los siguientes pasos:

- 1) Definimos $\vec{h}(1) = \vec{x}$;
- 2) Identificar todos los extremos locales en $\vec{h}(1)$, incluyendo el máximo local y el mínimo local;
- 3) Conectar todos los máximos/mínimos locales utilizando algún método de interpolación (lineal, spline, gaussiano, etc.) para generar los envolvimientos superior/inferior;
- 4) Determinar la curva media local, \vec{m} , promediando las envolvimientos superior e inferior;
- 5) Calcular el pre-IMF, $\vec{h}(2)$, restando \vec{m} de los datos $\vec{h}(1)$, $\vec{h}(2) = \vec{h}(1) - \vec{m}$;
- 6) Repita los pasos 2 a 5 para k iteraciones hasta que la diferencia entre dos pre-IMFs continuos, $SD^{(k)}$, y que alcance un criterio de detención definido por el usuario ε

$$SD^{(k)} = \frac{\|\vec{h}^{(k+1)} - \vec{h}^{(k)}\|^2}{\|\vec{h}^{(k)}\|^2} < \varepsilon \quad (4)$$

donde $\|\cdot\|$ denota la distancia euclidiana;

- 7) Definimos $\vec{c}_1 = \vec{h}^{(k)}$ como el primer IMF;
- 8) Calcular $\vec{r} = \vec{x} - \vec{c}_1$;
- 9) Reemplazar \vec{x} en el paso 1 por \vec{r} y repetir los pasos desde el 2 al 8 (proceso de recorrimiento), para encontrar los siguientes IMFs $\vec{c}_1, \vec{c}_2, \dots, \vec{c}_j$;
- 10) Detenga el proceso de recorrimiento cuando la función de residuos $\vec{r} = \vec{x} - \sum_{j=1}^J \vec{c}_j$ se convierte en una función monótona que no puede extraer más IMFs.

\vec{x} puede ser representado por una función de residuos monofónicos \vec{r} y un conjunto de IMF basados en $\vec{c}_1, \vec{c}_2, \dots, \vec{c}_j$ donde j es el número de IMF extraídos de \vec{x} . Cada $\vec{c}_k, 1 \leq k \leq j$ es un vector $1 \times N$ (Wu *et al.*, 2011). Los IMF pueden estar dispuestos en una matriz $C_{j \times N}$, donde cada fila \vec{c}_k representa el k -ésimo IMF; C se define como:

$$C = \begin{bmatrix} \vec{c}_1 \\ \vec{c}_2 \\ \vdots \\ \vec{c}_j \end{bmatrix}_{j \times N} \quad (5)$$

3.5.3. Fast Fourier Transform (FFT)

la Transformada Rápida de Fourier (FFT, por sus siglas en inglés *Fast Fourier Transform*), es una de las técnicas de análisis más comunes que se utiliza para señales biológicas (con o sin ruido) y tiene como objetivo separar la señal original en sus diferentes componentes espectrales (o de frecuencia). Es una versión más rápida de la Transformada Discreta de Fourier (DFT, por sus siglas en inglés *Discrete Fourier Transform*) (Kumaresan, 2015). La evaluación directa de la DFT requiere n^2 operaciones aritméticas. Mediante un algoritmo FFT se puede obtener el mismo resultado con sólo $n \log(n)$ operaciones para valores de n muy grandes. La FFT es el algoritmo que se utiliza para realizar la DFT de una forma eficiente y rápida (Cortes *et al.*, 2007). Con base a (6), el cálculo de DFT de n puntos de una secuencia $x(n)$ requiere la suma compleja de N multiplicaciones complejas para cada una de las salidas. En total, N^2 multiplicaciones complejas y $N(N - 1)$ sumas complejas. Para calcular FFT se divide la secuencia de datos de entrada $x(n)$ en dos grupos, uno de índices par y el otro de índices impar. Con estas sub-secuencias se realiza el DFT de $N/2$ puntos y sus resultados se combinan para formar el DFT de N puntos, podemos decir que el DFT de N puntos es la suma de dos DFTs de $N/2$ puntos. Los dos DFT de $N/2$ puntos se puede a su vez dividir para formar 4 DFTs de $N/4$ puntos, el proceso puede repetirse sucesivamente hasta llegar a calcular el DFT de dos valores $x(n)$, en concreto $x(k)$ y $x(k + N/2)$, para

$k = 0, 1, \dots, N/2 - 1$. Para cada proceso tenemos una multiplicación y dos sumas complejas, es decir $N/2$ operaciones por etapa y $\log_2 N$ etapas. El número total de multiplicaciones es $\frac{1}{2}N \log_2 N$ y el número total de sumas es $N \log_2 N$. Lo que se consigue con éste algoritmo es simplificar el cálculo de la DFT y reducir el número de operaciones (Gómez, 2017).

DFT permite la descomposición de señales de tiempo discreto en componentes sinusoidales cuyas frecuencias son múltiplos de una frecuencia fundamental. Consideremos una señal discreta $x(n), n = 1, 2, \dots, N$, que se ha derivado de $x(t)$ mediante muestreo a intervalos de tiempo iguales Δt , con una frecuencia de muestreo $f_s = \frac{1}{\Delta t}$, la longitud de la señal es $T = N * \Delta t$. La DFT se define como:

$$X[k] = \sum_{n=0}^{N-1} x(n) e^{-j(2\pi kn/N)} \quad (6)$$

El espectro $X(k)$ se estima en múltiplos de f_s/N (Freeman y Quiroga, 2013). La señal $x(n)$ puede ser reconstruida con la inversa de la DFT (IDFT):

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X[k] e^{j2\pi kn/N} \quad (7)$$

Los coeficientes de Fourier $X[k]$ son números complejos que pueden representarse en formas cartesianas o polares, como:

$$X[k] = X_R[k] + jX_I[k] = |X[k]| e^{j\phi} \quad (8)$$

donde X_R y X_I denotan las partes real e imaginaria en la representación cartesiana, $|X[k]|$ y ϕ denotan la amplitud y la fase en la representación Polar. Si consideramos sólo secuencias reales $[n]$, se puede demostrar fácilmente que $X[k] = X^*[N - k]$ (donde $*$ denota una conjugación compleja). Entonces, la Transformada de Fourier da un total de $N/2$ coeficientes complejos independientes; esto significa N valores

independientes. Puesto que podemos reconstruir una señal de N puntos de datos del mismo número de valores de Fourier independientes, la Transformada de Fourier no es redundante (Freeman y Quiroga, 2013).

A partir de la serie de tiempo $x[n]$ la DFT da la actividad a las frecuencias f_k , con

$$f_k = \frac{k}{N\Delta t} \quad (9)$$

La resolución de la frecuencia será dada por

$$\Delta f = \frac{1}{N\Delta t} = \frac{1}{T} \quad (10)$$

De acuerdo con el Teorema del Muestreo de Shannon (Mallat 1999), la frecuencia de Nyquist se define como la frecuencia más alta que se puede resolver con un período de muestreo:

$$f_n = \frac{1}{2\Delta t} = \frac{f_s}{2} \quad (11)$$

y corresponde a $k = N/2$ en (9) (Freeman y Quiroga, 2013).

3.5.4. Independent Components Analysis (ICA)

ICA fue introducido primero por Comon (1994), con desarrollos adicionales por Bell y Sejnowski (1995). Hyvärinen (2012), Acharya y Panda (2009) proporcionan una visión general de algunos desarrollos recientes, desde 2000, en la aplicación de ICA como la computación neuronal, procesamiento de señales y estadística. Desde entonces, se han desarrollado una gran variedad de algoritmos ICA, por ejemplo, los trabajos realizados por Blaschke y Wiskott (2004), Bach y Jordania (2002), Hyytiäinen y Oja (2000), Ziehe y Müller (1998), Bell y Sejnowski (1995), Sholz (2006).

En el campo de las ciencias biomédicas Isomura y Toyoizumi (2016) utilizaron una regla de aprendizaje local para ICA para entender el procesamiento de información

neuronal a través de imágenes naturales y sus aplicaciones en ingeniería neuromórfica. Oostenveld *et al.* (2011) presentaron un software de código abierto para el análisis avanzado de MEG, EEG, y datos electrofisiológicos invasivos basados en ICA. Kong *et al.* (2008) usaron ICA para aplicaciones de datos de expresión de genes de micro-arreglos. Hung *et al.* (2005) utilizaron ICA para el reconocimiento de señales de imágenes motoras en señales EEG. James y Hesse (2004) utilizaron para separar características de las señales EEG multicanal. Saidi *et al.* (2004) demostraron que el agrupamiento en los componentes ICA obtuvo agrupamientos (*clusters*) biológicamente más razonablemente agrupados que los obtenidos por PCA (por sus siglas en inglés *Principal Component Analysis*). Liebermeister (2002) la utilizó para analizar patrones de expresión génica durante el ciclo celular de la levadura y en la identificación de linfocitos humanos. Martoglio *et al.* (2002) lo aplicaron a los datos de cáncer de ovario. Tang *et al.* (2002) y Vigário *et al.* (2000) y utilizaron ICA para identificar los artefactos y señales de interés obtenidos por MEG; Jung *et al.* (2002 y 2000) utilizado en señales EEG.

Se encontró que ICA extrae componentes más significativos y mejor interpretables que PCA; e incluso se descubrió un artefacto experimental inesperado. Además, cuando se aplica a las actividades enzimáticas, ICA fue capaz de proporcionar componentes de mayor discriminación y con mayor importancia que los componentes PCA (Sholz, 2006).

ICA se ha utilizado con el fin de reducir el tiempo de cálculo mediante la eliminación y la construcción de datos irrelevantes y relevantes de las señales eléctricas cerebrales obtenidas por EEG para mejorar el rendimiento de los sistemas de BCI (Ungureanu *et al.*, 2004).

ICA es un método basado en la *independencia estadística* de los componentes que forman una señal. La independencia estadística es la idea principal de toda la construcción del método, ya que queremos encontrar en nuestras señales mixtas aquellas que son estadísticamente más independientes de las demás (Sandoval, 2014).

La independencia estadística se define como: Sea x_1, x_2, \dots, x_n un conjunto de variables aleatorias con *Función de Densidad de Probabilidad* (PDF, por sus siglas en inglés *Probability Density Function*) $f(x_1, x_2, \dots, x_n)$, estas variables son mutuamente independientes si

$$f(x_1, x_2, \dots, x_n) = f_1(x_1)f_2(x_2) \dots f_n(x_n) \quad (12)$$

donde f_i es la función de densidad marginal de x_i (Figura 3.20).




Figura 3.20 Mezcla de señales independientes con PDF no Gaussiana

Sea $x = [x_1, x_2, \dots, x_n]$ un vector de n componentes, se considera que este vector se produce como una combinación lineal de n señales independientes denotadas por $s = [s_1, s_2, \dots, s_n]$. Se asume que para la implementación del algoritmo que cada una de las señales s_i es estadísticamente independiente de las otras señales, entonces

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n, \quad i = 1 \dots n \quad (13)$$

donde los coeficientes a_{ij} determinan una matriz A que se conoce como la matriz de mezcla, el vector x como vector de mezclas y s el vector de componentes independientes, por lo que podemos definir el sistema como

$$x = As \quad (14)$$

La Figura 3.21 muestra la relación de la ecuación (14).

Consideremos que los componentes de mezcla a_{ij} toman valores que permiten que A sea invertible (Figura 3.21). Existe una matriz W , con coeficientes w_{ij} tales que nos permitirá separar las señales $s_i(t)$ como

$$\begin{aligned} s_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + \dots + w_{1j}x_j(t) \\ s_2(t) &= w_{21}x_1(t) + w_{22}x_2(t) + \dots + w_{2j}x_j(t) \\ &\vdots \\ s_n(t) &= w_{n1}x_1(t) + w_{n2}x_2(t) + \dots + w_{nj}x_n(t) \end{aligned} \quad j = 1..n \quad (15)$$

que podemos definir como

$$y = Wx \quad (16)$$

donde $y \cong s$.

ICA consiste en aplicar un algoritmo que nos permite encontrar la matriz W de tal manera que sea una buena aproximación del vector s (Hyvärinen y Oja, 2000; Sandoval, 2014).

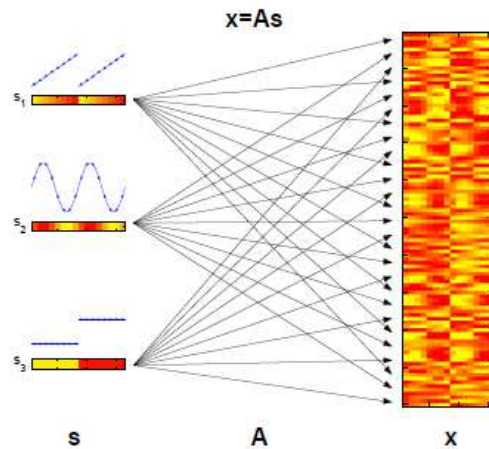


Figura 3.21 Identificación de los elementos de $x = As$ para señales EEG

3.5.5. Multivariate Synchronization Index (MSI)

Propuesto por Zhang (2014) para el reconocimiento de frecuencias en los sistemas BCI-SSVEP. Esta medida caracterizó la sincronización entre los EEG multicanales y las señales de referencia. Estas últimas fueron definidas de acuerdo con la frecuencia de estímulo. Suponiendo que la señal de referencia derivada del estímulo sería sincronizada con las grabaciones de EEG mezcladas; por lo tanto, el estimador S puede proporcionar un índice de sincronización para la detección de frecuencia. El MSI también debe crear una señal de referencia a partir de las frecuencias de estímulo de manera similar a CCA y MEC (Zhang(b) *et al.*, 2014).

Considere un conjunto de datos EEG $X \in R^{M \times P}$ (M número de canales y P número de puntos). Para implementar MSI para el reconocimiento en BCI-SSVEP, se requiere construir la señal de referencia $Y \in R^{2H \times P}$ a una cierta frecuencia de estímulo f_i como

$$R = \begin{cases} \sin(2\pi f_i t) \\ \cos(2\pi f_i t) \\ \vdots \\ \sin(2\pi N_h f_i t) \\ \cos(2\pi N_h f_i t) \end{cases} \quad t = \frac{1}{F_s}, \frac{2}{F_s}, \dots, \frac{T}{F_s} \quad (17)$$

donde N_h denota el número de armónicos y F_s es la tasa de muestreo. Suponiendo que tanto la X como Y han sido normalizadas para tener cero medios y varianzas unitarias. La matriz de correlación C se calcula entonces como

$$C = \begin{bmatrix} C_{xx} & C_{xy} \\ C_{yx} & C_{yy} \end{bmatrix} \quad (18)$$

donde

$$\begin{aligned} C_{xx} &= \frac{1}{P} X X^T \\ C_{yy} &= \frac{1}{P} Y Y^T \\ C_{xy} &= C_{yx} = \frac{1}{P} X Y^T \end{aligned} \quad (19)$$

La matriz C incluye tanto la autocorrelación como la correlación cruzada de X y Y , la autocorrelación influirá en la medida de sincronización (Zhang(b) *et al.*, 2014). Para reducir estas influencias, se aplicó la siguiente transformación lineal

$$U = \begin{bmatrix} C_{xx}^{-1/2} & 0 \\ 0 & C_{yy}^{-1/2} \end{bmatrix} \quad (20)$$

La matriz de correlación transformada es

$$G = UCU^T = \begin{bmatrix} I_{M \times M} & C_{xx}^{-1/2} C_{xy} C_{yy}^{-1/2} \\ C_{yy}^{-1/2} C_{yx} C_{xx}^{-1/2} & I_{2N_h \times 2N_h} \end{bmatrix} \quad (21)$$

donde $I_{M \times M}$ denota la matriz identidad de dimensión M y $I_{2N_h \times 2N_h}$ la matriz identidad de dimensión $2N_h$. La autocorrelación se anula en la ecuación (21) después de la transformación lineal de (20) (Zhang(b) *et al.*, 2014).

El índice de sincronización s entre X y Y puede estimarse como

$$S = 1 + \frac{\sum_{i=1}^P \lambda'_i \log(\lambda'_i)}{\log(P)} \quad (22)$$

donde

$$\lambda'_i = \frac{\lambda_i}{\sum_{i=1}^P \lambda_i} \quad (23)$$

$P = M + 2N_h$, λ_i es el i -ésimo valor propio de la matriz G y λ'_i son los i -ésimos valores propios normalizados. Si el conjunto de señales no está correlacionado $C_{xy} = C_{yx} = 0$ y G será una diagonal. Entonces $\lambda'_i = 1/P$, y como resultado S debe ser cero. En el otro caso, si los dos conjuntos de señales están perfectamente correlacionados, G tendrá unos en la diagonal principal y ceros en otra parte. Sólo

un valor propio normalizado es uno, y los otros valores son ceros. Por lo tanto, S debe ser uno. Para otras situaciones, el valor de S debe estar entre $[0 \ 1]$.

Se asume que hay k frecuencias de estímulo para ser reconocidas. Mediante la construcción de la señal de referencia establecida en cada una de las frecuencias de estímulo, estimamos los índices de sincronización s_1, s_2, \dots, s_k para todas las k frecuencias de estímulo (Zhang(b) *et al.*, 2014). La frecuencia de estímulo f que codifica el objetivo en el que el usuario que mira es la frecuencia que satisface

$$f_t = \max_{f_j}(s_j), \quad j = 1, 2, \dots, k \quad (24)$$

3.5.6. Principal Component Analysis (PCA)

PCA es una técnica de análisis de datos que se remonta a Pearson (1901). Se puede utilizar para comprimir conjuntos de datos de vectores de alta dimensión en los de menor dimensión. Esto es útil, por ejemplo, en la visualización y la extracción de características. PCA ha sido ampliamente utilizado en la literatura: Braack *et al.* (2013) y Nolan *et al.* (2010) para la identificación de artefactos en las señales EEG. Acharya *et al.* (2012), Blankertz *et al.* (2011), Subasi y Gursoy (2010) para la clasificación de señales de EEG. Martis *et al.*, (2012), Sharma *et al.* (2012) y Langley *et al.* (2010), utilizaron PCA en señales ECG. Turnip *et al.* (2011) para extracción de características e señales EEG.

PCA se puede derivar de una serie de puntos de partida y criterios de optimización. Los más importantes son la minimización del error de cuadrado medio en la compresión de datos, la búsqueda de direcciones mutuamente ortogonales en los datos que tienen varianzas máximas y la no correlación de los datos usando transformaciones ortogonales (Ilin y Raiko, 2010).

Supongamos que tenemos n vectores de datos de tamaño $d \times 1$, y_1, y_2, \dots, y_n que son modelados como

$$y_i \approx Wx_j + m \quad (25)$$

donde W es una matriz de $d \times c$, x_j son vectores de $c \times 1$ de los componentes principales, y m es un vector diagonal de $d \times 1$. Se asume que $c \leq d \leq n$. El objetivo es encontrar W, x_j y m tal que el error de reconstrucción, ecuación (26) se minimizado.

$$C = \sum_{j=1}^n \|y_j - Wx_j - m\|^2 \quad (26)$$

En la notación matricial, los vectores de datos y los componentes principales pueden ser calculado en matrices $d \times n$ y $c \times n$. $Y = [y_1, y_2, \dots, y_n]$ y $X = [x_1, x_2, \dots, x_n]$ donde y_{ij} , wy_{ik} y xy_{kj} representan los elementos de las matrices Y , W y X , respectivamente.

La matriz de polarización M contiene n copias del vector de polarización m como sus columnas. Encontrar W y X tales que $Y \approx WX + M$ y la función de costo minimizado es la suma de los elementos cuadrados (o norma de Frobenius) de la matriz $Y - WX - M$, ecuación (27):

$$C = \|Y - WX - M\|^2 \quad (27)$$

Sin más limitaciones, existen infinitas maneras de realizar una descomposición que minimiza (26) o equivalentemente (27). Esto puede observarse que cualquier rotación o escalamiento de W puede compensarse girando o escalando X en consecuencia, dejando el producto WX igual. Sin embargo, el subespacio generado por los vectores columna de la matriz W , llamado subespacio principal, es único (Ilin y Raiko, 2010).

3.5.7. Power Spectral Density (PSD)

El método PSD se utiliza a menudo como un método de detección SSVEP, que se relaciona con el procesamiento de la señal en el dominio de la frecuencia. La implementación del PSD se realiza observando las densidades de potencia alrededor de las frecuencias de estímulo y obteniendo una relación señal/ruido como se muestra en la ecuación (28)

$$S_k = 10 \log_{10} \left(\frac{nP(f_k)}{\sum_{m=1}^{n/2} P(f_k + mf_{res}) + P(f_k - mf_{res})} \right) \quad (28)$$

donde n es el número de puntos cercanos al estímulo de frecuencia, $P(f_k)$ es la densidad de potencia de las frecuencias de estímulo y f_{res} es la frecuencia de resolución, que depende del número de muestras utilizadas en la Transformada de Fourier. $P(f_k + mf_{res})$ y $P(f_k - mf_{res})$ son densidades de potencia alrededor de la frecuencia objetivo (Castillo-García *et al.*, 2014).

3.5.8. Wavelet Transform (WT)

La Transformada Wavelet descompone una señal en un conjunto de funciones básicas llamadas *wavelets*. Estos se obtienen a partir de una única wavelet prototipo, llamada *wavelet madre*. La descomposición de la señal conduce a un conjunto de coeficientes llamados *coeficientes wavelet*. Por lo tanto, la señal puede ser reconstruida como una combinación lineal de las funciones de onda que ponderan los coeficientes wavelet. Con el fin de obtener una reconstrucción exacta de la señal, se debe calcular el número adecuado de coeficientes (Subasi, 2007).

La primera mención del término "wavelet" fue en 1909, en una tesis de Alfred Haar. Jean Morlet y el equipo del Centro de Física Teórica de Marsella, trabajando bajo Alex Grossmann en Francia, propusieron por primera vez el concepto de wavelets en su forma teórica actual. Principalmente Meyer y sus colegas, que han asegurado la difusión de los métodos, han desarrollado los métodos de análisis wavelet (Akin, 2002).

Basicamente wavelet es una función $\psi \in L^2(R)$ con media cero, ecuación (29)

$$\int_{-\infty}^{+\infty} \psi(t)dt = 0 \quad (29)$$

La Transformada de Wavelet Continuo (CWT) de una señal $x(t)$ se define entonces como

$$CWT_{\psi}x(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t)\psi^*\left(\frac{t-b}{a}\right)dt \quad (30)$$

donde $\psi(t)$ se llama wavelet madre, el asterisco (*) denota complejo conjugado, mientras que a y b ($a, b \in R, a \neq 0$) son parámetros de escala, dilatación y traslación, respectivamente. El parámetro de escala a determina la frecuencia oscilatoria y la longitud de la wavelet, y el parámetro de traslación b determina su posición de desplazamiento (Omerhodzic *et al.*, 2013).

La aplicación de WT en áreas de ingeniería generalmente requiere la Transformada Wavelet Discreta (DWT, por sus siglas en inglés *Discrete Wavelet Transform*). El DWT se define mediante el uso de valores discretos del parámetro de escala a y del parámetro de traslación b . Ajustamos $a = a_0^m$ y $b = nb_0a_0^m$, obtenemos

$$\psi_{m,n}(t) = a_0^{-m/2}\psi(a_0^{-m}t - nb_0) \quad (31)$$

$m, n \in Z$ y m está indicando la localización de la frecuencia y n está indicando la localización del tiempo. Generalmente, podemos elegir $a_0 = 2$ y $b_0 = 1$ (Omerhodzic *et al.*, 2012).

DWT analiza la señal en diferentes bandas de frecuencias, mediante la descomposición de la señal en diferentes resoluciones. DWT emplea dos conjuntos

de funciones llamadas *funciones de escalado* y *funciones de onda*, que están relacionadas con los filtros de paso bajo y de paso alto, respectivamente. La descomposición de la señal en las diferentes bandas de frecuencia se obtiene simplemente mediante filtrados pasos altos y paso-bajos consecutivos del dominio del tiempo (Subasi, 2007).

El procedimiento de descomposición multi-resolución de una señal $x[n]$ se muestra esquemáticamente en la Figura 3.22. Cada etapa de este esquema consiste en dos filtros digitales y dos mostradores descendentes (*down-samplers*) por dos. El primer filtro, $h[\cdot]$ es la wavelet madre discreta, de paso alto al natural, y la segunda, $g[\cdot]$ es su versión reflejo, de paso bajo al natural. Las salidas de muestreo de los primeros filtros de paso alto y paso bajo proporcionan el detalle, D1 y la aproximación A1, respectivamente. La primera aproximación A1 se descompone más y este proceso se continúa. Los coeficientes wavelet extraídos proporcionan una representación compacta que muestra la distribución de energía de la señal EEG en tiempo y frecuencia (Subasi, 2007).

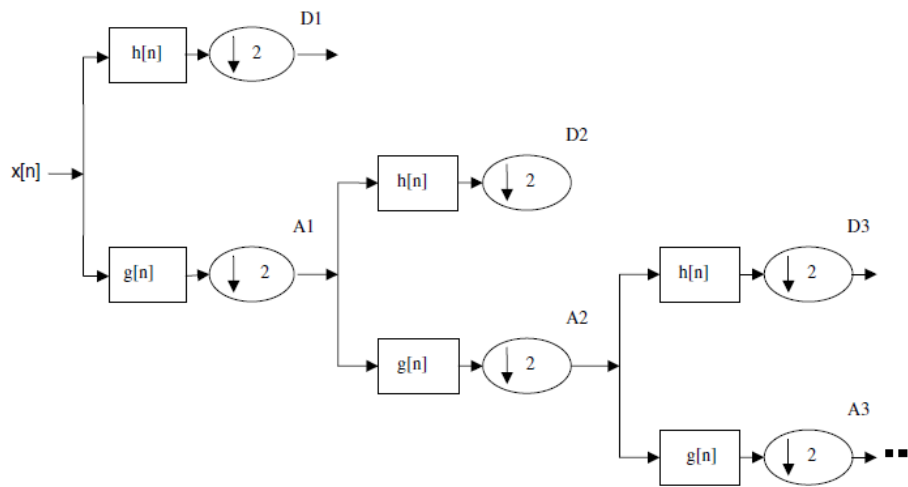


Figura 3.22 Descomposición de sub-bandas.

El algoritmo Wavelet proporciona una manera de representar una frecuencia de tiempo en una ventana variable de tamaño determinado. Las ventajas de usar la transformación wavelet son porque este tipo de transformación puede capturar las

características transitorias en una señal dada y proporcionar la correspondiente información de frecuencia de tiempo. Los diferentes tipos de familias de wavelet se muestran en la Tabla 3.5. Las familias de wavelet tales como Haar, Daubechies, Symlets y Coiflets tienen propiedades suficientes para analizar la adquisición de la señal. Las familias de wavelets Morlet y Sombrero Mexicano no pueden revelar completamente las características esenciales para las áreas biomédicas (Tumari *et al.*, 2013).

No	Familias Wavelet	Descripción
1	Morlet (<i>mor1</i>)	Esta wavelet no tiene función de escala, pero es explícita.
2	Mexican Hat (<i>mexh</i>)	Esta wavelet no tiene función de escala y se deriva de una función que es proporcional a la segunda función derivada de Gaussiana
3	Meyer (<i>meyr</i>)	La función de escala se define en el dominio de la frecuencia.
4	Haar (<i>haar</i>)	Discontinuo y se asemeja a una función escalonada. Haar se representan como Daubechies db1.
5	Daubechies (<i>dbN</i>)	La más utilizada por los investigadores
6	Symlets (<i>symN</i>)	Esta wavelet es una modificación de la familia db.
7	Coiflets (<i>coifN</i>)	Construido por I. Daubechies que tiene $2N$ momentos.
8	Splines biorthogonal wavelets (<i>biorNr.Nd</i>)	Esta wavelet necesita dos wavelets para la reconstrucción de la señal y la imagen.

Tabla 3.5 Familias Wavelet

La banda de frecuencias $[f_m/2 : f_m]$ de cada escala de detalle del DWT está directamente relacionada con la velocidad de muestreo de la señal original, dada por $f_m = f_s/2^{l+1}$ donde f_s es la frecuencia de muestreo y l el nivel de descomposición (Tabla 3.6). Las wavelets de Daubechies son las wavelets más populares que representan las bases del procesamiento de señales wavelet, y se utilizan en numerosas aplicaciones (Omerhodzic *et al.*, 2013).

Descomposición de señales	Banda de Frecuencia (Hz)	Nivel de descomposición
D1	43.4-86.8	1 (ruido)
D2	21.7-43.4	2 (gamma)
D3	10.8-21.7	3 (beta)
D4	5.40-10.8	4 (alpha)
D5	2.70-5.40	5 (theta)
A5	0.00-2.70	5 (delta)

Tabla 3.6 Bandas de frecuencias de los diferentes niveles de descomposición de DWT.

3.6. Algoritmos de inteligencia de enjambre

La familia de algoritmos de Inteligencia de enjambre son modelos computacionales inspirados en el comportamiento colectivo de grupos sociales naturales. Recientemente los trabajos de investigación basados en SI han aumentado considerablemente para la obtención de soluciones aproximadas a problemas de optimización en una cantidad razonable de tiempo de cálculo. Se describen los algoritmos más representativos de SI, a saber, Optimización de Colonias de Hormigas (ACO, por sus siglas en inglés *Ant Colony Optimization*) y Optimización de Enjambre de Partículas (PSO, por sus siglas en inglés *Particle Swarm Optimization*) y Colonia de Abejas Artificial (ABC, por sus siglas en inglés *Artificial Bee Colony Algorithm*). En este trabajo nos centraremos principalmente en ACO y PSO.

3.6.1. Algoritmos de Optimización de Colonia de Hormigas

Las colonias de hormigas, y de manera más general las sociedades de insectos sociales, a pesar de la sencillez de sus individuos, presentan una organización social altamente estructurada.

Como resultado de esta organización, las colonias de hormigas pueden realizar tareas complejas que en algunos casos superan con creces las capacidades individuales de una sola hormiga. El campo de los "algoritmos de hormigas" son modelos de estudios derivados de la observación del comportamiento de las hormigas reales, y utiliza estos modelos como fuente de inspiración para el diseño de nuevos algoritmos para la solución de optimización y problemas de control distribuido.

La idea principal es que los principios de auto-organización que permiten el comportamiento altamente coordinado de las hormigas reales pueden ser explotados para coordinar las poblaciones de agentes artificiales que colaboran para resolver problemas computacionales. Varios aspectos diferentes del comportamiento de las colonias de hormigas han inspirado diferentes tipos de algoritmos de hormigas. Ejemplos búsqueda de alimento, división del trabajo, la clasificación de cría, y el transporte cooperativo. En todos estos ejemplos, las

hormigas coordinan sus actividades a través de una forma de comunicación indirecta mediada por modificaciones del medio ambiente (llamado stigmergy). En la búsqueda de alimento la hormiga deposita una sustancia química (feromona) en el suelo lo que aumenta la probabilidad de que otras hormigas seguirán el mismo camino. Los biólogos han demostrado que muchos de los comportamientos observados a nivel de colonia de insectos sociales pueden explicarse a través de modelos bastante simples en las que sólo la comunicación indirecta (stigmergy) está presente. La idea detrás de los algoritmos de hormigas es usar alguna forma de stigmergy artificial para coordinar las sociedades de agentes artificiales (Dorigo y Stützle, 2004).

Los algoritmos de optimización por colonias de hormigas (ACO por sus siglas en inglés *Ant Colony Optimization*) es un tipo de metaheurística que simula el comportamiento social de enjambres de insectos para resolver problemas de optimización y están inspirado en el comportamiento de “forrajeo” de las colonias de hormigas, (Figura 3.23). La Tabla 3.7 muestra los orígenes de los algoritmos de hormigas y sus diferentes modificaciones (Das *et al.*, 2008).

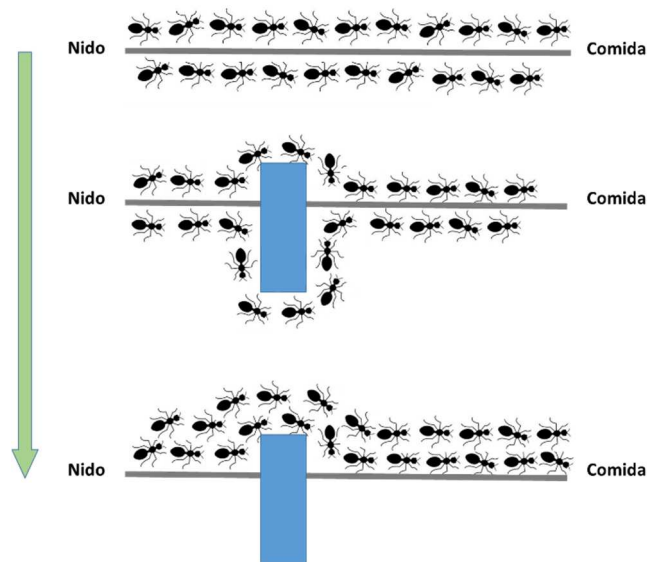


Figura 3.23 Representación de la optimización del “forrajeo” a través del tiempo

Algoritmo	Referencias
Sistema de Hormigas (AS, Ant System)	<i>Dorigo et al.</i> (1992) <i>Dorigo, Maniezzo y Coloni</i> (1991, 1996)
Sistema de Hormigas elitista (EAS, Elite AS)	<i>Dorigo et al.</i> (1992) <i>Dorigo, Maniezzo y Coloni</i> (1991, 1996)
Sistema de Colonia de Hormigas (ACS, Ant Colony System)	<i>Dorigo y Gambardella</i> (1997)
Sistema de Hormigas Max-Min (MMAS)	Stützle y Hoos (1996, 2000) Stützle (1999)
Sistema de Hormigas por Ordenación (OAS)	Bullnheimer, Hartl y Strauss (1997, 1999)
Hormigas	Maniezzo (1999)
Sistema de Hormigas Hiper-Cubo (Hyper Cube AS)	Blum, Roli y <i>Dorigo</i> (2001) Blum y <i>Dorigo</i> (2004)
Sistema de la mejor peor Hormiga (BWAS Best Worst AS)	Cordón <i>et al.</i> (2000)
Clasificación de Hormigas (Ranked AS)	Bullnheimer, Hartl, y Strauss (1997)
Ant-Q	Gambardella y <i>Dorigo</i> (1995)
Base poblacional ACO (Population based ACO)	Guntsch y Middendorf (2002)
Beam ACO	Blum (2005, 2008)
Omicron ACO (OA)	Gómez y Barán (2004)
Hormigas Iterativas (IA)	Wiesemann y Stützle (2006)
Cunning Ants (cAS)	Tsutsui (2006)
Agrupamiento de colonia de hormigas (AntClust)	Labroche, Monmarché y Venturini (2002)
Agrupamiento estándar de hormigas (SACA, Standard Ant Clustering Algorithm)	Lumer y Faieta (1994)
Búsqueda aproximada de árboles no determinísticos (ANTS, Approximate Nondeterministic Tree Search)	Maniezzo (1998)

Tabla 3.7 Algoritmos basados en colonia de Hormigas

3.6.2. Sistema de hormigas (AS)

El primer algoritmo propuesto dentro de la metaheurística ACO fue el Sistema de hormigas (AS, por sus siglas en inglés *Ant System*) para resolver el problema del agente viajero (TSP, por sus siglas en inglés *Travelling Salesman Problem*). De manera general, en el algoritmo AS, se posiciona un número de hormigas k en cada nodo. Cada hormiga construye una solución factible al problema, al aplicar de manera iterada la siguiente regla de transición que combina τ y η para elegir con cierta probabilidad p_{ij} la siguiente ciudad j a visitar desde la ciudad i .

$$p_{ij}^k = \begin{cases} \frac{\tau_{ij}^\alpha \eta_{ij}^\beta}{\sum_{u \in N_i^k} \tau_{iu}^\alpha \eta_{iu}^\beta} & \text{si } j \in N_i^k \\ 0 & \text{en otro caso} \end{cases} \quad (32)$$

donde los parámetros α y β , determinan la importancia de la feromona y la información heurística, respectivamente. Por otro lado η_{ij} , es el recíproco de la

distancia entre i y j , τ representa la cantidad de feromona depositada por la hormiga. Una vez que todas las hormigas han construido un tour completo, actualizan la feromona, de acuerdo a la ecuación (33)

$$\tau_{ij} = (1 - \rho)\tau_{ij} + \sum_{k=1}^m \Delta\tau_{ij}^k \quad (33)$$

donde ρ es la tasa de evaporación, m es el número de hormigas, y $\Delta\tau_{ij}^k$ es la cantidad de feromona depositada en el arco (i, j) por la hormiga k . $\Delta\tau_{ij}^k$ se calcula como Q/L_k , con L_k que representa la longitud del tour construido, si (i, j) pertenece al tour hecho por la hormiga k es cero en otro caso. (Mancera-Galván, 2015; Adubi 2014).

3.6.3. Algoritmos de Optimización de Enjambre de Partículas (PSO)

PSO fue Desarrollado por Eberhart y Kennedy (1995), como un método de optimización para funciones no lineales en espacios continuos y discretos, basado en la simulación de un modelo social simple del desplazamiento de cardúmenes o bandadas, Figura 3.24 (Kennedy y Eberhart, 1997). En un sistema PSO la búsqueda se realiza utilizando una población de partículas que corresponden a los individuos, cada uno de los cuales representa una solución candidata al problema. Las partículas cambian su estado al "volar" a través del espacio de búsqueda hasta que se ha encontrado un estado relativamente estable Figura 3.25a (Muñoz *et al.*, 2008).

Cada partícula "vuela" a través del espacio de búsqueda de acuerdo a su propio vector de velocidad. En un algoritmo de PSO los vectores de velocidad de las partículas se ajustan en cada iteración del algoritmo. Para el nuevo vector de velocidad de una partícula, su mejor posición personal y también la mejor posición global es la mejor posición global encontrada hasta el momento en que las partículas actúan como atractores (Figura 3.25b).




Figura 3.24 Representación de un enjambre de partículas

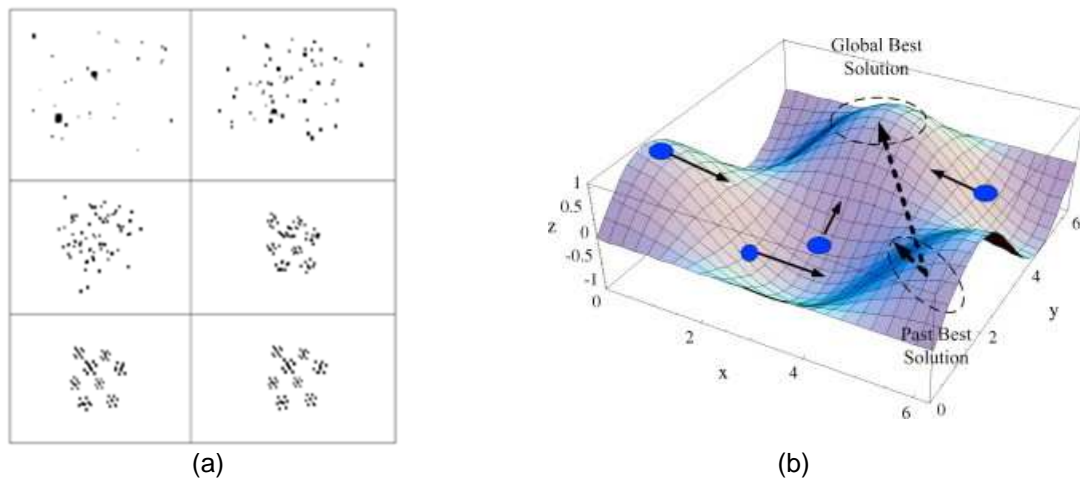


Figura 3.25 Optimización de enjambre de partículas. (a) Wahab, 2015 (b) Biswas, 2016.

En PSO, la i -ésima partícula es tratada como un punto dentro de un espacio N -dimensional, representada por $X_i = (x_{i1}, x_{i2}, \dots, x_{iN})$. La mejor posición encontrada por la partícula anteriormente, o sea aquella donde se obtuvo el mejor valor en la función de costo, es representada como $p_i = (p_{i1}, p_{i2}, \dots, p_{iN})$. La mejor posición encontrada por el total de la población es representada por el símbolo g . La tasa de cambio de posición (velocidad) para una partícula i es representada como $v_i = (v_{i1}, v_{i2}, \dots, v_{iN})$. Las partículas son manipuladas de acuerdo a las ecuaciones (34) y (35), donde c_1 y c_2 son dos constantes positivas, R_1 y R_2 son dos

números aleatorios en el rango de [0 1], (Ab Wahab *et al.*, 2015) y w es el peso inercial.

$$v_{in}(t + 1) = w \cdot v_{in}(t) + c_1 \cdot R_1 \cdot (p_{in} - x_{in}(t)) + c_2 \cdot R_2 \cdot (p_{gn} - x_{in}(t)) \quad (34)$$

$$x_{in}(t + 1) = x_{in}(t) + v_{in}(t + 1) \quad (35)$$

La ecuación (34) es utilizada para calcular la nueva velocidad de la partícula de acuerdo a su velocidad anterior y las distancias de su posición actual a su mejor posición y la mejor posición dentro del grupo. Luego la partícula se desplaza hacia una nueva posición de acuerdo a la ecuación (35). El peso inercial w , formulado por Shi y Eberhart (1998), es utilizado para controlar el impacto de las velocidades previas en la velocidad actual, influenciando el cambio entre las habilidades de exploración global (rango amplio) o local (rango corto) de las partículas (Muñoz *et al.*, 2008).

Una característica de los algoritmos PSO es que sus capacidades globales y locales de exploración pueden equilibrarse fácilmente mediante el ajuste de la influencia relativa de mejor solución local y solución global durante la actualización de la velocidad (Merkle y Middendorf, 2008). Un sistema PSO combina un modelo “únicamente social”, el cual sugiere que los individuos ignoran su propia experiencia y ajustan su conocimiento de acuerdo a las creencias exitosas de los individuos en la vecindad; y un modelo “únicamente cognitivo”, el cual trata a los individuos como seres aislados (Muñoz *et al.*, 2008). La influencia de la mejor posición personal se considera como el aspecto cognitivo del comportamiento de las partículas, mientras que la influencia de la mejor posición global es considerada como el aspecto social.

4. RESULTADOS Y DISCUSIÓN

4.1. Experimentación

En la presente investigación se implementaron los algoritmos de inteligencia de enjambre como herramientas para optimizar señales obtenidas por EEG para mejorar el desempeño de los sistemas BCI basados en SSVEP. Se utilizaron el equipamiento y los materiales descritos en la sección 3.2. El proceso para la obtención de las señales EEG se basó en el protocolo de pruebas descrito en el apéndice “B”. Se implementó un sistema de pruebas basado en las metodologías descritas en la sección 3.4.3 y 3.4.4 para sistemas BCI-SSVEP.

Durante las pruebas experimentales, los sujetos de estudio fueron sentados en una silla cómoda a 70 cm de un monitor estándar de 15 pulgadas LCD (con una resolución de pantalla de 1024x768 y una tasa de actualización de 60 Hz). El sistema de pruebas experimental se aplicó a 29 voluntarios sanos, 17 hombres y 12 mujeres, con edades entre 20-29 y 48-50, participaron en el experimento. 17 de ellos con visión normal y 12 con visión corregida, los voluntarios no tenían experiencia previa con experimentos en sistemas BCI. Todos los participantes dieron su consentimiento informado después de una explicación completa del protocolo experimental. Los resultados de las pruebas se muestran en la base de datos anexa en el apéndice “B”.

De las 14 señales obtenidas en cada prueba durante el experimento, únicamente se seleccionaron de cada prueba los electrodos O1 y O2, ubicados en la parte occipital del cuero cabelludo, ya que son los que están directamente relacionados con la actividad visual.

4.2. Modelo Propuesto

La selección de características puede servir como una herramienta de pre-procesamiento de gran importancia antes de resolver los problemas de clasificación. El propósito de la selección de la función es reducir el número máximo de características irrelevantes manteniendo una precisión de clasificación aceptable. La selección de características es de considerable importancia en la clasificación de patrones, análisis de datos, recuperación de información multimedia, biometría,

monitoreo a distancia, visión por computadora, procesamiento de datos médicos, aprendizaje automático y aplicaciones de minería de datos. Entre los diferentes métodos propuestos para la extracción de características, los métodos de SI pretenden lograr mejores soluciones usando el conocimiento de iteraciones anteriores sin conocimiento previo de características de los datos a analizar (Ghanbari *et al.*, 2014).

Este trabajo presenta el uso de algoritmos de inteligencia de enjambre como un método confiable para la optimización de las señales EEG para la mejorar el desempeño del BCI-SSVEP. Se propone utilizar los algoritmos ACO y PSO descritos en la sección 3.6.2 y 3.6.3, respectivamente, como herramientas de mejora para en la selección de las características de las señales cerebrales y facilitar la detección de eventos basados en estímulos visuales. Como modelo de referencia utilizamos el método de ICA descrito en la sección 3.5.4, el cual se ha utilizado en investigaciones recientes para la extracción y la detección de datos relevantes o no-relevantes de las señales eléctricas del cerebro, así como la recolección de información sobre la respuesta a una estímulo separando las señales que se generaron de forma independiente en ciertas zonas del cerebro.

La Figura 4.1 muestra el modelo ICA básico utilizado por los investigadores en los sistemas BCI y en la Figura 4.2 el diagrama de flujo del modelo propuesto. Tanto el modelo AS como el modelo PSO se analizarán de manera independiente ya que debido a la naturaleza propia del algoritmo AS éste genera una única señal optimizada independientemente del número de señales que se utilicen para su creación, Figura 4.3. En el caso de PSO se obtienen dos señales optimizadas, una por cada electrodo debido a que cada electrodo representa una población de partículas y cada población obtiene una única solución Figura 4.4.




Figura 4.1 Modelo ICA para BCI

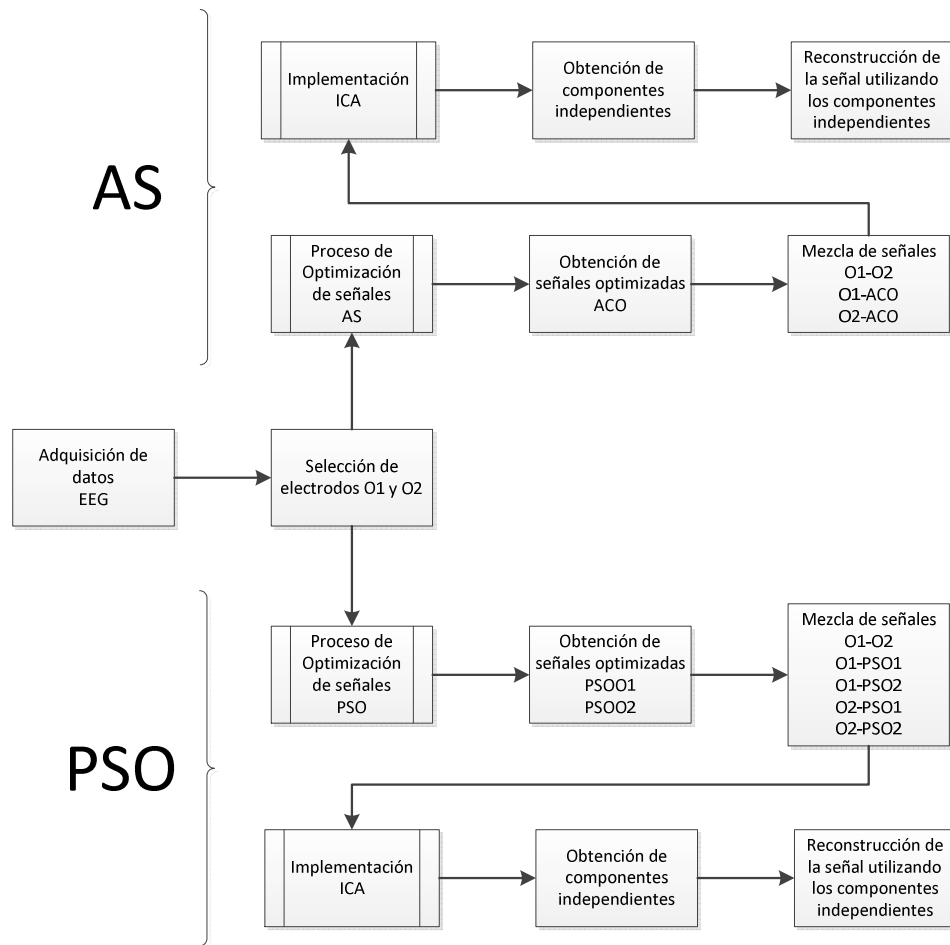


Figura 4.2 Diagrama de flujo del modelo propuesto.




Figura 4.3 Esquema de optimización ACO




Figura 4.4 Esquema de Optimización PSO

4.3. Algoritmos

Para la implementación de los algoritmos se consideró que cada señal EEG como una serie de tiempo $X(n) = (x_1, x_2, \dots, x_N)$, con una longitud N . Para ilustrar las series de tiempo mediante representación gráfica, se utiliza un modelo bidimensional para reflejar cada dato en un punto particular del espacio. El eje x representa el tiempo t , que es el índice de los datos, y el eje y representa los datos x_t . Después de trazar, el espacio bidimensional muestra un diagrama formado por N puntos que están dispuestos por tamaños de índice, como se muestra en la Figura 4.5 (Weng y Liu, 2006). El objetivo de los algoritmos es encontrar una serie de tiempo nueva (señal optimizada) que tenga las características fundamentales de la señal original pero que permita un mejor desempeño en el procesamiento de la misma.




Figura 4.5 Serie de tiempo y su proyección

4.3.1. Algoritmo de Sistema de Hormigas (AS)

Para la optimización de las señales EEG por medio del algoritmo AS se tomó como base resolver el problema de optimización del TSP (Gambardella y Dorigo, 1995, 1997; Dorigo y Gambardella 1996; Stützle, y Dorigo, 1999, 2002; Maniezzo *et al.*, 2004, Blum 2005; Weng y Liu, 2006; Kang y Cao, 2010 Aggarwal *et al.*, 2012).

Consideramos a cada señal EEG como un camino y cada punto de la señal como una ciudad, el inicio de la señal como la ciudad inicial (nido) y el último punto como la ciudad destino final, la señal optimizada está representada por la ruta realizada en el TSP. Haciendo la análoga con ACO (Figura 3.23), el nido está representado por el inicio de las señales y el alimento por el término de la señal. Las señales representan los posibles caminos de las hormigas, la decisión de una hormiga de tomar un camino u otro está representado para cruces entre las señales, la hormiga tomará el camino más transitado (más corto) con base a aquel que tenga mayor rastro de feromona. El camino final que tomarán las hormigas es el camino más corto entre el nido y el alimento y representará nuestra señal optimizada. La Figura 4.6 muestra un esquema del proceso, donde el punto A representa el nido y el punto B representa el alimento, las flechas indican la ruta óptima.




Figura 4.6 Esquema del proceso AS, (Johann Dréo, 2006).

La razón detrás de aplicar el algoritmo ACO en la segmentación de series de tiempo es encontrar una ruta con el menor costo de N puntos entre x_0 y x_{N-1} , con el fin de conectar todos los puntos. La ruta completa pasará $K - 1$ puntos para dividir la serie de tiempo entero en K segmentos. Cada vez que una hormiga alcanza un punto, este punto será tratado como el final de un nuevo segmento. Sin embargo, antes de determinar qué camino tomar, una hormiga puede visitar cualquier punto que desee, por lo que cualquier hormiga puede estar en cualquier punto y caminar cualquier camino que conecta su actual ciudad a la siguiente. Se considera que hay un punto de conexión entre cada dos puntos y cada trayecto conectivo es unidireccional, lo que sólo permite que un punto con un valor índice menor dé lugar a un punto con un valor de índice mayor como se muestra en la Figura 4.7 (Weng y Liu, 2006).




Figura 4.7 La ruta de desplazamiento del algoritmo ACO

Al aplicar AS al TSP (en el instante t), cada hormiga elige aleatoriamente una ciudad como punto de partida y luego usa un valor de probabilidad para elegir la ciudad siguiente a visitar. Cuando el tiempo es $t + 1$, cada hormiga visita la ciudad al lado del punto de partida. Cuando una hormiga visita una ciudad, esa ciudad se pone en las ciudades visitadas. Cuando el tiempo alcanza $t + N$, todas las hormigas deben terminar el recorrido y regresar al punto de partida, que es el final de un ciclo. Cada vez que se termina un ciclo, se registra la cantidad de feromona que se deja una hormiga en cada trayectoria, lo que también indica el número de hormigas que han recorrido un camino determinado. También se registra la fuerza total de la feromona

en cada trayectoria. Este algoritmo se repite hasta que todas las hormigas están en la misma trayectoria, o hasta que el número de ciclos alcanza el valor de umbral preestablecido del usuario. Por lo tanto, cuanto más larga una hormiga viaja, más débil será la fuerza de la feromona en cada trayectoria conectiva. En contraste, cuanto más corta una hormiga viaja por un camino, más fuerte se convierte en la feromona residual. Por lo tanto, las hormigas que viajan más segmentos dejan menos feromonas (Weng y Liu, 2006). El diagrama de flujo de la implementación del algoritmo AS se muestra en la Figura 4.8.

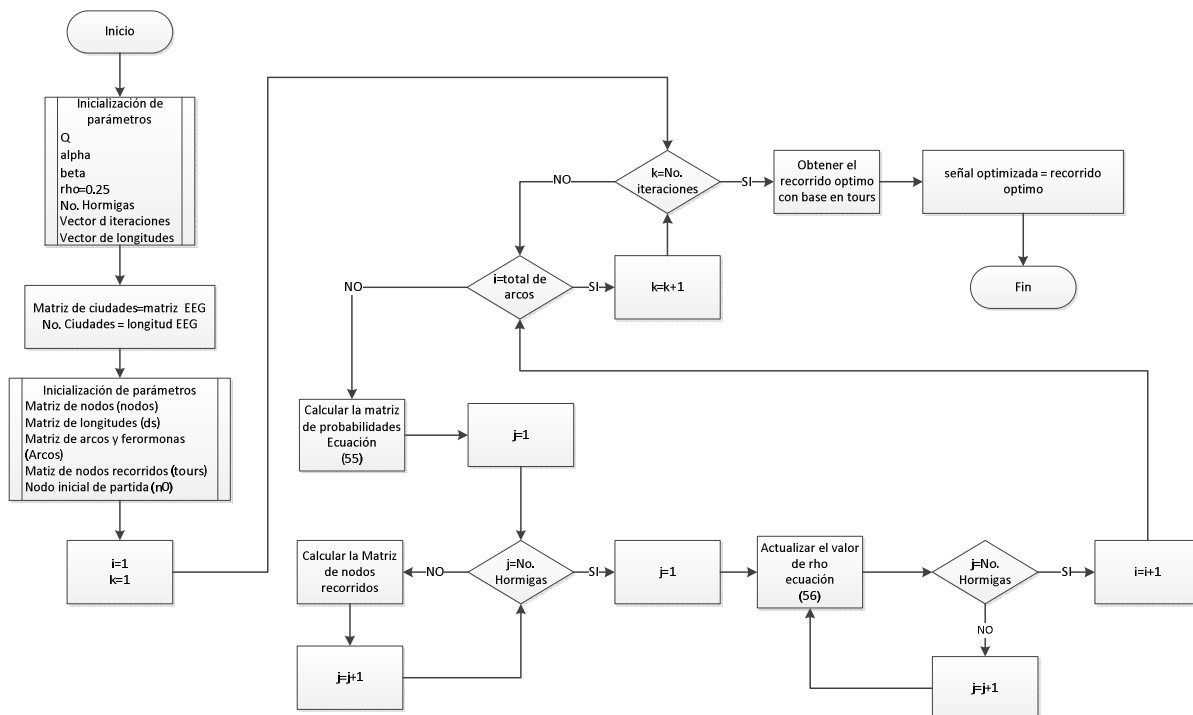


Figura 4.8 Diagrama de Flujo de la Implementación del algoritmo AS

Para la realización de la simulación de los procesos, se seleccionó un sujeto de la base de datos obtenida por los experimentos descritos en la sección 3.4.4. En la Figura 4.11 mostramos el resultado del proceso de optimización basado en las señales originales que se muestran en la Figura 4.9 y Figura 4.10.




Figura 4.9 Señales EEG originales. Representación de toda la prueba






Figura 4.10 Señales EEG originales. Segmento de 5 s.



(a)



(b)

Figura 4.11 Señales optimizadas. (a) Representación de toda la prueba. (b) Segmento de 5 s.

Para la implementación del modelo AS se realizaron simulaciones con diferentes cantidades de hormigas (10, 20, 50) y con iteraciones para los recorridos de 5 y 10, para ver el comportamiento sobre los resultados de optimización. En la Figura 4.12, donde el eje *y* derecho representa el tiempo y el eje *y* izquierdo representa la distancia, podemos observar que el tiempo de recorrido aumenta exponencialmente con base a la cantidad de hormigas utilizadas, por lo que el costo computacional es mayor con base al aumento en el número de hormigas utilizadas en el proceso de optimización, independientemente del número de iteraciones que se realizaron (10 iteraciones 4.12a, 5 iteraciones 4.12b). En la Figura 4.13 se muestra la distancia total recorrida por el proceso de optimización, donde observamos que para 10 recorridos siempre la distancia disminuye independientemente del número de hormigas a utilizar en el proceso. En el caso de 5 recorridos con 50 hormigas, la distancia va disminuyendo de forma continua durante todos los recorridos, en los otros casos al término de los recorridos la distancia aumenta. Sin embargo, la diferencia entre las distancias recorridas en ambos casos es del 1% (con base al promedio de la desviación estándar de as distancia total recorrida), por lo que, consideramos que la distancia no es un factor para el proceso de optimización y el costo computacional si es un factor importante a considerar. Para el propósito del presente trabajo se consideró utilizar las señales optimizadas con los parámetros de 20 hormigas y 5 recorridos.





Figura 4.12 Costo Computacional de AS. (a) 10 Iteraciones. (b) 5 Iteraciones.



(a) (b)
 Figura 4.13 Distancia total recorrida. (a) 10 Iteraciones. (b) 5 Iteraciones

La siguiente etapa del modelo propuesto es la implementación del modelo ICA (Figura 4.14) utilizando las señales originales EEG (identificadas como O1/O2) y la señal optimizada con AS (identificada como ACO-O1O2), para obtener los componentes principales y finalmente hacer la reconstrucción de la señal con base a los componentes encontrados.




Figura 4.14 Modelo ICA-AS

La representación de la mezcla de las señales así como el histograma (representación PDF de las señales) se muestran en la Figura 4.15 y Figura 4.16 respectivamente. La Figura 4.17 muestra los componentes independientes (IC1, IC2) obtenidos por el proceso ICA.

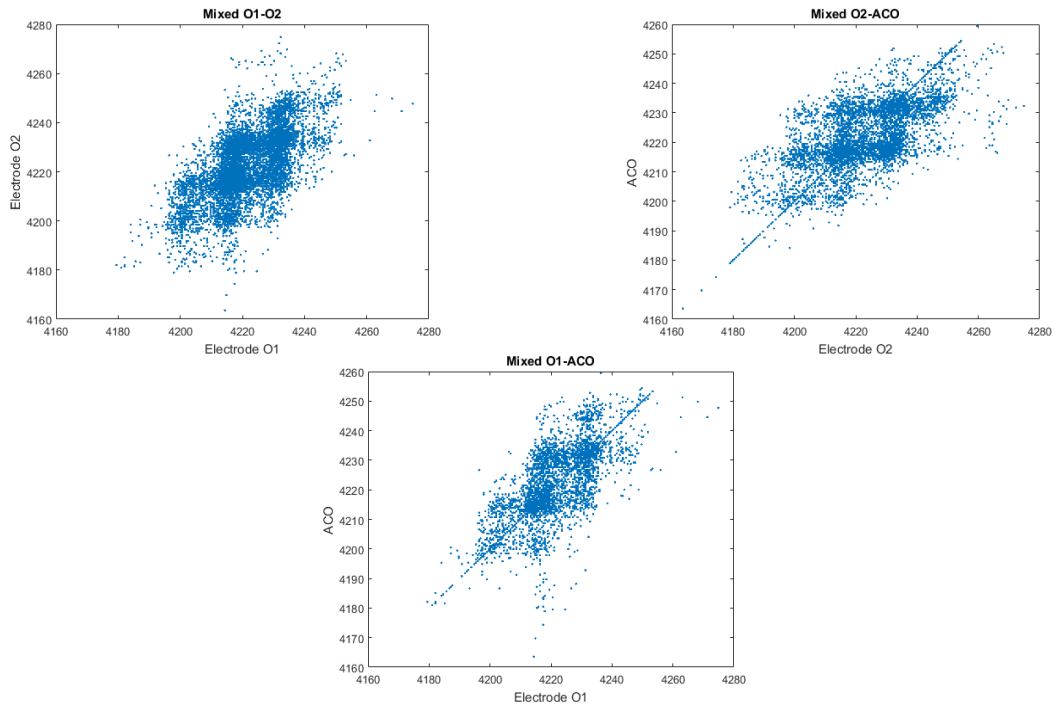


Figura 4.15 Representación de las mezclas.

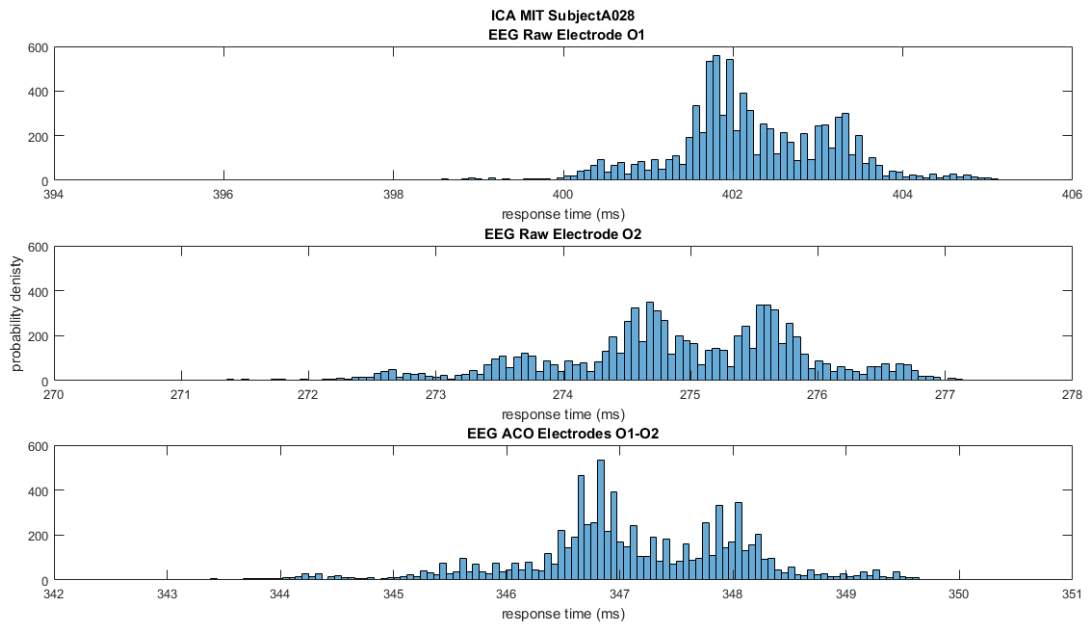


Figura 4.16 Función de densidad de probabilidad

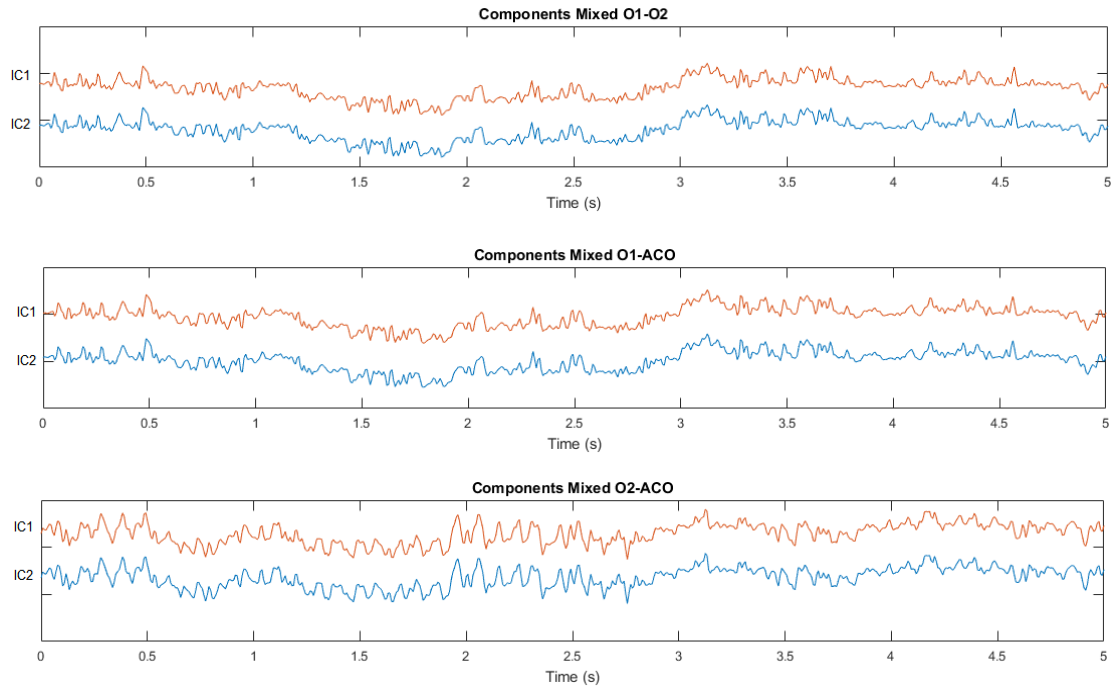


Figura 4.17 Componentes Independientes ICA-ACO

La Figura 4.18 muestra las señales originales y la señal reconstruida (*extracted*), la cual se obtiene con base a los componentes independientes obtenidos por el proceso ICA ($extracted = IC1 + IC2$). Podemos observar que para el presente ejemplo, la reconstrucción del electrodo O1 es muy similar al original; en el caso de O2 podemos apreciar la pérdida de algunos elementos de la señal original.




Figura 4.18 Señal original vs señal reconstruida, mezcla O1-O2

La comparación de la señal original con la señal reconstruida a partir de las mezclas de las señales originales con la señal optimizada se muestra en la Figura 4.19 y Figura 4.20. Podemos observar en ambos casos menos pérdida de elementos en las señales reconstruidas de ambos electrodos.




Figura 4.19 Señal original vs señal reconstruida, mezcla O1-ACO




Figura 4.20 Señal original vs señal reconstruida, mezcla O2-ACO.

Después del proceso ICA-ACO, podemos observar en los histogramas de la actividad de los componentes independientes (IC1 lado izquierdo en la figura, IC2 lado derecho en la figura) de la Figura 4.21, como en el componente IC2 la dispersión es mucho menor en el caso de las mezclas con ACO; en el caso del componente IC1 la dispersión es similar. Podemos interpretar que las mezclas con ACO concentran más elementos de la señal.

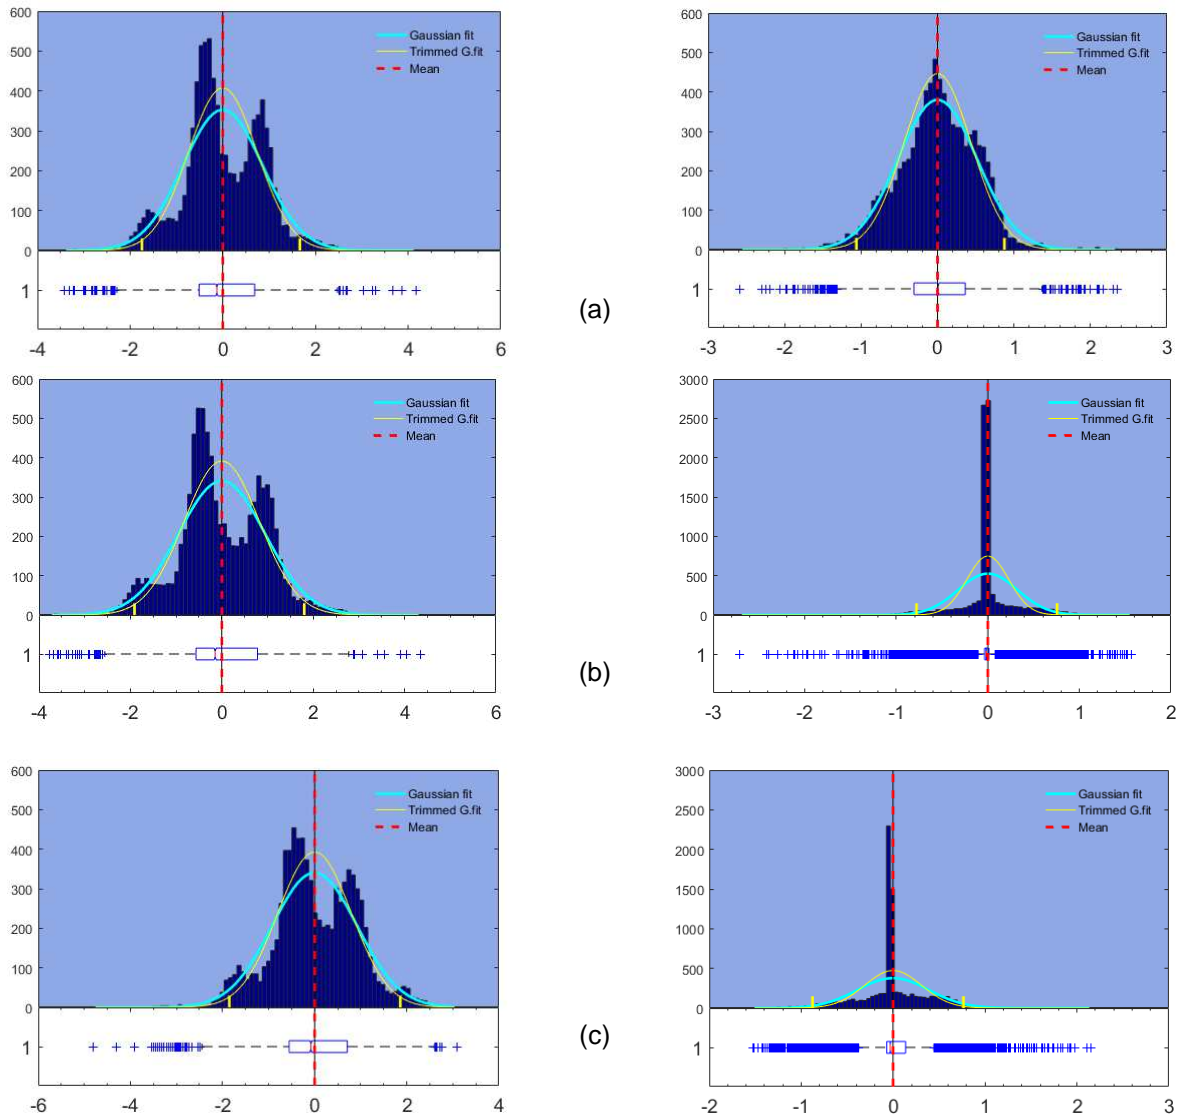


Figura 4.21 Histograma PDF normalizado de los componentes.
 (a) Mezcla O1-O2. (b) Mezcla O1-ACO. (c) Mezcla de O2-ACO

La Figura 4.22 muestra el PSD para los componentes de señal y para cada electrodo para las mezclas de estudio. Específicamente para la frecuencia, correspondiente a los estímulos realizados durante la prueba (0.895 Hz). El PSD en el componente IC1 se comporta de manera similar para O1 en todas las mezclas; Sin embargo, para O2 la potencia es mayor para las mezclas con ACO. Cuanto mayor sea la potencia, mayor será la probabilidad de encontrar la frecuencia del estímulo.

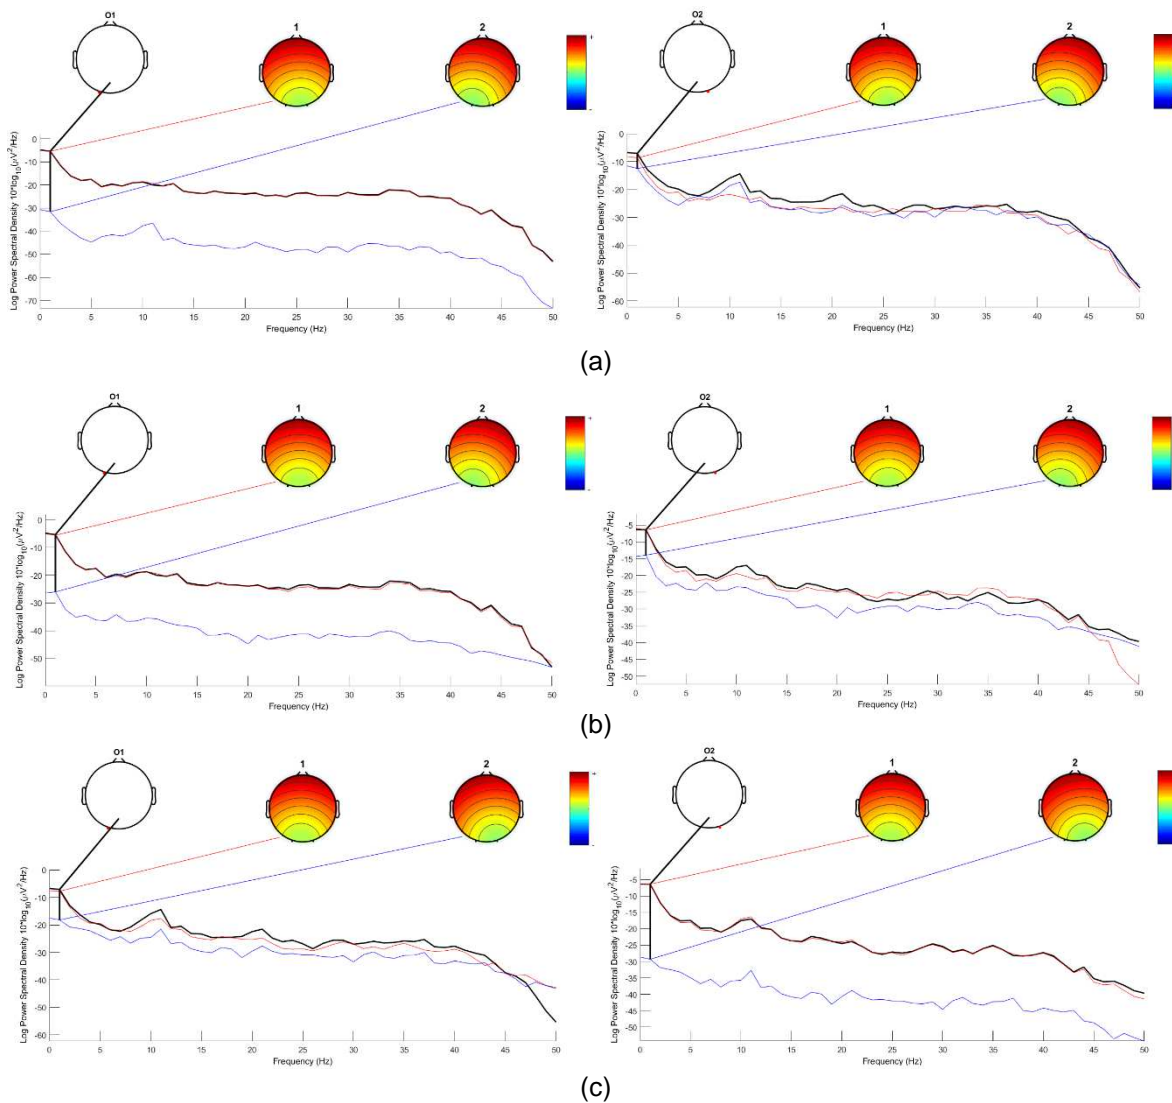


Figura 4.22 PSD de los canales y componentes.
 (a) Mezcla O1-O2. (b) Mezcla O1-ACO. (c) Mezcla O2-ACO

En la Figura 4.23 observamos la frecuencia del estímulo (0.895 Hz, línea roja), así como sus armónicos (1.79, 2.685, 3.58,... Hz, líneas negras) los cuales están presentes en todas las señales generadas por el estudio, lo que implica que los componentes conservan una de las características principales de la señal. Los espectrogramas de la Figura 4.24 muestran la identificación de la frecuencia del estímulo. Podemos observar que la potencia de la señal tiene a 0 alrededor de la frecuencia de estímulo, lo cual permite identificarla de una manera precisa.




Figura 4.23 Representación del PSD. Señales originales y componentes.

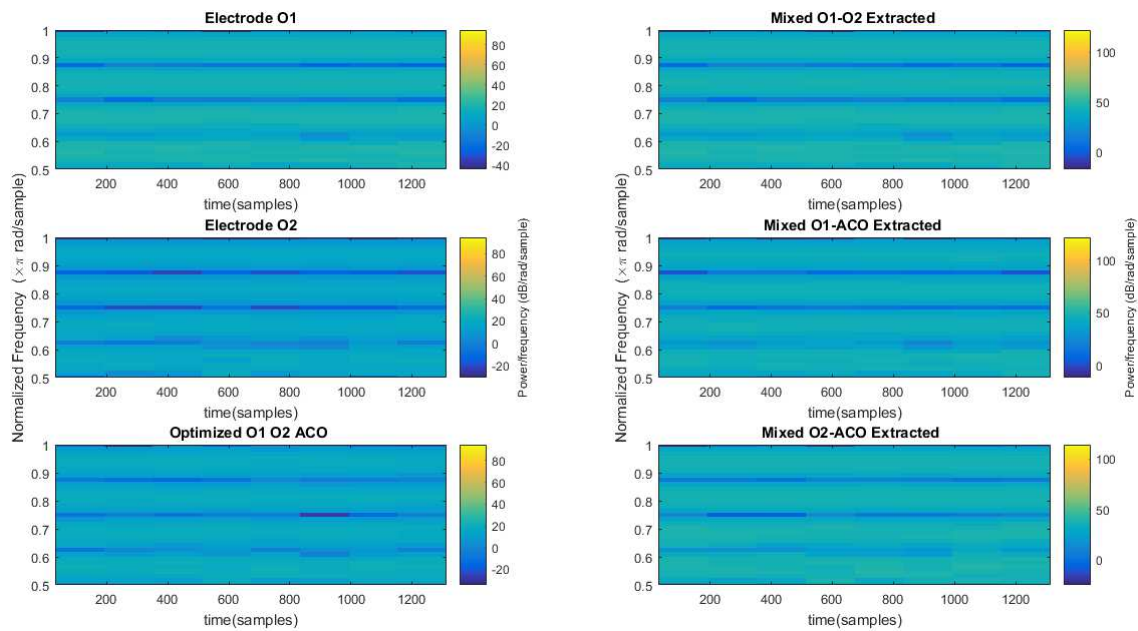


Figura 4.24 Identificación de la frecuencia de estímulo

La Tabla 4.1 muestra los resultados obtenidos de la implementación del modelo ICA-ACO a todos los sujetos del experimento. La columna ORIGINAL representa la mezcla de las señales originales y la columna EXTRACT de las señales

reconstruidas a partir de componentes independientes. Los valores mostrados representan la correlación entre las señales, (1 representaría que una señal es idéntica a otra).

USR	O1O2	O1O2	O1ACO	O1ACO	O2ACO	O2ACO
	ORIGINAL	EXTRACT	ORIGINAL	EXTRACT	ORIGINAL	EXTRACT
A001	0.65275	0.64599	0.75899	0.75391	0.88779	0.88507
A002	0.25834	0.25506	0.60584	0.60343	0.53443	0.53015
A003	0.41599	0.41223	0.60876	0.6058	0.75087	0.74864
A004	0.39095	0.38796	0.47605	0.47328	0.8953	0.89389
A005	0.35604	0.35225	0.66601	0.66341	0.57413	0.56765
A006	0.40944	0.40562	0.73551	0.73328	0.627	0.62342
A007	0.48767	0.48454	0.74114	0.7392	0.69802	0.69534
A008	0.97218	0.97113	0.97218	0.97113	0.56166	0.53865
A009	0.97932	0.97543	0.9797	0.97589	0.99571	0.99511
A010	0.98365	0.98232	0.97366	0.97152	0.97501	0.973
A011	0.38596	0.3816	0.70025	0.69753	0.62466	0.62172
A012	0.9068	0.90512	0.17832	0.18623	0.23504	0.24062
A013	0.62089	0.61857	0.80176	0.80034	0.76475	0.76228
A014	0.55065	0.54694	0.80358	0.80159	0.71116	0.70751
A015	0.68614	0.68214	0.82285	0.82033	0.83757	0.83452
A016	0.91164	0.90966	0.9582	0.95722	0.94837	0.94699
A017	0.81977	0.81738	0.9228	0.92169	0.88674	0.88483
A018	0.94852	0.947	0.98148	0.98091	0.96487	0.96364
A019	0.79789	0.7935	0.89979	0.89741	0.86434	0.85981
A021	0.50396	0.50081	0.73624	0.7342	0.70659	0.70329
A022	0.90516	0.90358	0.90516	0.64055	0.64671	0.64055
A023	0.73834	0.73378	0.95915	0.95833	0.76874	0.76502
A024	0.53992	0.53509	0.78506	0.78224	0.66021	0.6516
A025	0.77073	0.75807	0.89839	0.89247	0.81629	0.80984
A026	0.04135	0.035098	0.42813	0.42234	0.31358	0.30386
A027	0.93049	0.92726	0.97826	0.97722	0.95103	0.94875
A028	0.31401	0.30947	0.66291	0.65989	0.59055	0.5851
A029	0.41971	0.41529	0.73451	0.73181	0.57841	0.56956
A030	0.009597	0.014805	0.66377	0.66023	0.15246	0.61731

Tabla 4.1 Correlación de señales del modelo ICA-ACO

Comparando las mezclas de las señales O1-O2 originales con las mezclas de señales ACO, se tiene una correlación O1-ACO vs O1-O2 de 82.76%, 10.34% con correlación igual y sólo 6.9% mejor correlación entre O1-O2 (Figura 4.25a). Así mismo, se tiene un 86.2% mejor correlación entre O2-ACO vs O1-O2 y un 13.8% mejor correlación entre O1-O2 (Figura 4.25b).

En el caso de señales reconstruidas, se tiene una mejor correlación de 82.76% en O1-ACO vs O1-O2; 6.9% con puntuaciones iguales y una correlación 10.34% mejor en O1-O2. (Figura 4.26a). Se obtuvo una mejor correlación de O2-ACO vs O1O2 de 86.2% y sólo una correlación 13.8% mejor entre O1-O2 vs O2-ACO (Figura 4.26b).

Los resultados de la correlación de las señales muestran que las señales optimizadas con ACO, ya sea en las señales originales o en las señales reconstruidas, presentan mejores características en la selección de componentes que en las señales originales sin optimización.




Figura 4.25 Correlación de señales originales ICA-ACO
 (a) O1-O2 vs O1-ACO. (b) O1-O2 vs O2-ACO




Figura 4.26 Correlación de señales reconstruidas ICA-ACO
 (a) O1-O2 vs O1-ACO. (b) O1-O2 vs O2-ACO.

En la Figura 4.27 se puede observar que 24 de 29 usuarios en O1 y 24 de 29 usuarios en O2 obtuvieron una mejor señal reconstruida utilizando la señal de optimización ACO (1 significa de señales idénticas). 3 usuarios con el mismo resultado se muestran en O1 y 2 usuarios en O2; Y sólo 2 en O1 y 3 en O2 donde el uso de las señales O1 y O2 muestran una mejora en la reconstrucción. La Tabla 4.2 muestra el desempeño del Modelo ICA-ACO con base a la correlación entre las señales.

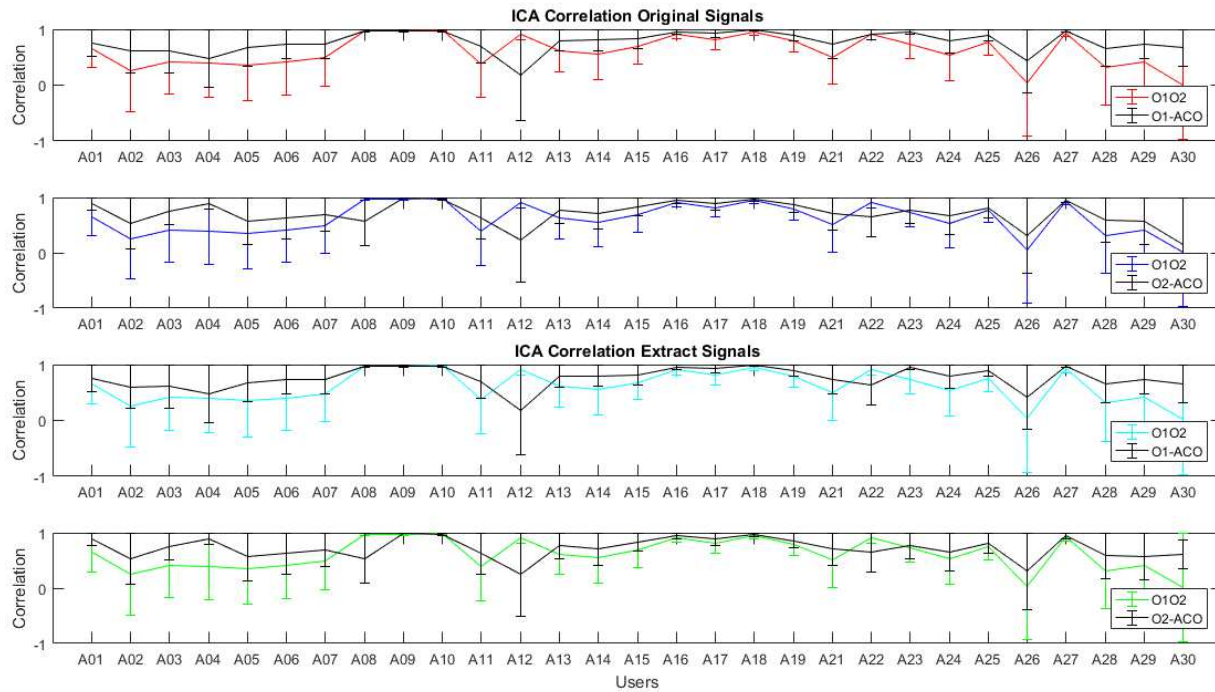


Figura 4.27 Comparativo señales originales vs señales optimizadas ICA-ACO

ORIGINAL O1O2	O1-ACO	O2-ACO
MEJOR ACO	83%	83%
IGUAL	10%	0%
MEJOR ORIGINAL	7%	17%
EXTRACT O1O2	O1-ACO	O2-ACO
MEJOR ACO	83%	86%
IGUAL	7%	0%
MEJOR ORIGINAL	10%	14%

Tabla 4.2 desempeño de ICA-ACO

4.3.2. Algoritmo de Optimización por Enjambre de Partículas (PSO)

PSO se ha empleado para abordar varios problemas en las aplicaciones BCI, tales como la selección de características (Wei *et al.*, 2012; Atyabi *et al.*, 2013, 2012;), localización de la eventos (Escalona-Vargasa, 2013; Shirvany *et al.*, 2014), cambio de detección de punto (Saaid *et al.* 2011) y el filtro de señal adaptativa (Ahirwal *et al.*, 2012, 2014), entre otros. Cinar y Sahin (2013) utilizaron PSO como clasificador estáticos en conjunto con redes neuronales. Hema *et al.* (2008) como clasificador dinámico. Karait *et al.*, (2012) introdujeron un PSO híbrido para la clasificación de señales EEG. Para la implementación del PSO, descrito en la sección 3.6.3 se

considera la mejor posición global como la señal optimizada. El diagrama de flujo de la implementación del algoritmo PSO se muestra en la Figura 4.28.

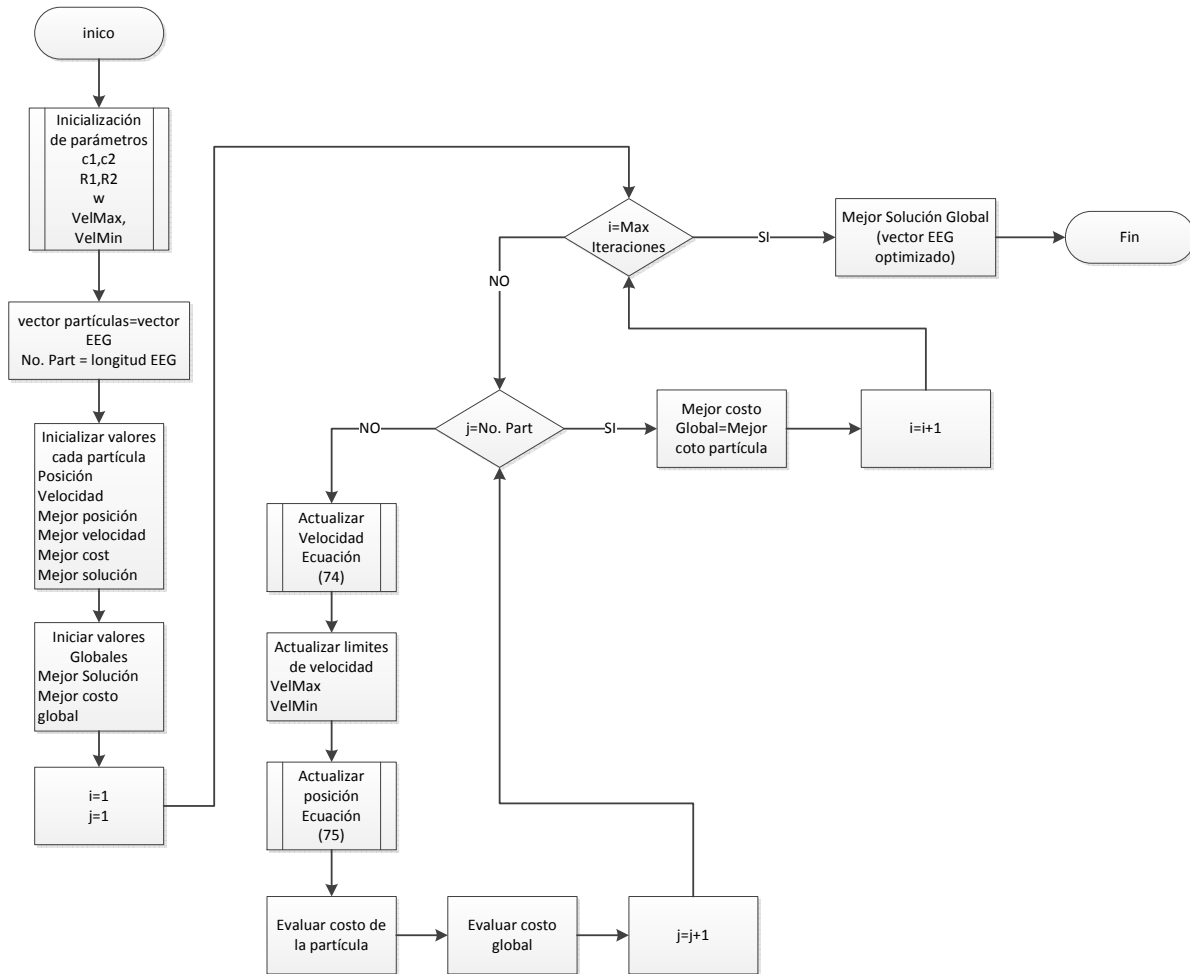


Figura 4.28 Diagrama de Flujo de la Implementación del algoritmo PSO

Para la realización de la simulación de PSO utilizamos las señales originales (O1/O2) que se muestran en la Figura 4.29 y Figura 4.30, en conjunto con el resultado del proceso de la optimización (*bestSol*). El proceso genera dos señales óptimas una por cada electrodo, *bestSol-O1* y *best-Sol-O2*, a las cuales identificaremos como *PSO-O1*, *PSO-O2* respectivamente.




Figura 4.29 Señales original vs optimizadas. Representación de toda la prueba.




Figura 4.30 Señales originales vs optimizadas. Representación de un segmento de 5 s.

Para la implementación del modelo PSO se realizaron simulaciones a diferentes iteraciones (20, 30, 50, 100), para ver el comportamiento sobre los resultados de optimización. Podemos observar que el tiempo de convergencia a la mejor solución llega rápidamente en todos los casos (Figura 4.31a). Podemos observar que el mejor costo (Figura 4.31b), el cual representa la solución óptima, y la media

estadística son igual en todos los casos, así mismo podemos observar que la varianza y la desviación estándar (Figura 4.31c), con relación al mejor costo, son menores para el caso del proceso de 30 iteraciones, lo cual implica que es el proceso que está más cerca de la solución óptima. Así mismo podemos observar que el costo computacional (Figura 4.31d) crece exponencialmente con base al número de iteraciones. Para el propósito del presente trabajo se consideran las señales obtenidas con el proceso de 30 iteraciones considerando el costo computacional.

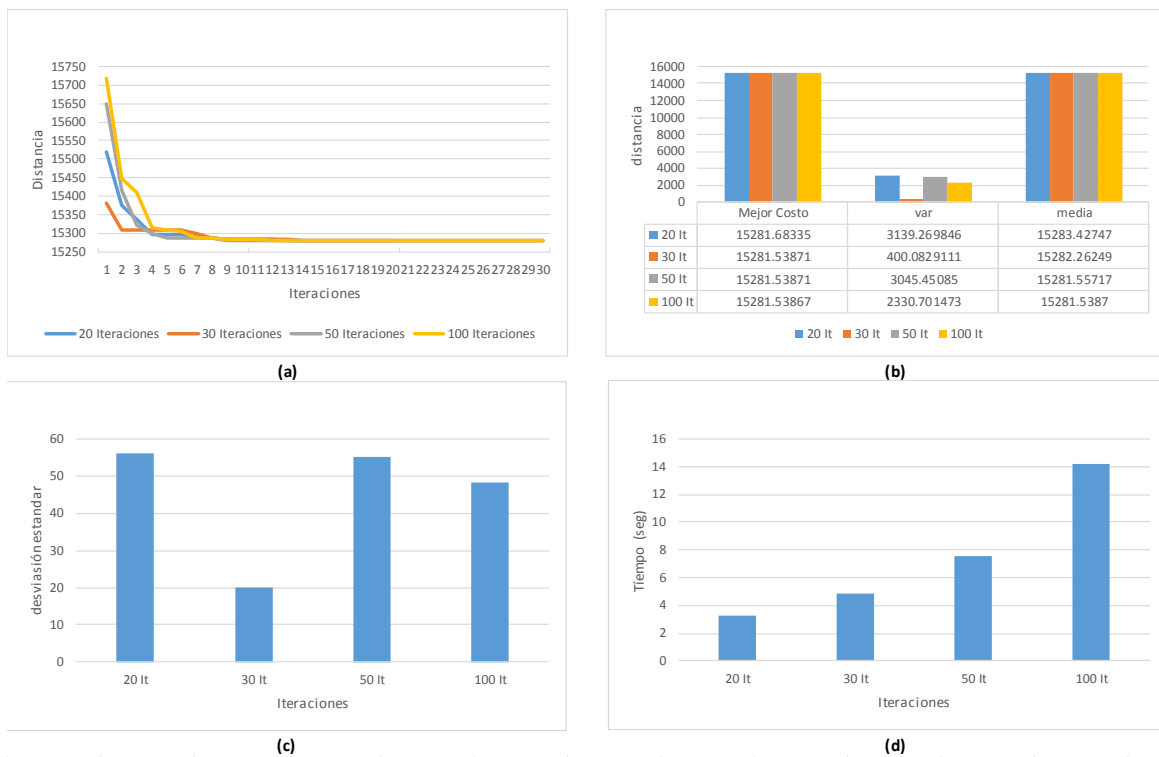


Figura 4.31 Desempeño PSO para segmentos de 5 s.

(a) Mejor solución. (b) Comportamiento de las soluciones. (c) Desviación estándar. (d) Tiempo de ejecución.

La siguiente etapa es la implementación del modelo ICA con las señales optimizadas con PSO (Figura 4.32).

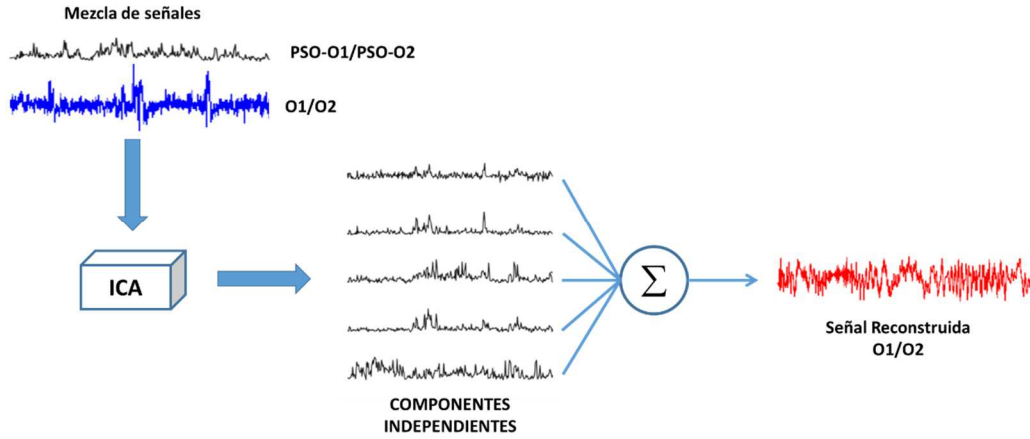


Figura 4.32 Modelo ICA-PSO

La representación de las mezclas de las señales y su histograma se muestran en la Figura 4.33 y Figura 4.34 respectivamente. La Figura 4.35 y la Figura 4.36 muestran los componentes independientes obtenidos por el proceso ICA-PSO para toda la duración del estudio.

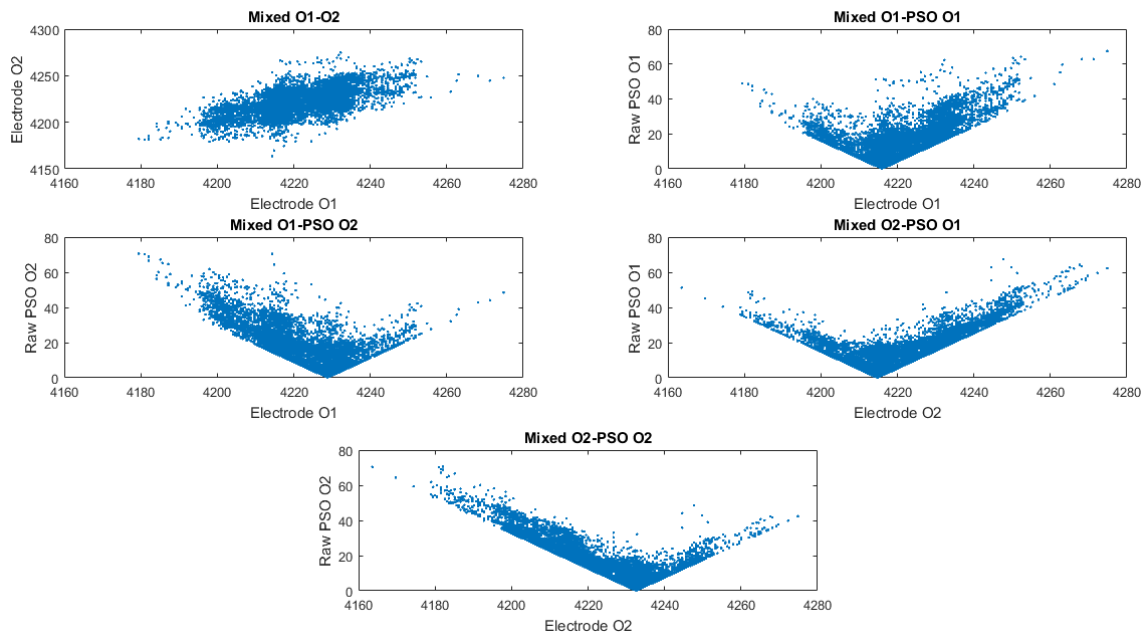


Figura 4.33 Mezcla de señales




Figura 4.34 Función de densidad de probabilidad




Figura 4.35 Componentes Independientes ICA-PSO




Figura 4.36 Componentes Independientes ICA-PSO

El comparativo de las señales originales con las señales reconstruidas, con base a las mezclas definidas, se muestran en las Figuras 4.37-4.41. La señal reconstruida se identifica como *extracted* en las gráficas. Las gráficas muestran segmentos de 10 s para una mejor visualización del comportamiento de las señales. Observamos que para la mezcla O1-O2 (Figura 4.37), el comportamiento en la reconstrucción de O1 (señal) es mejor que en el caso de O2 donde podemos observar que la optimización genera una disminución en la amplitud de la señal, generalmente por la eliminación de ruido, más sin embargo esto no implica la pérdida de elementos de la misma como se mostrará más adelante. La mezcla con PSO-O1 (Figura 4.38, Figura 4.39) la reconstrucción de O1 prácticamente no presenta cambios en la señal reconstruida y si muestra variaciones significativas en la amplitud con respecto a O2. En el caso de la mezcla con PSO-O2 (Figura 4.40, Figura 4.41) el comportamiento de la reconstrucción para O1 es el que muestra varianza significativa en la amplitud y sin cambios significativos en O2. Podemos concluir que la reconstrucción de las señales está directamente relacionada con la mezcla de las señales optimizadas y sus respectivos electrodos.




Figura 4.37 Reconstrucción de las señales con la mezcla O1-O2




Figura 4.38 Reconstrucción de las señales con la mezcla O1-PSO-O1




Figura 4.39 Reconstrucción de las señales con la mezcla O1-PSO-O2




Figura 4.40 Reconstrucción de las señales con la mezcla O2-PSO-O1




Figura 4.41 Reconstrucción de las señales con la mezcla O2-PSO-O2

A continuación analizaremos el comportamiento de los componentes independientes obtenidos por proceso ICA-PSO. Podemos observar en los histogramas de la Figura 4.42 como en componente IC2 (lado derecho de la figura) su comportamiento es prácticamente homogéneo y en el caso de IC1 (lado izquierdo de la figura) hay una variabilidad en su comportamiento de distribución.

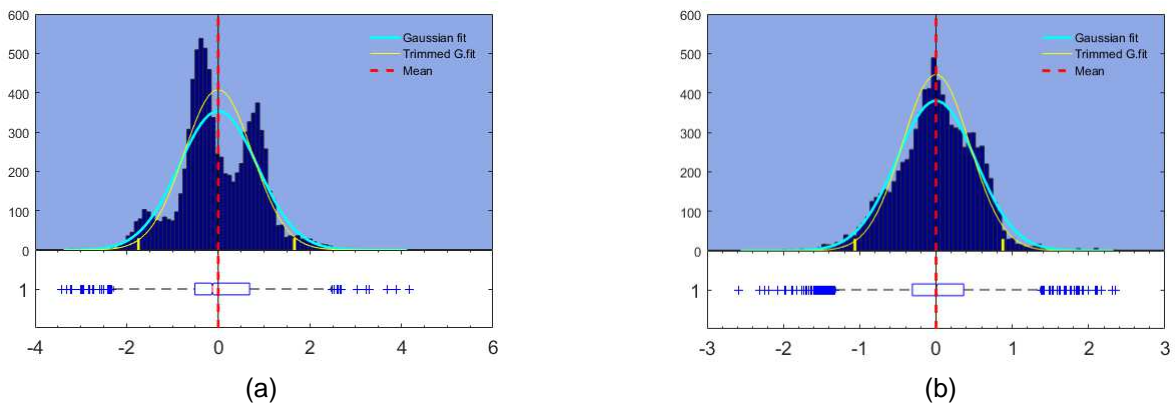


Figura 4.42 Histogramas de los componentes Mezcla O1-O2.

Para el caso de IC1 su comportamiento es homogéneo para todos los casos, IC2 tanto la distribución de la actividad de la señal como la potencia de disminuye notablemente en el electrodo O2 (Figura 4.43)

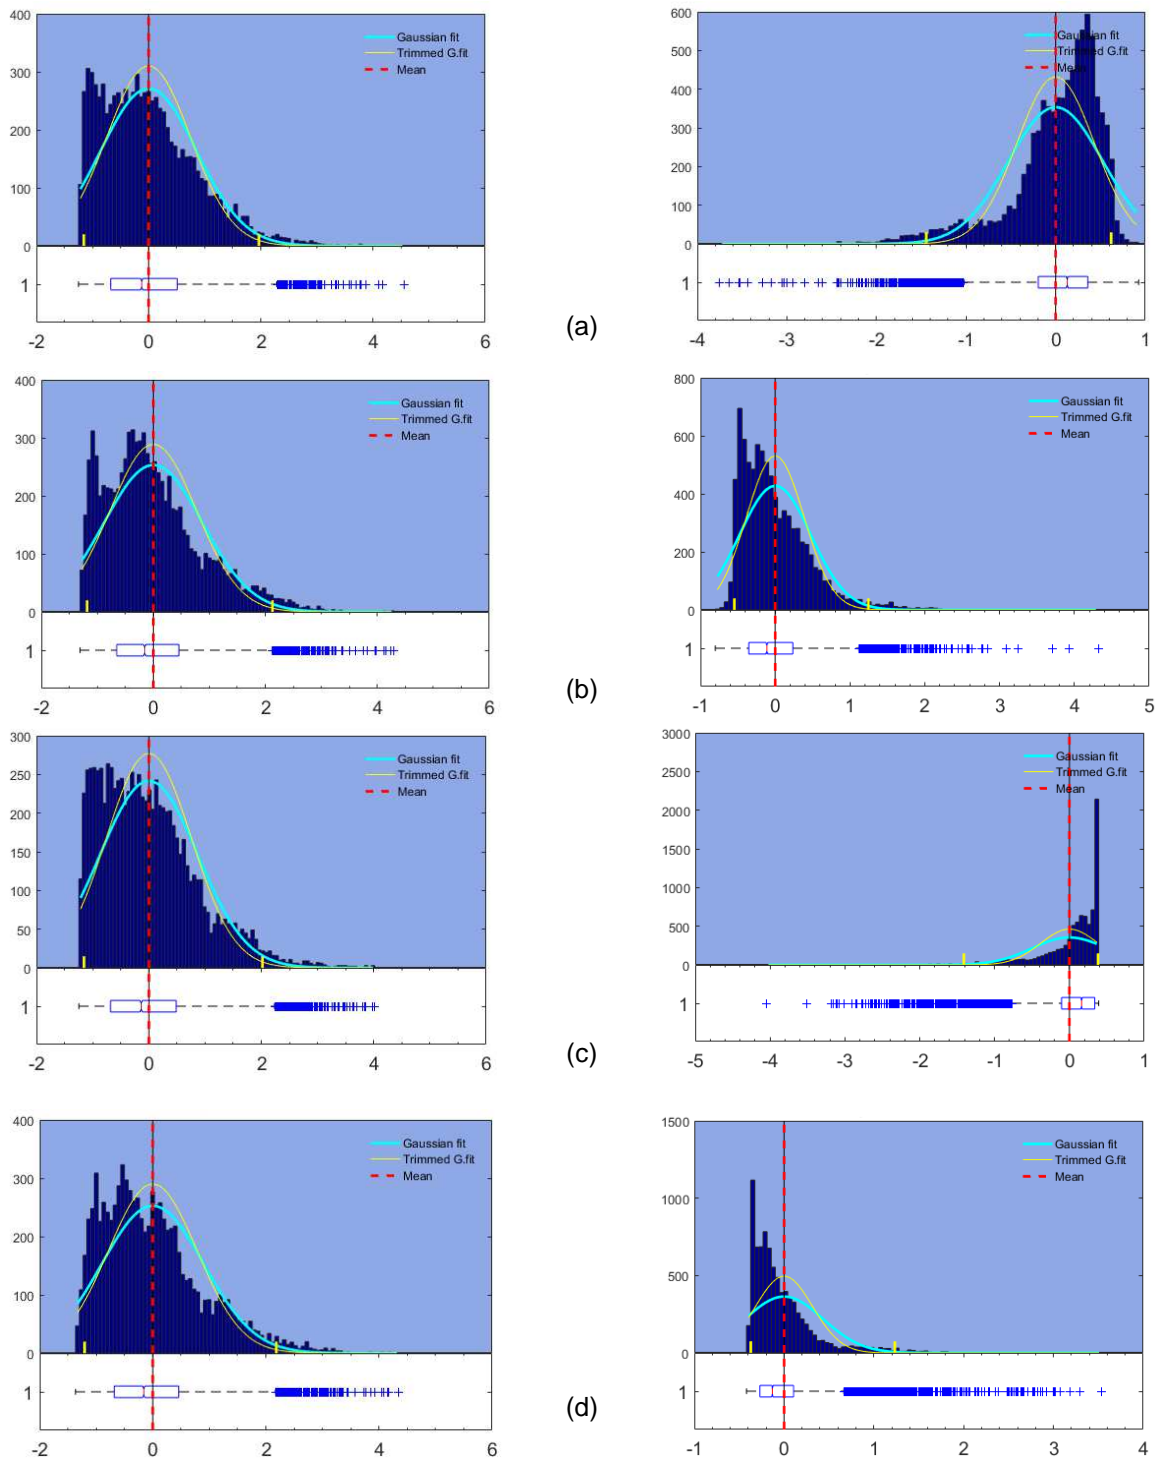


Figura 4.43(a) Mezcla O1-PSO-01. (b) Mezcla O1-PSO2. (c) Mezcla O2-PSO-01. (d) Mezcla O2-PSO-02

A continuación presentamos en la Figura 4.44 el comportamiento de la densidad de potencia de la señal (PSD) para cada electrodo y sus componentes independientes con relación a la frecuencia de estímulo (0.895 Hz). Podemos observar que el componente IC1 su tendencia de comportamiento es similar al comportamiento del electrodo mientras que el componente IC2 la potencia es menor y el comportamiento tiene mayor varianza en la potencia.

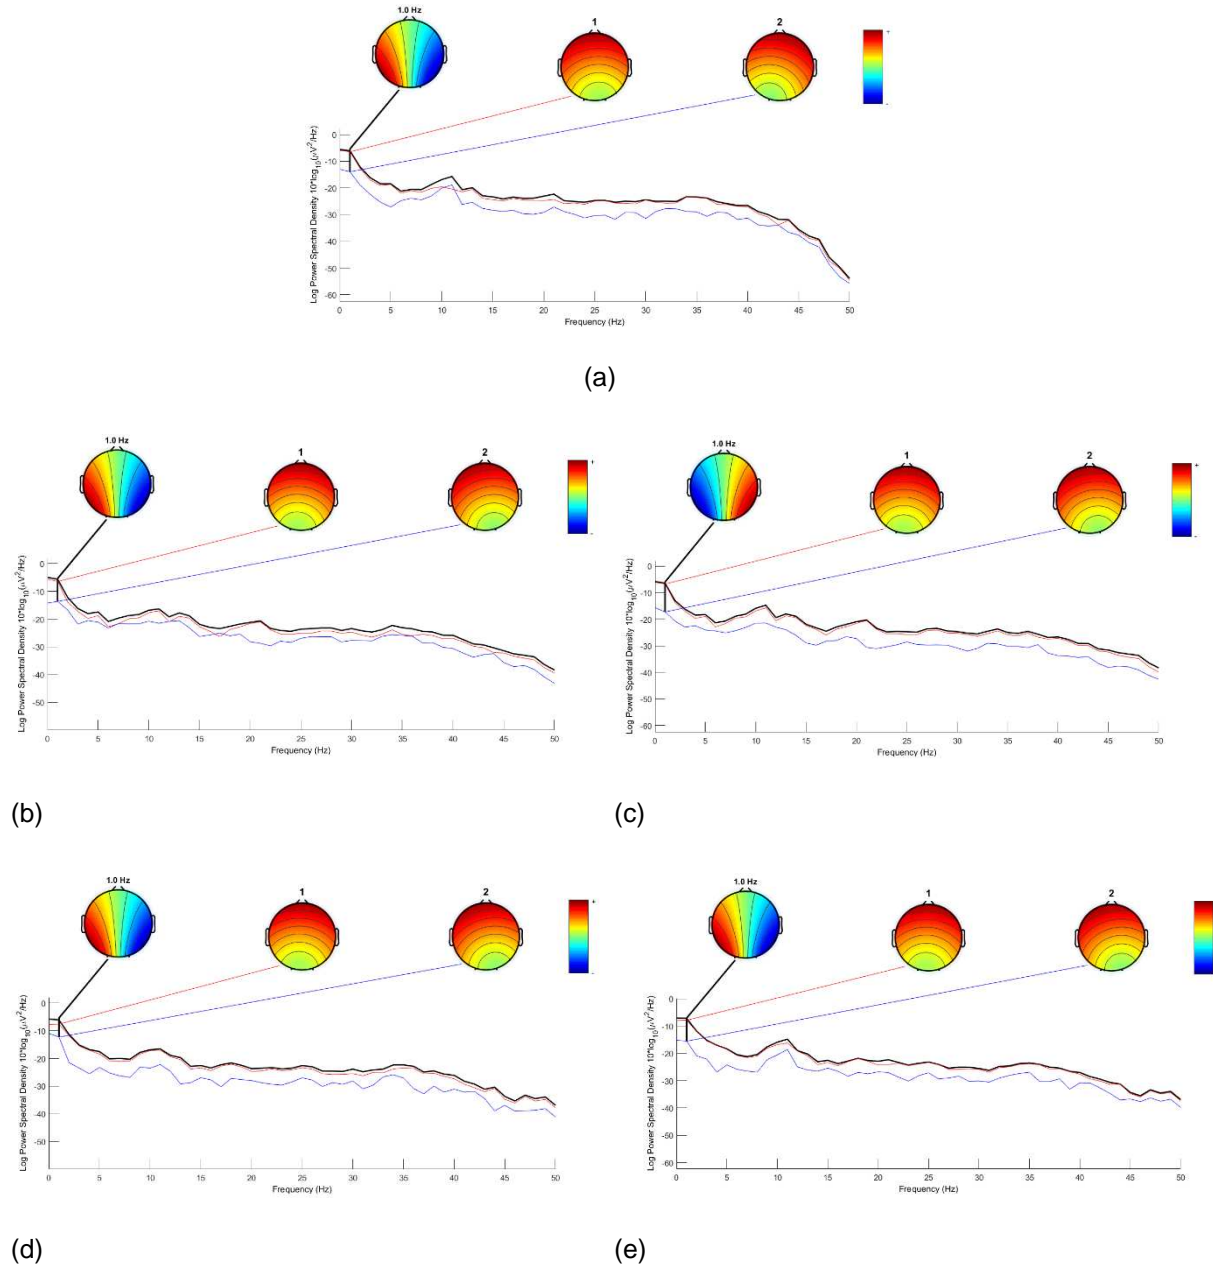


Figura 4.44 PSD de los electrodos y los componentes independientes. (a) Mezcla O1-O2. (b) Mezcla O1-PSO-O1. (c) Mezcla O2-PSO-O1. (d) Mezcla O1-PSO-O2. (e) Mezcla O2-PSO-O2

En la Figura 4.45 mostramos la estimación de la potencia de la señal para cada componente, donde podemos observar que cada componente de cada una de las mezclas conserva la frecuencia del estímulo (0.895 Hz, línea negra), así como sus armónicos (1.79, 2.685, 3.58,... Hz, líneas cafés). Así mismo en la figura 4.45 podemos observar que la potencia de la frecuencia de estímulo siempre es mayor en comparación a sus armónicos. En este sentido, se puede identificar en los espectrogramas de la Figura 4.46, 4.47 y 4.48, la frecuencia del estímulo. Podemos observar que la potencia en las señales optimizadas PSO (Figura 4.46) es mayor de manera general con respecto a las señales originales, como podemos observar, en las Figuras 4.47 y 4.48, genera una compensación en la potencia en el momento de las mezclas. Así mismo la reconstrucción de las señales con base a las mezclas la potencia de la señal tiende a 0 de manera discontinua en el rango de la frecuencia de estímulo, lo cual no permite identificarla de una forma precisa como en el caso del modelo ACO (Figura 4.24).



Figura 4.45 Representación del PSD. (a) Señales originales y señales optimizadas. (b)Mezclas con O1. (c)Mezclas con O2.

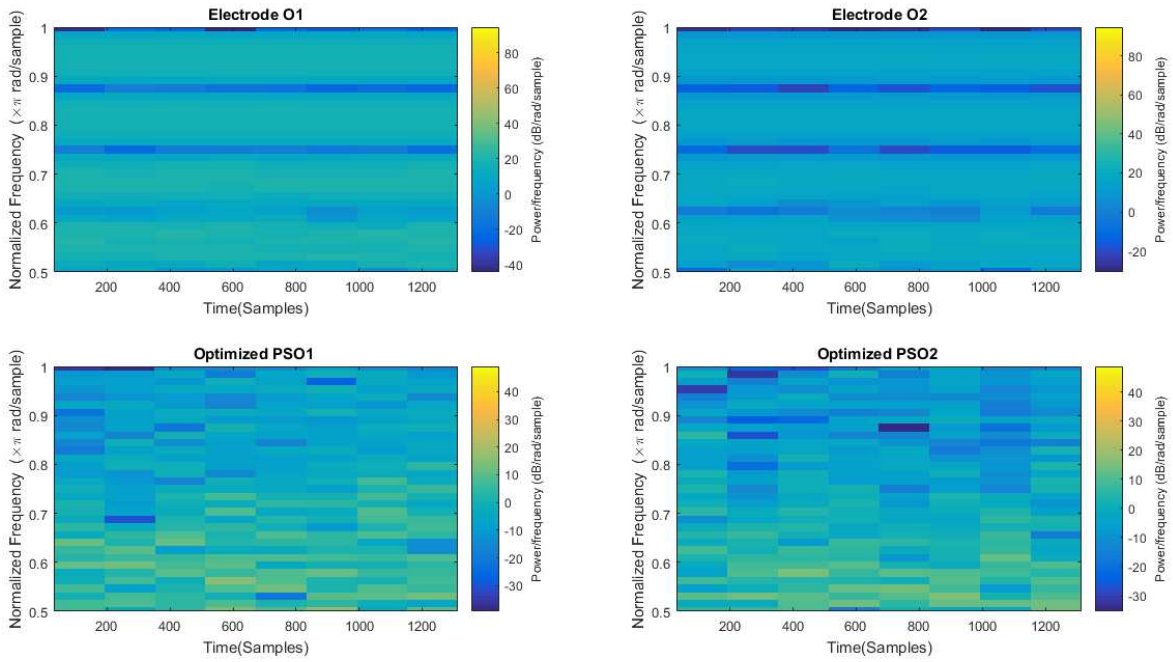


Figura 4.46 Identificación de la frecuencia de estímulo

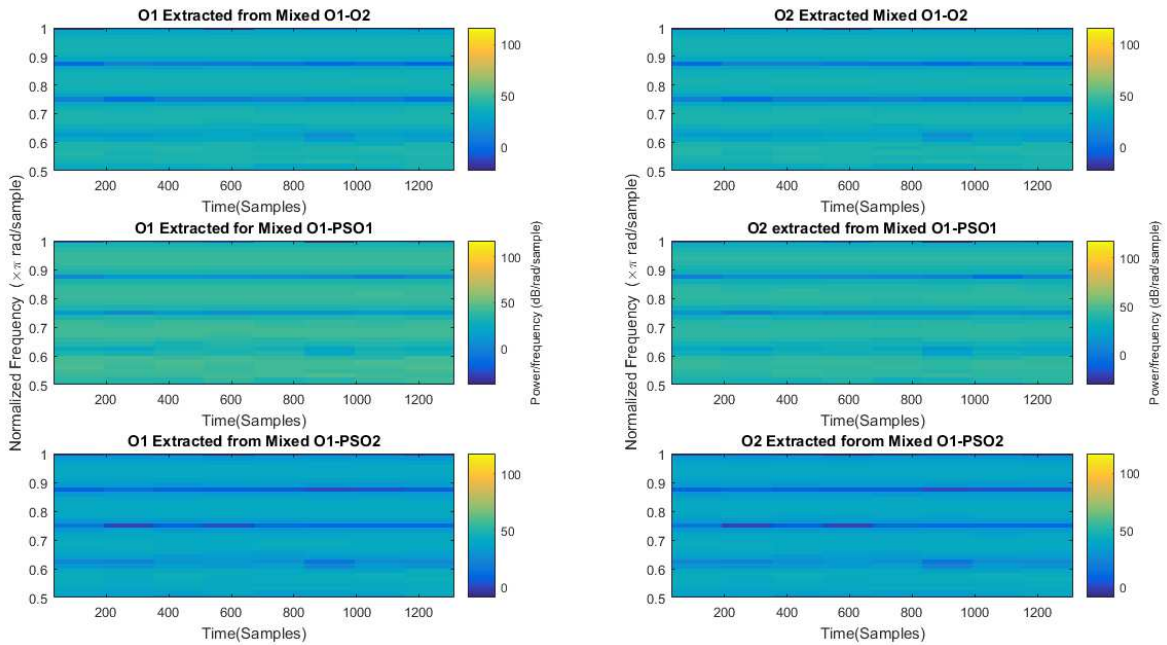


Figura 4.47 Identificación de la frecuencia de estímulo para las mezclas O1, O2 y O1-PSO.

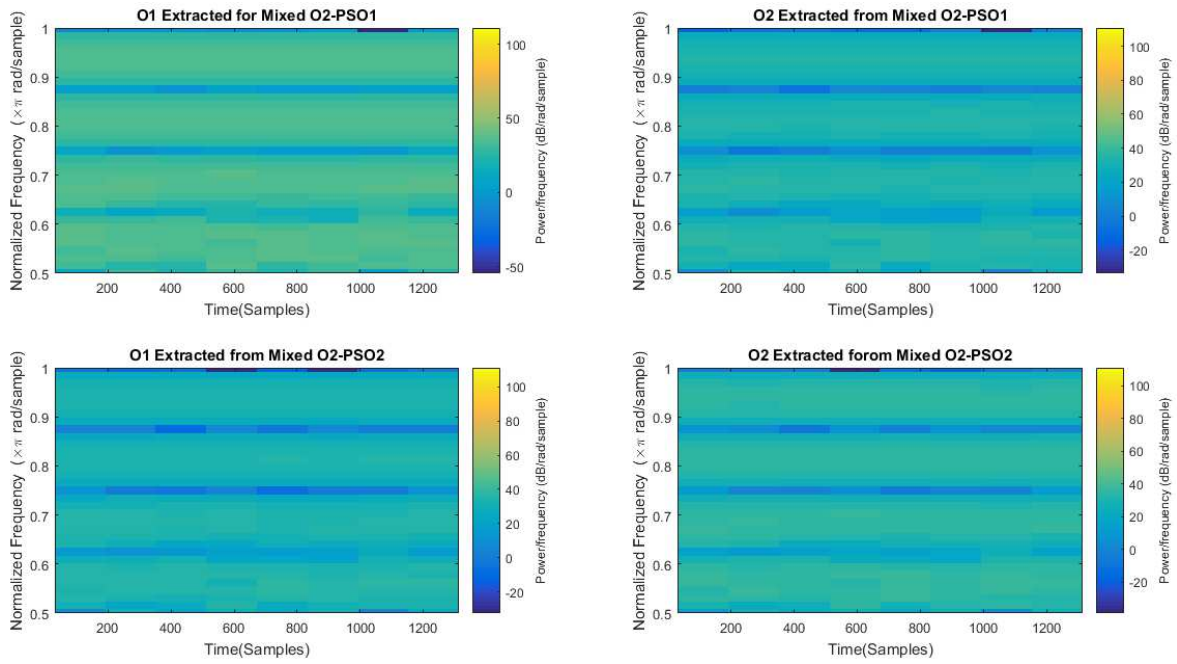



Figura 4.48 Identificación de la frecuencia de estímulo para las mezclas O2-PSO

Los resultados de la implementación ICA-PSO se muestran en la Tabla 4.3.

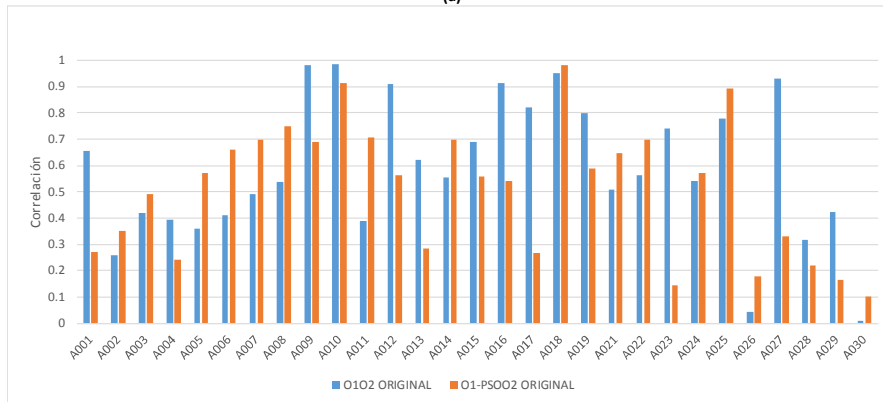
USR	O1O2	O1O2	O1-PSO01	O1-PSO01	O1-PSO02	O1-PSO02	O2-PSO01	O2-PSO01	O2-PSO02	O2-PSO02
	ORIGINAL	EXTRACT	ORIGINAL	EXTRACT	ORIGINAL	EXTRACT	ORIGINAL	EXTRACT	ORIGINAL	EXTRACT
A001	0.65617	0.64376	0.67256	0.68128	0.27204	0.2552	0.55417	0.56594	0.31883	0.30156
A002	0.25997	0.25405	0.65997	0.66289	0.35285	0.34768	0.37395	0.38082	0.71566	0.71115
A003	0.41787	0.41109	0.49599	0.50086	0.49197	0.48639	0.67507	0.67872	0.22689	0.21972
A004	0.39242	0.38703	0.68825	0.69096	0.24091	0.23542	0.53846	0.54509	0.28439	0.2748
A005	0.3579	0.35106	0.30671	0.3001	0.57251	0.57687	0.63529	0.62666	0.2612	0.27311
A006	0.41134	0.40445	0.42731	0.4212	0.66165	0.66529	0.5836	0.57757	0.60913	0.61404
A007	0.48923	0.48358	0.4553	0.45003	0.6962	0.69915	0.59573	0.59055	0.7277	0.73087
A008	0.53528	0.5124	0.76074	0.77098	0.74956	0.73609	0.88675	0.89525	0.56435	0.52946
A009	0.98135	0.9731	0.074922	0.058925	0.68709	0.60265	0.066739	0.036049	0.69989	0.63846
A010	0.98433	0.98174	0.83742	0.81676	0.91482	0.92306	0.81422	0.79118	0.93269	0.9392
A011	0.38816	0.38029	0.5449	0.53911	0.70697	0.71046	0.47424	0.46841	0.69591	0.69924
A012	0.90766	0.9046	0.69201	0.69812	0.56153	0.55198	0.70114	0.70567	0.54189	0.53446
A013	0.62203	0.61786	0.73161	0.73404	0.28497	0.27948	0.86501	0.86686	0.33055	0.32288
A014	0.5525	0.54578	0.43774	0.43076	0.697	0.70081	0.47682	0.46823	0.77888	0.78257
A015	0.68813	0.68086	0.58524	0.57714	0.55814	0.5654	0.62065	0.61101	0.61433	0.62255
A016	0.91263	0.90901	0.56585	0.55333	0.54097	0.5521	0.5717	0.55761	0.55626	0.56855
A017	0.82095	0.81663	0.73949	0.74386	0.26671	0.25646	0.75393	0.7588	0.27163	0.25961
A018	0.94928	0.94648	0.93357	0.93034	0.98209	0.98278	0.92177	0.91748	0.97789	0.97884
A019	0.80007	0.79203	0.611	0.62142	0.58719	0.57427	0.72486	0.73551	0.50701	0.48701
A021	0.50552	0.49984	0.3255	0.31939	0.64641	0.6499	0.42497	0.41694	0.81014	0.81299
A022	0.56193	0.55157	0.075256	0.062606	0.69963	0.70547	0.41533	0.40194	0.59015	0.59932
A023	0.74065	0.73232	0.60343	0.61187	0.14558	0.13117	0.58039	0.58851	0.23669	0.22375
A024	0.54229	0.53353	0.24904	0.23858	0.57222	0.57893	0.0088313	0.01152	0.85368	0.85857
A025	0.77752	0.75334	0.0033379	0.039487	0.89277	0.88261	0.13154	0.15919	0.7094	0.69345
A026	0.044478	0.033121	0.21814	0.20802	0.17769	0.18744	0.65311	0.64391	0.14435	0.12973
A027	0.93214	0.92606	0.13651	0.16961	0.33135	0.299	0.14371	0.17636	0.31772	0.28547
A028	0.31626	0.30804	0.52295	0.5284	0.21805	0.21017	0.83037	0.83368	0.21886	0.20717
A029	0.42188	0.41388	0.38557	0.39257	0.16554	0.15693	0.78544	0.79147	0.40102	0.41495
A030	0.0070635	0.016506	0.23613	0.2446	0.09992	0.10897	0.52686	0.47482	0.61011	0.56411

Tabla 4.3 Correlación de señales del modelo ICA-PSO


La Figura 4.49 y la Figura 4.50 muestran el comparativo de la correlación de las mezclas de las señales originales y las reconstruidas respectivamente.




(a)



(b)




(c)




(d)


Figura 4.49 Correlación de señales originales ICA-PSO



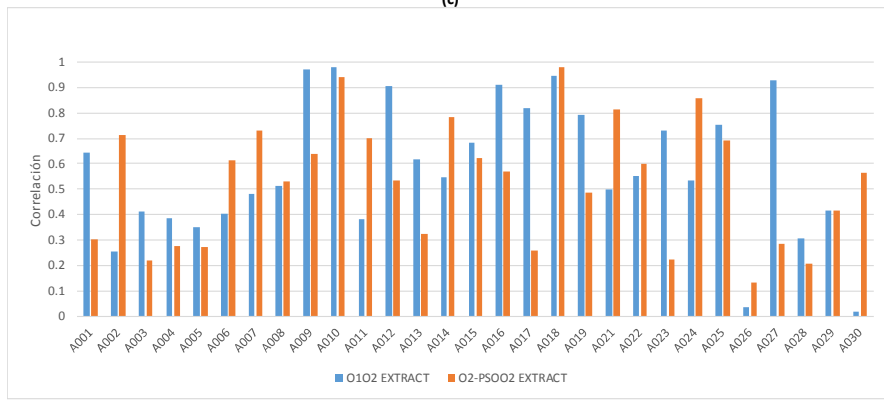
(a)



(b)



(c)



(d)

Figura 4.50 Correlación de señales originales ICA-PSO

La Figuras 4.51-4.53 muestran el comportamiento del desempeño del modelo ICA-PSO con base a la correlación de las señales. Podemos observar que en el caso de las mezclas originales y en las reconstruidas tenemos una mejor correlación al utilizar señales optimizadas con PSO-O2 (Figura 4.53a). Así mismo podemos observar en la comparación del desempeño promedio de las señales originales vs las reconstruidas que obtenemos resultados iguales con la señal optimizada en PSO-O1 y la señal original O1, y el mejor desempeño se muestra en las señales con PSO-O2. La figura 4.54a muestra el desempeño total entre las la señales originales y las reconstruidas, donde podemos observar un mejor desempeño en las señales reconstruidas. En el caso de promedio total el mejor desempeño se muestra en PSO-O2 (Figura 4.54b).




Figura 4.51 Comparativo señales originales vs señales optimizadas Modelo ICA-PSO






Figura 4.52 Comparativo señales reconstruidas vs señales optimizadas Modelo ICA-PSO



(a)

(b)

Figura 4.53 Desempeño del Modelo ICA-PSO.



(a)

(b)

Figura 4.54 Totales del desempeño del Modelo ICA-PSOI

4.3.3. Discusión

En el presente trabajo presentamos algoritmos de inteligencia de enjambre como un nuevo paradigma para el procesamiento de señales EEG. Se implementaron los algoritmos ACO y PSO para la clasificación de los elementos característicos de las señales EEG. Los algoritmos propuestos permiten obtener señales optimizadas y conservar las características principales de las señales originales. Los métodos inspirados por la inteligencia de enjambre pueden ser aplicados en muchas etapas del proceso de procesamiento de datos biomédicos (Figura 2.14). Primeramente, se presentó en éste trabajo técnicas de optimización inspiradas en las hormigas, tratando a las señales EEG como un problema TSP resuelto con ACO.

Hemos presentado y evaluado el método AS para obtener señales optimizadas que se pueden utilizar para extraer sus características y clasificarlas y mejorar las condiciones de las señales originales. Para medir el desempeño del algoritmo se implementó el modelo ICA como referencia para hacer un comparativo entre las características de las señales obtenidas de las señales originales y las obtenidas por el proceso de optimización.

Como se observó en la Tabla 4.2 la optimización de la señal mostró una mejora del 83% con referente a la reconstrucción de la señal, en aquellas que se obtuvieron a partir de las señales optimizadas con ACO. Esto nos permite presentar una mejora en la señal dentro del proceso de extracción de características de los sistemas BCI. Adicionalmente la Figura 4.23 mostró que la potencia de la señales optimizadas es mayor que la potencia de las señales originales, permitiendo con ello identificar de una manera más precisa la frecuencia de estímulo así como la réplica de sus armónicos durante el proceso de prueba de los sujetos de estudios; con ello podemos decir que se obtiene una mejora en el proceso de selección de características del modelo BCI. Los resultados obtenidos muestran una buena capacidad de mejorar el desempeño de aplicaciones basadas en BCI.

En segundo término presentamos técnicas basadas en poblaciones, donde hemos presentado y evaluado el método PSO tratando a las señales EEG como un conjunto de elementos sociales para obtener señales optimizadas que se pueden

utilizar para extraer e identificar las características principales de las señales EEG originales.

Los resultados presentados con referente a la correlación de las señales originales contra las señales reconstruidas, en las Figuras 4.50-4.54 observamos que tenemos mejor desempeño con las señales optimizadas PSO-O2 con el electrodo O1 y desventaja con las señales optimizadas en O2. La relación de los usuarios que obtuvieron un mejor desempeño son usuarios sanos con edades entre 18-26 años, los cuales el 93% son diestros. Podemos afirmar que el resultado del desempeño obtenido en ICA-PSO se basa en que los dos hemisferios del cerebro difieren en su capacidad de procesamiento de la información, siendo el hemisferio derecho dominante en el procesamiento de las relaciones espacio-visual (Hugdahl, 2013) y siendo el hemisferio izquierdo el dominante para las personas diestras (Sainburg, 2002). La mezcla de señales con mejor desempeño se obtuvo de la optimización del electrodo O2 (procesamiento visual), ubicado en el hemisferio derecho del cerebro y la señal original O1 (personas diestras) ubicada en el hemisferio izquierdo.

Podemos concluir que el método de optimización con PSO para el proceso de extracción de características de los sistemas BCI solo presenta mejora en un pequeño sector de la población. Adicionalmente las Figuras 4.44 y 4.45 muestran el resultado de la distribución de la potencia de la señal con base a la frecuencia de estímulo en donde podemos observar que la potencia de la señal siempre es mayor en las señales con mezclas optimizadas que en las mezclas de las señales originales, lo cual implica que la frecuencia de estímulo está plenamente identificada así como así como en las réplicas de sus armónicos, durante el proceso de prueba de los sujetos de estudio. Este cambio en la potencia de la señal representa una mejora en el proceso de selección de características de los sistemas BCI.

5. CONCLUSIONES

En éste trabajo presentamos a los sistemas BCI como un sistema de comunicación que permite a los usuarios interactuar con dispositivos electrónicos mediante señales de control adquiridas de la actividad cerebral sin comprometer los nervios periféricos y/o musculares. La motivación preliminar para la investigación en BCI fue el desarrollo de dispositivos de ayuda para las personas con discapacidades motrices y se centra en desarrollar propuestas de mejora en el procesamiento de señales de los sistemas BCI basados en eventos visuales de estado estable asíncronos (BCI_SSVEP).

Para establecer la viabilidad de los sistemas BCI, la clasificación de las características de las señales de EEG y la identificación de los patrones estímulo son una tarea sofisticada que determina la exactitud del reconocimiento de intenciones realizado por el sistema BCI que, a su vez, determina el grado de naturalidad de la interacción proporcionada por el usuario. Implementar nuevas herramientas que permitan mejorar el desempeño en las diferentes etapas de procesamiento de señales representa un avance significativo en el desarrollo de aplicaciones para los sistemas BCI. Debido a las características no estacionarias y dinámicas de las señales EEG se requieren procesos que permitan al sistema identificar los patrones de intención en forma adaptativa y en línea. De acuerdo con Nicolas-Alonso *et al.*, (2012), los algoritmos adaptativos son muy importantes para los sistemas BCI no invasivos y asincrónicos, ya que con ellos podemos obtener mejoras en los algoritmos de procesamiento de señales de los mismos.

En el presente trabajo se presentaron algoritmos basados en inteligencia colectiva animal para mejorar el desempeño de las etapas de procesamiento de señales de los sistemas BCI, se presentaron algoritmos basados en hormigas (ACO) y en poblaciones (PSO), aplicando nuestra propuesta a bases de datos biomédicas reales obtenidas por un proceso de experimentación basado en estándares internacionales para el desarrollo de pruebas con seres humanos. Nuestros resultados experimentales demuestran una mejora en la obtención de las características de la señales EEG así como en la identificación de estímulos

visuales de estado estable asíncronos. Se mostró que el modelo de optimización basado en hormigas presenta mejores resultados tanto en la extracción de las características de las señales EEG como en la clasificación de dichas características. El modelo de optimización basado en poblaciones presenta mejoras en una parte de la población de estudio con referente a la extracción de las características de las señales EEG y una mejora notable en el proceso de la selección de las características de las señales de estímulos visuales. La medición de los resultados se realizó con base a la correlación entre las señales originales y las señales reconstruidas y con base a la distribución de la potencia de la señal.

La implementación de técnicas de procesamiento de señales que reducen el costo computacional y resuelven problemas de optimización de sistemas complejos, es una parte importante del desarrollo de nuevas investigaciones en el campo de la bioinformática. Como trabajo futuro la implementación de algoritmos basados en comportamiento animal o en poblaciones en conjunto con los métodos estocásticos frecuentemente utilizados en las investigaciones en sistemas BCI, son una oportunidad para presentar nuevas alternativas en el área de procesamiento de señales biomédicas. El uso de metodologías basadas en inteligencia colectiva en señales biomédicas es una nueva rama que debe ser explotada en el futuro.

6. REFERENCIAS

Ab Wahab, M. N., Nefti-Meziani, S., & Atyabi, A. (2015). A comprehensive review of swarm optimization algorithms. *PloS one*, 10(5), e0122827.

Acqualagna, L., Bosse, S., Porbadnigk, A. K., Curio, G., Müller, K. R., Wiegand, T., & Blankertz, B. (2015). EEG-based classification of video quality perception using steady state visual evoked potentials (SSVEPs). *Journal of neural engineering*, 12(2), 026012.

Adubi, S. A., & Misra, S. (2014, September). A comparative study on the ant colony optimization algorithms. In *Electronics, Computer and Computation (ICECCO), 2014 11th International Conference on* (pp. 1-4). IEEE.

Ahirwal, M. K., Kumar, A., & Singh, G. K. (2014). Adaptive filtering of EEG/ERP through bounded range artificial bee colony (BR-ABC) algorithm. *Digital Signal Processing*, 25, 164-172.

Ahmed, H., & Glasgow, J. (2012). *Swarm intelligence: concepts, models and applications*. School Of Computing, Queens University Technical Report.

Akin, M. (2002). "Comparison of wavelet transform and FFT methods in the analysis of EEG signals". *Journal of medical systems*, 26(3), 241-247.

Alwasiti, H. H., Aris, I., & Jantan, A. (2010). Brain computer interface design and applications: Challenges and future. *World Applied Sciences Journal*, 11(7), 819-825.

Amiri, S., Rabbi, A., & Azinfar, L. (2013). A review of P300 SSVEP and hybrid P300/SSVEP brain-computer interface systems [J]. *Brain-Computer Interface Systems—Recent Progress and Future Prospects*. INTECH chapter 10, 195-213.

Arellano J. S., Hall R.T., Hernandez Arriaga J. (2014). *Ética de la investigación científica*. Universidad Autónoma de Querétaro, Centro Universitario, Cerro de las Campanas s/n. Código Postal 76010, Querétaro, Qro., México, ISBN: 978-607-513-127-6.

Arito, F. L. A., & Luis-Argentina, S. (2010). Algoritmos de Optimización basados en Colonias de Hormigas aplicados al Problema de Asignación Cuadrática y otros problemas relacionados. Universidad Nacional de San Luis Facultad de Ciencias Físico Matemáticas y Naturales Departamento de Informática, San Luis–Argentina

Bashashati, A., Fatourehchi, M., Ward, R. K., & Birch, G. E. (2007). A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals. *Journal of Neural engineering*, 4(2), R32.

Beni, G., & Wang, J. (1989). *Swarm Intelligence in Cellular Robotic Systems*, Proceed. NATO Advanced Workshop on Robots and Biological Systems, Tuscany, Italy, June 26-30. *Applied Mathematics and Computation*, 3, 268-308.

Beverina, F., Palmas, G., Silvoni, S., Piccione, F., & Giove, S. (2003). User adaptive BCIs: SSVEP and P300 based interfaces. *PsychNology Journal*, 1(4), 331-354.

Bin, G., Gao, X., Yan, Z., Hong, B., & Gao, S. (2009). An online multi-channel SSVEP-based brain–computer interface using a canonical correlation analysis method. *Journal of neural engineering*, 6(4), 046002.

Blum C. & Merkle D. (Eds.). (2008). *Swarm Intelligence – Introduction and Applications*. Springer-Verlag Berlin Heidelberg. ISBN 978-3-540-74088-9

Blum, C., & Li, X. (2008). Swarm intelligence in optimization. In *Swarm Intelligence* (pp. 43-85). Springer Berlin Heidelberg.

Bonabeau, E., Dorigo, M., & Theraulaz, G. (1999). *Swarm intelligence: from natural to artificial systems* (No. 1). Oxford university press.

Bretón Blas, J., & Fernández Ros, J. (2000). Aplicación de los algoritmos de hormigas para la resolución del problema de equilibrado de líneas de montaje SALBP-E y aplicación a un caso real.

Cao, L., Ju, Z., Li, J., Jian, R., & Jiang, C. (2015). “Sequence detection analysis based on canonical correlation for steady-state visual evoked potential brain computer interfaces”. *Journal of neuroscience methods*, 253, 10-17.

Castillo-García, J., Müller, S., Caicedo, E., Cotrina, A., & Bastos, T. (2014, July). Comparison among feature extraction techniques based on power spectrum for a SSVEP-BCI. In *Industrial Informatics (INDIN), 2014 12th IEEE International Conference on* (pp. 284-288). IEEE.

Cervantes, G. S., Martínez, N. H. M., & Pérez, M. A. R. (2008, September). Interfaz Cerebro Computadora para el Posicionamiento de un Robot Virtual. In *XII Simposio Mexicano en Cirugía Asistida por Computadora y Procesamiento de Imágenes Médicas*, México, DF.

Cortes J. A., Medina F. A., Chaves [sic] J. A., (Mayo, 2007). Del Análisis de Fourier a las Wavelets Análisis de Fourier. *Scientia et Technica*. Año XIII, No 34, pp. 151-156

Council for International Organizations of Medical Sciences. (2002). *Pautas éticas internacionales para la investigación biomédica en seres humanos*. Geneva: Council for international organizations of medical sciences.

Clerc, M. (2004). Discrete particle swarm optimization, illustrated by the traveling salesman problem. In *New optimization techniques in engineering* (pp. 219-239). Springer Berlin Heidelberg.

Clerc, M. (2006). Stagnation analysis in particle swarm optimisation or what happens when nothing happens.

Das, S., Abraham, A., & Konar, A. (2008). Swarm intelligence algorithms in bioinformatics. In *Computational Intelligence in Bioinformatics* (pp. 113-147). Springer Berlin Heidelberg.

De la Escalera, N. C. M. (2010). *Modelación de la actividad neuroeléctrica*.

De la Torre A. J. (2012). *Procesado de Señales EEG para un Interfaz Cerebro-Máquina (BCI)*, Tesis Licenciatura Universidad Carlos III de Madrid, España.

- Delorme, A., & Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of neuroscience methods*, 134(1), 9-21.
- Dimigen, O., Sommer, W., Hohlfeld, A., Jacobs, A., & Kliegl, R. (2011). Coregistration of eye movements and EEG in natural reading: Analyses & Review. *Journal of Experimental Psychology: General*, 140 (4), 552-572
- Ding, J., Srinivasan, R., & Sperling, G. (2006). Flicker elicits eeg responses in two distinct cortical networks depending on attention and flicker frequency. *Journal of Vision*, 6(6), 515-515.
- Dorigo, M., & Stutzle, T. (2004). *Ant Colony Optimization*, Massachusetts Institute of Technology.
- Dorigo, M., & Blum, C. (2005). Ant colony optimization theory: A survey. *Theoretical computer science*, 344(2-3), 243-278.
- Eberhart, R., & Kennedy, J. (1995, October). A new optimizer using particle swarm theory. In *Micro Machine and Human Science, 1995. MHS'95, Proceedings of the Sixth International Symposium on* (pp. 39-43). IEEE.
- Escobar, M. I., & Pimienta, H. J. (2003). *Sistema nervioso*. Universidad del Valle.
- Emotiv. (2014). *Brain Computer Interface & Scientific Contextual EEG*. Emotiv Inc.
- Fernandez-Vargas, J., Pfaff, H. U., Rodríguez, F. B., & Varona, P. (2013). Assisted closed-loop optimization of SSVEP-BCI efficiency.
- Freeman, W. J., & Quiroga, R. Q. (2013). Time-frequency analysis. In *Imaging Brain Function with EEG* (pp. 37-48). Springer New York.
- Friman, O., Volosyak, I., & Graser, A. (2007). Multiple channel detection of steady-state visual evoked potentials for brain-computer interfaces. *IEEE transactions on biomedical engineering*, 54(4), 742-750.

García G. (2008). "High frequency SSVEPs for BCI applications". Philips Research Europe, Eindhoven Netherlands.

Gendreau, M., & Potvin, J. Y. (2010). Handbook of metaheuristics (Vol. 2). New York: Springer.

Ghanbari, A. A., Adinehvand, K., & Nia, M. M. (2014). Overhead Reduction in EEG signals using Particle Swarm Optimization and Independent Component Analysis. *International Journal of Information and Communication Technology Research Volume 4 No. 5, May 2014.*

Gómez Arribas F. J. (2017). Procesamiento Digital de Señal. MS320C5x, E. D. P., & en Web, D. E. M. O. S. T. R. A. C. I. O. N. E. S. Temas Avanzados en Arquitectura de Ordenadores I (TAAO1): Universidad Autónoma de Madrid.

Guger, C., Allison, B. Z., & Müller-Putz, G. R. (2015). Brain-Computer Interface Research: A State-of-the-Art Summary 4. In Brain-Computer Interface Research (pp. 1-8). Springer International Publishing.

Hugdahl, K. (2013). Visual-spatial information processing in the two hemispheres of the brain is dependent on the feature characteristics of the stimulus. *Frontiers in neuroscience*, 7, 10.

Hyvärinen A. Oja E. (2000). "Independent Component Analysis: Algorithms and Applications". Neural Networks Research Centre, Helsinki University of Technology, 13(4-5):411-430,

Ilin, A., & Raiko, T. (2010). Practical approaches to principal component analysis in the presence of missing values. *Journal of Machine Learning Research*, 11(Jul), 1957-2000.

Jian, H. L., & Tang, K. T. (2014, December). "Improving classification accuracy of SSVEP based BCI using RBF SVM with signal quality evaluation". In Intelligent Signal Processing and Communication Systems (ISPACS), 2014 International Symposium on (pp. 302-306). IEEE.

Kennedy, J., & Eberhart, R. C. (1997, October). A discrete binary version of the particle swarm algorithm. In *Systems, Man, and Cybernetics, 1997. Computational Cybernetics and Simulation, 1997 IEEE International Conference on* (Vol. 5, pp. 4104-4108). IEEE.

Kennedy, J., Eberhart, R. C., & Shi, Y. (2001). *Swarm intelligence, 2001*. Kaufmann, San Francisco, 1, 700-720.

Kennerly, R. (2004). QEEG analysis of cranial electrotherapy: a pilot study. *Journal of Neurotherapy, 8*, 112-112.

Kübler, A., & Birbaumer, N. (2008). Brain–computer interfaces and communication in paralysis: extinction of goal directed thinking in completely paralysed patients?. *Clinical neurophysiology, 119*(11), 2658-2666.

Kumaresan R. (2015). Tutorial, F. F. T. University of Rhode Island Department of Electrical and Computational Engineering ELE 436: Communication Systems.

Kuzovkin I. (2013). *Adaptive Interactive Learning: a Novel Approach to Training Brain-Computer Interface Systems*. Tesis Maestría, University of Tartu Faculty of Mathematics and Computer Science Institute of Computer Science.

Lerma, J. (2010). *Cómo se comunican las neuronas* (Vol. 14). Editorial CSIC-CSIC Press.

Liu Q, Chen K, Ai Q, Xie S. Q. (2013). Review: Recent Development of Signal Processing Algorithms for SSVEP-based Brain Computer Interfaces. *Journal of Medical and Biological Engineering, 34*(4): 299-309.

Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., & Arnaldi, B. (2007). A review of classification algorithms for EEG-based brain–computer interfaces. *Journal of neural engineering, 4*(2), R1.

Makeig, S., Westerfield, M., Jung, T. P., Covington, J., Townsend, J., Sejnowski, T. J., & Courchesne, E. (1999). Functionally independent components of the late

positive event-related potential during visual spatial attention. *Journal of Neuroscience*, 19(7), 2665-2680.

Mancera-Galván, E. A., Licon, B. A. G., & Rodríguez-Vázquez, K. (2015). Optimización mediante algoritmo de hormigas aplicado a la recolección de residuos sólidos en UNAM-CU. *Research in Computing Science*, 94, 163-177.

Martínez Albaladejo, F. J. (2014). Evaluación de técnicas computacionales para el análisis lineal de señales electroencefalografías.

Mason, S. G., & Birch, G. E. (2003). A general framework for brain-computer interface design. *IEEE transactions on neural systems and rehabilitation engineering*, 11(1), 70-85.

Merkle, D., & Blum, C. (2008). *Swarm Intelligence: Introduction and Application*.

Millán, J. D. R., Rupp, R., Mueller-Putz, G., Murray-Smith, R., Giugliemma, C., Tangermann, M., & Neuper, C. (2010). Combining brain-computer interfaces and assistive technologies: state-of-the-art and challenges. *Frontiers in neuroscience*, 4, 161.

Millonas, M. M. (1994). Swarms, phase transitions, and collective intelligence. In *SANTA FE INSTITUTE STUDIES IN THE SCIENCES OF COMPLEXITY- PROCEEDINGS VOLUME-* (Vol. 17, pp. 417-417). ADDISON-WESLEY PUBLISHING CO.

Mishra, E. A., Das, D. M., & Panda, D. T. (2013). Swarm intelligence optimization: editorial survey. *International Journal of Emerging Technology and Advanced Engineering*, 3(1), 217-230.

Moore, M. M. (2003). Real-world applications for brain-computer interface technology. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), 162-165.

Moraglio, A., Di Chio, C., & Poli, R. (2007). Geometric particle swarm optimisation. *Genetic Programming*, 125-136.

Muñoz, M. A., López, J. A., & Caicedo, E. F. (2008). Inteligencia de enjambres: sociedades para la solución de problemas (una revisión). *Ingeniería e Investigación*; Vol. 28, núm. 2 (2008); 119-130 *Ingeniería e Investigación*; Vol. 28, núm. 2 (2008); 119-130 2248-8723 0120-5609.

Nan, W., Wong, C. M., Wang, B., Wan, F., Mak, P. U., Mak, P. I., & Vai, M. I. (2011, April). A comparison of minimum energy combination and canonical correlation analysis for SSVEP detection. In *Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference On IEEE*, pp. 469-472.

Nicolas-Alonso, L. F., & Gomez-Gil, J. (2012). Brain computer interfaces, a review. *Sensors*, 12(2), 1211-1279.

Olivas, C. A. N., Gutiérrez, L. C., & Bribiesca, J. A. B. (2010). Mapeo Electroencefalográfico y Neurofeedback.

Omerhodzic, I., Avdakovic, S., Nuhanovic, A., & Dizdarevic, K. (2013). "Energy distribution of EEG signals: EEG signal wavelet-neural network classifier". arXiv preprint arXiv:1307.7897.

Omerhodzic, I., Nuhanovic, A., Dizdarevic, K., Rotim, K., & Avdakovic, S. (2012). "Energy distribution of EEG signal components by wavelet transform". INTECH Open Access Publisher.

Panigrahi, B. K., Shi, Y., & Lim, M. H. (2011). *Handbook of Swarm Intelligence. Series: Adaptation, Learning, and Optimization.*

Parsons, S. (2005). *Independent Component Analysis: A Tutorial Introduction* by James V. Stone, MIT Press, 193 pp, ISBN 0-262-69315-1.

Pedemonte, M., & Cancela, H. (2011). *Ideas recientes en Ant Colony Optimization.*

Pfurtscheller, G., Allison, B. Z., Bauernfeind, G., Brunner, C., Solis Escalante, T., Scherer, R., & Birbaumer, N. (2010). The hybrid BCI. *Frontiers in neuroscience* 4, 3.

Pregenzer, M., Flotzinger, D., & Pfurtscheller, G. (1994). Distinction Sensitive Learning Vector Quantisation-a new noise-insensitive classification method. In *Neural Networks, 1994. IEEE World Congress on Computational Intelligence. 1994 IEEE International Conference on* (Vol. 5, pp. 2890-2894). IEEE.

Pregenzer, M., & Pfurtscheller, G. (1999). Frequency component selection for an EEG-based brain to computer interface. *IEEE Transactions on Rehabilitation Engineering*, 7(4), 413-419.

Renard Y., Lotte F., Gibert G., Congedo M., Maby E., Delannoy V., Bertrand O., & Lécuyer A., (2010). OpenViBE: An Open-Source Software Platform to Design, Test and Use Brain-Computer Interfaces in Real and Virtual Environments. *Presence: teleoperators and virtual environments*, Vol. 19, No 1.

Rosas-Cholula, G., Ramirez-Cortes, J. M., Alarcon-Aquino, V., Gomez-Gil, P., Rangel-Magdaleno, J. D. J., & Reyes-Garcia, C. (2013). "Gyroscope-driven mouse pointer with an EMOTIV® EEG headset and data analysis based on empirical mode decomposition". *Sensors*, 13(8), 10561-10583.

Rutkowski, T. M., Mandic, D. P., Cichocki, A., & Przybyszewski, A. W. (2008, September). "EMD approach to multichannel eeg data-the amplitude and phase synchrony analysis technique". In *International Conference on Intelligent Computing* (pp. 122-129). Springer Berlin Heidelberg.

Sainburg, R. L. (2002). Evidence for a dynamic-dominance hypothesis of handedness. *Experimental brain research*, 142(2), 241.

Sandoval Salazar D. J. (2014). "Análisis de componentes independientes aplicado al estudio de la actividad cerebral". Tesis. Universidad Nacional de Colombia, Facultad de Ciencias, Departamento de Matemáticas, Bogotá D.C., Colombia.

Sanei, S., & Chambers, J. A. (2013). *EEG signal processing*. John Wiley & Sons.

Shenoy, P., Krauledat M.,Blankertz B., Rao R., and Müller K. (Marzo 2006). "Towards adaptive classification for BCI". *J. Neural Eng.*, vol. 3, pp. 13–23-

Singla, R., Khosla, A., & Jha, R. (2013). Influence of stimuli color on steady-state visual evoked potentials based BCI wheelchair control. *Journal of Biomedical Science and Engineering*, 6(11), 1050.

Schalk, G., & Mellinger, J. (2010). A practical guide to brain–computer interfacing with BCI2000: General-purpose software for brain-computer interface research, data acquisition, stimulus presentation, and brain monitoring. Springer Science & Business Media.

Shih, J. J., Krusienski, D. J., & Wolpaw, J. R. (2012, March). Brain-computer interfaces in medicine. In *Mayo Clinic Proceedings* (Vol. 87, No. 3, pp. 268-279). Elsevier.

Sholz M. (2006). "Approaches to analyze and interpret biological profile data". POTSDAM UNIVERSITY. German.

Socha, K., & Dorigo, M. (2008). Ant colony optimization for continuous domains. *European journal of operational research*, 185(3), 1155-1173.

Song, X., Yoon, S. C., & Perera, V. (2013, November). Adaptive common spatial pattern for single-trial EEG classification in multisubject BCI. In *Neural Engineering (NER), 2013 6th International IEEE/EMBS Conference on* (pp. 411-414). IEEE.

Subasi, A. (2007). "EEG signal classification using wavelet feature extraction and a mixture of expert model". *Expert Systems with Applications*, 32(4), 1084-1093.

Stützle, T., & Dorigo, M. (1999). ACO algorithms for the traveling salesman problem. *Evolutionary algorithms in engineering and computer science*, 163-183.

Torres, C. E. T. (2014). Inteligencia colectiva: enfoque para el análisis de redes. *Estudios Gerenciales*, 30(132), 259-266.

Torres, M. E., Colominas, M. A., Schlotthauer, G., & Flandrin, P. (2011, May). "A complete ensemble empirical mode decomposition with adaptive noise". In *Acoustics, speech and signal processing (ICASSP), 2011 IEEE international conference on* (pp. 4144-4147). IEEE

Townsend, J., Westerfield, M., Leaver, E., Makeig, S., Jung, T. P., Pierce, K., & Courchesne, E. (2001). Event-related brain response abnormalities in autism: evidence for impaired cerebello-frontal spatial attention networks. *Cognitive Brain Research*, 11(1), 127-145.

Tumari, S. M., Sudirman, R., & Ahmad, A. H. (2013). "Selection of a suitable wavelet for cognitive memory using electroencephalograph signal". *Engineering*, 5(05), 15.

Ungureanu M., Bigan C., Strungaru R., Lazarescu V. (2004) "Independent Component Analysis Applied in Biomedical Signal Processing". *MEASUREMENT SCIENCE REVIEW*, Volume 4, Section 2.

Vizine, A. L., De Castro, L. N., Hruschka, E. R., & Gudwin, R. R. (2005). Towards improving clustering ants: An adaptive ant-clustering algorithm. *Informatica (Ljubljana)*.

Viteri Dillon, V. G., & Cruz Garcés, H. F. (2007). Optimización de problemas combinatorios y mutiobjetivo utilizando el método de colonia de hormigas (OCH).

Voß, S., Martello, S., Osman, I. H., & Roucairol, C. (Eds.). (2012). *Meta-heuristics: Advances and trends in local search paradigms for optimization*. Springer Science & Business Media.

Volosyak, I., Malechka, T., Valbuena, D., & Gräser, A. (2010, August). A novel calibration method for SSVEP based brain-computer interfaces. In *Signal Processing Conference, 2010 18th European* (pp. 939-943). IEEE.

Weng, S. S., & Liu, Y. H. (2006). Mining time series data for segmentation by using Ant Colony Optimization. *European Journal of Operational Research*, 173(3), 921-937.

Wolpaw, J., & Wolpaw, E. W. (2012). *Brain-computer interfaces: principles and practice*. OUP USA.

Wolpaw, J. R., Birbaumer, N., Heetderks, W. J., McFarland, D. J., Peckham, P. H., Schalk, G., & Vaughan, T. M. (2000). *Brain-computer interface technology: a review*

of the first international meeting. *IEEE transactions on rehabilitation engineering*, 8(2), 164-173.

Wu, C. H., Chang, H. C., Lee, P. L., Li, K. S., Sie, J. J., Sun, C. W., ... & Shyu, K. K. (2011). "Frequency recognition in an SSVEP-based brain computer interface using empirical mode decomposition and refined generalized zero-crossing". *Journal of neuroscience methods*, 196(1), 170-181.

Wu, Z., Lai, Y., Xia, Y., Wu, D., & Yao, D. (2008). Stimulator selection in SSVEP-based BCI. *Medical engineering & physics*, 30(8), 1079-1088.

Xie, J., Xu, G., Wang, J., Zhang, F., & Zhang, Y. (2012). Steady-state motion visual evoked potentials produced by oscillating newton's rings: implications for brain-computer interfaces. *PloS one*, 7(6), e39707.

Zhang(a), Y., Zhou, G., Zhao, Q., Onishi, A., Jin, J., Wang, X., & Cichocki, A. (2011, November). "Multiway canonical correlation analysis for frequency components recognition in SSVEP-based BCIs". In *International Conference on Neural Information Processing* (pp. 287-295). Springer Berlin Heidelberg

Zhang, Y., Jin, J., Qing, X., Wang, B., & Wang, X. (2012). LASSO based stimulus frequency recognition model for SSVEP BCIs. *Biomedical Signal Processing and Control*, 7(2), 104-111.

Zhang, Y., Ma, H., Jin, J., & Wang, X. (2014, July). Adaptive strategy for time window length in SSVEP-based brain-computer interface. In *Mechatronics and Control (ICMC), 2014 International Conference on* (pp. 140-143). IEEE.

Zhang(b), Y., Xu, P., Cheng, K., & Yao, D. (2014). Multivariate synchronization index for frequency recognition of SSVEP-based brain-computer interface. *Journal of neuroscience methods*, 221, 32-40.

Zomaya, A. Y. (Ed.). (2006). *Handbook of nature-inspired and innovative computing: integrating classical models with emerging technologies*. Springer Science & Business Media.

Zhu, D., Bieger, J., Molina, G. G., & Aarts, R. M. (2010). A survey of stimulation methods used in SSVEP-based BCIs. *Computational intelligence and neuroscience*, 2010, 1.

APÉNDICE A

Tabla de Acrónimos

Acrónimo	Descripción
ABC	Artificial Bee Colony
ACO	Ant Colony Optimization
ACS	Ant Colony System
ACSP	Analytic Common Spatial Pattern
AEP	Auditive Evoked Potentials
ALS	Esclerosis Lateral Amiotrófica
AS	Ant System
BCI	Brain Computer Interface
BMI	Brain Machine Interface
BWAS	Best Worst Ant System
CAR	Common Average Referencing
CAS	Cunning Ants
CCA	Cross-Correlation Analysis
CLIS	Complete Locked-In State
CO	Combinatory Optimization
CRT	Cathode Ray Tube
CS	Cuckoo Search
CSS	Charged System Search
CSP	Common Spatial Patterns
CWT	Continuos Wavelet Transform
DFT	Discrete Fourier Transform
DSLVBQ	Distinctive Sensitive Learning Vector Quantization
DWT	Discrete Wavelet Transform
EA	Evolutionary Algorithms
EAS	Elite Ant System
EC	Evolutionary Computation
ECoG	Electrocorticografía
EEG	Electroencefalograma
EEDM	Ensemble Empirical Mode Decomposition
EFM	Ensamble Feature Model
EMD	Empirical Mode Decomposition
EMG	Electromiografía
EOG	electro-oculograma
ERD/ERS	Event Related Desynchronization/ Synchronization
ERN	Event-Related Negativity
ERP	Evoked Related Potentials
FA	Firefly Algorithm
FFT	Fast Fourier Transform
GA	Genetic Algorithm

GSA	Gravitational Search Algorithm
HGA	Hybrid-Binary Genetic Algorithm
HHT	Hilbert-Huang Transform
HT	Hilbert Transform
IA	Iterative Ant
ICA	Independent Component Analysis
ICC	Interface Cerebro Computadora
IDFT	Inverse Discrete Fourier Transform
IMF	Intrinsic Mode Functions
ITR	Information Transfer Rate
IWD	Intelligent Water Drops
LASSO	Least Absolute Shrinkage and Selection Operator
LCD	Liquid Cristal Display
LDA	Linear Discriminant Analysis
LIS	Locked-In State
MCC	Maximum Contrast Combination
MEC	Minimum Energy Combination
MEG	Magneto encefalografía
MFD	Matched Filter Detector
MI	Motors Imaginary
MMAS	Max-Min Ant System
MRI	Imágenes de resonancia magnética funcional
MSI	Multivariate Synchronization Index
NEC	Nased Error Correction
NIRS	Espectroscopia de infrarrojo cercano
OAS	Order Ant System
PDF	Probability Density Function
PET	Tomografía por emisión de positrones
PCA	Principal Component Analysis
PNN	Probabilistic Neural Network
PSDA	Power Spectral Density-Based Analysis
PSD	Power Spectral Density
PSO	Particle Swarm Optimization
RFD	River formation Dynamics
RGZC	Refined generalized zero crossing
RVS	Repetitive Visual Stimulus
SA-UK	Successive averaging unknown output state
SACA	Standard Ant Clustering Algorithm
SC	Stability Coefficient
SCP	Slow Cortical Potentials
SD	Sequence Detection
SDA	Stepwise Discriminant analysis
SDFS	Stepping Delay Flickering Sequence
SFT	Spectralm F-Test
SI	Swarm Intelligence

SL	Surface Laplacian
SNR	Signal to Noise Ratio
SP	Spectral Parameters
SSVEP	Steady State Visually Evoked Potential
SVM	Support Vector Machine
TRF	Time–frequency representation
TSP	Travelling Salesman Problem
TWL	Time Window Length
VEP	Visual Evoked Potentials
WT	Wavelet Transform

APÉNDICE B

PROTOCOLO DE ADQUISICIÓN DE DATOS POR MEDIO DE ELECTROENCEFALOGRAMA PARA LA GENERACIÓN DE INFORMACIÓN QUE PERMITA EL DESARROLLO DE INTERFACES CEREBRALES

1. RESUMEN

El cerebro humano está formado por células llamadas neuronas. Las neuronas son células eléctricamente excitables, procesan y transmiten información vía señales químicas y eléctricas. El electroencefalograma (EEG) es un instrumento de medición no invasivo que permite medir la actividad eléctrica del cerebro en diferentes estados fisiológicos de la persona, vigía, sueño, etc.

La actividad eléctrica del cerebro al ser medible puede ser procesada, por lo cual permite la interacción entre el cerebro humano y una computadora, las **interfaces cerebrales** son sistemas informáticos que traducen las actividades electrofisiológica del cerebro en señales que pueden ser medibles por un dispositivo electromecánico/electrónico. Las interfaces cerebrales tienen por objeto proporcionar un canal de comunicación no-muscular para el envío de comandos al mundo exterior utilizando la actividad eléctrica del cerebro. Las interfaces cerebrales monitorean la actividad cerebral del usuario y traduce sus intenciones en órdenes sin activar ningún músculo o nervio periférico.

El presente estudio pretende generar un banco de datos de señales cerebrales obtenidas por EEG con personas en diferentes estados fisiológicos para poder tener información que permita desarrollar interfaces cerebrales de acuerdo a las necesidades de uso de las personas

2. JUSTIFICACIÓN

Los **interfaces cerebrales, Brain Computer Interface (BCI)** es una tecnología que permite controlar dispositivos electrónicos y/o mecánicos por medio de las ondas cerebrales. El cerebro genera señales eléctricas a través de las conexiones neuronales, esas señales eléctricas pueden ser detectadas por equipos especializados y pueden ser identificadas, y medidas para posteriormente manipularlas desde el exterior para controlar algún dispositivo.

Los sistemas BCI pueden proporcionar una nueva forma de comunicación para usuarios especiales que no se pueden comunicar a través de vías normales. Los interfaces cerebrales han demostrado su aplicabilidad en varios contextos: la conducción de un robot o silla de ruedas, prótesis de funcionamiento, la selección de cartas de un teclado virtual, navegación en Internet o en realidades virtuales, el control de los juegos de computadora, y algunos otros. Este tipo de sistemas es una forma natural para aumentar las capacidades humanas al proporcionar un nuevo enlace de interacción con el mundo exterior y es especialmente relevante como una ayuda para las personas con discapacidad. El principio central de un sistema BCI es la capacidad de distinguir los diferentes patrones de actividad cerebral, cada uno asociado a una intención particular o a una tarea específica.

Los sistemas BCI ofrecen a sus usuarios nuevos canales de comunicación y de control sin ninguna intervención de los nervios periféricos y los músculos. Por lo tanto, muchas investigaciones se centran en la creación de aplicaciones BCI, con la esperanza de que esta tecnología pudiera ser útil para las personas con discapacidades motoras severas.

Las principales poblaciones objetivo para las aplicaciones BCI se dividen en tres clases: El primer grupo CLIS (*Complete Locked-In State*) incluye a personas que han perdido todo el control motor, que se encuentran en fase terminal de Esclerosis Lateral Amiotrófica (ALS) o sufren de parálisis cerebral severa. El segundo grupo LIS (*Locked-In State*) comprende a personas que están casi completamente paralizadas pero con el movimiento voluntario residual, como el movimiento de los ojos, parpadeo de los ojos o contracciones nerviosas con el labio. El tercer grupo de usuarios potenciales incluye personas con capacidades sanas y los que tienen el control neuromuscular, sobre todo de habla y/o control de la mano. Los sistemas BCI tienen poco que ofrecer al tercer grupo, ya que puede enviar la misma información mucho más rápida y fácilmente a través de otras interfaces.

A pesar de esto, los sistemas BCI se utilizan cada vez más el tercer grupo de usuarios, su aplicación principal está en el “*neuro-marketing*” y en los video juegos como una herramienta para revelar la información afectiva de los usuarios, que no pueden ser reportados tan fácilmente a través de interfaces convencionales. Del mismo modo los sistemas BCI se pueden utilizar para algunas personas que sufren de trastornos neurológicos como la esquizofrenia o la depresión.

Independientemente del grupo de personas objetivos, el desarrollo de aplicaciones tiende a centrarse en aquellas que requieren menor tiempo en la interpretación de la intención de la persona y la ejecución del sistema de control (aplicaciones en tiempo real). Por ello se requieren sistemas BCI más rápidos, con una tasa de error menor y de un desempeño más eficiente.

3. ÉTICA DE ESTUDIO

Las consideraciones éticas del presente estudio están basadas en el documento “PAUTAS ÉTICAS INTERNACIONALES PARA LA INVESTIGACIÓN BIOMÉDICA EN SERES HUMANOS” preparadas por el *Consejo de Organizaciones Internacionales de las Ciencias Médicas (CIOMS)* en colaboración con la *Organización Mundial de la Salud (OMS)*, sobre las cuales todos los involucrados en el desarrollo del proceso tendrán pleno conocimiento de las mismas. Cualquier controversia al respecto se hará referencia al documento mencionado anteriormente. Los principios éticos generales en los que se basa el presente estudio son:

- a) **Respeto.**- Por la autonomía de todas las personas normal, que implica que las personas son capaces de deliberar sobre sus decisiones y sean tratadas con respeto por su capacidad de autodeterminación; así mismo proporcionar seguridad contra daño o abuso a todas las personas dependientes o vulnerables.
- b) **Beneficencia.**- El diseño de la investigación está enfocado al beneficio de estudios y desarrollos posteriores en Inteligencia Artificial. Los investigadores tendrán la competencia para proteger el bienestar de los sujetos de estudio.
- c) **Justicia.**- Cada persona que participe en el presente estudio será tratada de manera moralmente correcta y apropiada con énfasis en las personas dependientes o vulnerables.

Confianza.- la información personal, los registros generados por los estudios realizados y el uso de los mismos como parte de éste u otros trabajos de investigación acerca de las personas y de las personas dependientes o vulnerables que participan en el estudio, será tratada de manera confidencial y anónima con el fin de proteger su integridad.

4. ANTECEDENTES

Los sistemas BCI, traducen la actividad electrofisiológica o la tasa metabólica de un sistema nervioso orgánico en señales que pueden ser medibles por un dispositivo electromecánico. El origen de las tecnologías BCI nació con el descubrimiento de la naturaleza eléctrica del cerebro por Richard Caton 1875.

Hans Berger (1924) consiguió registrar la actividad cerebral mediante la electroencefalografía, siendo primero en registrar un EEG de un cerebro humano. Berger consiguió clasificar las diferentes ondas cerebrales.

En los 90's se ha producido un rápido desarrollo en sistemas BCI los cuales han sido capaces de captar señales complejas de córtex cerebral mediante la grabación del conjunto de las señales neuronales y el uso de éstos para controlar dispositivos externos. Grupos de investigación destacados: Richard Andersen, John Donoghue, Phillip Kennedy, Yang Dan, Miguel Nicolelis y Andrew Schwartz. El campo de investigación de los sistemas BCI durante la época de los 90's se ha centrado principalmente en fines médicos, como la implantación de prótesis neuronales para poder recuperar la audición, vista o movilidad dañadas en un individuo.

En mayo del 2000 R. Quian Quiroga, del *John Von Neumann Computing Institute* en Zurich Alemania, presentó un método de un análisis de señales de EEG basadas en eventos visuales y auditivos generando registros de información de diferentes individuos.

El "*Freiburg Center for Data Analysis and Modeling*" de la Universidad de Freiburg, Alemania, fue creado en 1994 con el fin de desarrollar metodología para la obtención de datos por medio de EEG

El Centro Médico de la Universidad de Bonn, Alemania cuenta con un departamento para el estudio de la epilepsia; donde obtiene información de sus pacientes por medio de análisis de las señales de EEG.

5. OBJETIVOS

El objetivo general del presente protocolo es la adquisición de datos por medio de señales de electroencefalograma obtenidas como respuesta a un estímulo visual. Con ello se pretende identificar las frecuencias cerebrales y su ubicación en el cuero cabelludo, contar con información que permita el desarrollo de sistemas de interfaces cerebrales.

6. DESCRIPCIÓN

6.1. Pruebas de búsqueda visual (*Visual Search*)

Resumen: Esta prueba consta de cinco pruebas experimentales. En este, un participante busca un pequeño estímulo dentro de las imágenes.

Imágenes: Imágenes naturales en blanco y negro de 800x600 pixeles se presentan en el centro de la pantalla de 1366x768 pixeles.

Estímulo: El estímulo es un círculo amarillo con un porcentaje de la pantalla del 4 por ciento.

Descripción: El estímulo aparece entre 8 y 16 segundos después del inicio de la imagen en una ubicación aleatorio dentro de la imagen, el sujeto no debe realizar ninguna acción al aparecer el estímulo, solo ubicar su posición en la pantalla con la mirada. 1000 ms después, la imagen se sustituye por una pantalla oscura con una duración de 3000 ms y se repite la prueba cinco veces.

Debido a que el tiempo necesario para mostrar el estímulo en la pantalla varía, el tiempo de la prueba también.


Secuencia:

- Botón para iniciar
- Evento para sincronizar (Pantalla oscura 5s).
- Mostrar imagen en pantalla
- Mostrar estímulo en una ubicación aleatoria dentro de la imagen (8-16 segundos después de la imagen).
- Mostrar pantalla oscura (1000ms después)
- Repetir el experimento cinco veces.

Pantallas:



Pantalla inicial



Pantalla de espera



Imagen en escala de grises



Estímulo dentro de la imagen

6.2 Pruebas de Imágenes Motoras (*Motor Images*)

Resumen: La prueba de imágenes motoras consiste en mostrarle al sujeto de prueba imágenes que asemejen a alguna parte del cuerpo, con cierto orden determinado para cumplir el propósito de la mejor manera.

Imágenes: Imágenes artificiales a color de 800x600 píxeles se presentan en el centro de la pantalla de 1366x768 píxeles.

Estímulo: Los estímulos utilizados son representaciones digitales de las manos de un humano, cada estímulo tiene un código de colores para facilitar la identificación por parte del sujeto de prueba. Las manos abiertas son de color rojo y las manos cerradas son de color azul.

Descripción: El propósito de la prueba es que al ver la imagen mostrada, el sujeto de prueba genere una imagen mental de la parte del cuerpo que representa la imagen y que, al hacerlo, genere un impulso cerebral, el cual podrá ser adquirido y registrado por el sistema de adquisición.


Para facilitar aún más la identificación de las imágenes por parte del sujeto de prueba, en el centro de la prueba hay una cruz en la cual se centraliza la vista del sujeto y a los lados (correspondientemente con las manos) aparecen las imágenes de las extremidades, todo sobre un fondo completamente blanco.

Cada evento (imagen motora mostrada) dura 5 segundos en la pantalla, esto provee un marco de reacción y captura de la señal cerebral. La prueba completa dura 30 segundos.


Secuencia:

- Imagen de estabilización.
- Mano derecha abierta.
- Mano izquierda abierta.
- Ambas manos abiertas.
- Mano derecha cerrada.
- Mano izquierda cerrada.
- Ambas manos cerradas.


Pantallas:



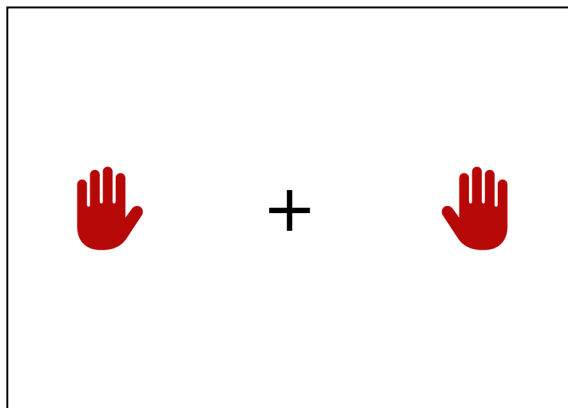
Pantalla de estabilización




Pantalla de mano derecha abierta




Pantalla mano izquierda abierta



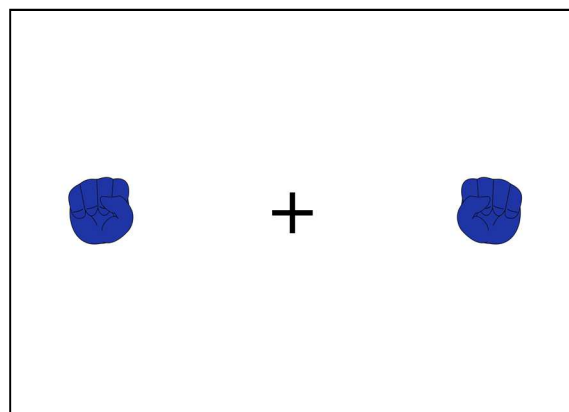
Pantalla ambas manos abiertas



Pantalla mano izquierda cerrada



Pantalla mano derecha cerrada



Pantalla ambas manos cerradas

6.3 Pruebas de discriminación visual de las 5 cajas (*Visual 5 Box*)



Resumen: Se busca obtener datos relacionados a estímulos en las señales cerebrales durante un ejercicio de atención simple. Aquí se busca encontrar la diferencia entre estímulos relacionados a la atención y los no relacionados a la atención. A diferencia a las pruebas visuales, el sujeto debe discriminar entre diferentes tipos de estímulos que son presentados a velocidad alta.

Estímulos: Los estímulos que ocurren dentro de esta caja son estímulos atendidos. Estímulos dentro de las cajas azules se conocen como estímulos no atendidos. Todas las pruebas contienen 100 estímulos en total; 80 son no atendidos y 20 son atendidos. Los estímulos son presentados al sujeto en una posición aleatoria a 250ms, 500ms, 750ms, y 1 segundo. Los estímulos duran 200ms en la pantalla antes de desaparecer.

- Variante Discriminación Simple: Los estímulos son círculos rojos dentro de las 5 cajas. 120 (25%) eventos atendidos y 480 (75%) eventos no atendidos.
- Variante Discriminación Compuesta: Los estímulos son cajas rellenas de su color original. 120 (25%) eventos atendidos y 480 (75%) eventos no atendidos
- Variante Discriminación Combinada: Prueba considera ambas pruebas anteriores. La mitad de los estímulos son de variante simple y la otra mitad de variante compuesta. Los estímulos

atendidos son solo los **círculos rojos**. 35 (25%) eventos atendidos y 105 (75%) eventos no atendidos.

Descripción de la Pantalla de Prueba: La prueba de las 5 cajas está diseñada para la obtención de Potenciales cerebrales relacionados con eventos (ERPs). En la prueba los usuarios fijan su vista en una cruz, por encima de la cual se exhibieron constantemente cinco cajas (cuadros) Fig. 1. Cada bloque de prueba es de 76 s, una de las cajas fue de diferente color (color verde). La ubicación de éste cuadro fue de manera aleatoria durante los periodos de pruebas. Una serie de círculos se presentaron brevemente en cualquiera de las cinco cajas en un orden aleatorio. Se le pidió al usuario se concentrara cada vez que un disco apareciera en uno de los cuadros se registraron a partir de sujetos que asistieron a las secuencias aleatorias de discos llenos aparecen brevemente en el interior de una de las cinco plazas vacías que fueron mostrados (Townsend y Courchesne 1994). Los contornos cuadrados de 1,6 cm se muestran sobre un fondo negro en ángulos visuales horizontales de 0° , $\pm 2.7^\circ$ y $5.5^\circ \pm$ de fijación. Durante cada bloque de 76-s de los ensayos, una de las cinco líneas generales era de color verde y los otros cuatro azul. El cuadrado verde marcó la ubicación a la que asistirán. Esta ubicación se varió con el fin de contrapeso al azar a través de bloques. En cada bloque, 100 estímulos (llenos discos rojos) se muestran para 117 ms en una de las cinco plazas vacías en una secuencia pseudo-aleatoria con intervalos inter-estímulo (ISIS) de 250 a 1000 ms (en cuatro equiprobables pasos de 250 ms). Scott Makeig et al 1999, Halgren et al., 1980; Knight et al., 1989, Ford et al., 1994; Ebmeier et al., 1995.



Pantalla de estímulos

7. GRUPOS DE ESTUDIO

Los sujetos que participen en la elaboración de las pruebas descritas en este protocolo deben presentarse de manera voluntaria y estar de acuerdo con el procedimiento, firmar la carta de consentimiento y la carta de confidencialidad. En caso de ser menores de edad el consentimiento para participar en las pruebas deberá ser autorizado y firmado por alguno de sus padres o tutores. Se definen 2 grupos de estudio,

Grupo A (Normal): Sujetos pertenecientes a grupos sociales No vulnerables, sujetos sanos, ambos sexos, de edad indistinta mayores de edad, indistinto si son diestros o zurdos, con visión regular o con lentes (no cirugías oculares), no estar bajo tratamiento médico ni tomar medicamentos. Se excluyen a las mujeres embarazadas.

Grupo B (Vulnerable): Sujetos pertenecientes a grupos sociales vulnerables, sujetos limitados en sus capacidades físicas o genéticas, ambos sexos, menores de edad entre 10-17 y mayores de edad entre 18-30 años, indistinto si son diestros o zurdos, con visión regular o con lentes (no cirugías oculares), no estar bajo tratamiento médico ni tomar medicamentos. Se excluyen a mujeres embarazadas

La inclusión de sujetos pertenecientes a grupos sociales vulnerables se justifica por ser parte de las poblaciones objetivo CLIS, ALS y LIS del desarrollo de interfaces cerebrales. El proceso de pruebas no presenta riesgo alguno sin embargo es recomendable que los sujetos de estudio de ambos grupo se presenten con un período de descanso de 6-8 horas, y cualquier sujeto puede suspender el procedimiento en el momento que él lo desee.

8. GLOSARIOS DE TÉRMINOS

BCI.- Brain Computer Interface (Interface computadora cerebro) Sistema que traduce la actividad electrofisiológica o la tasa metabólica de un sistema nervioso orgánico en señales que pueden ser medibles por un dispositivo electromecánico.

Electroencefalograma (EEG).- Instrumento de medición no invasivo que permite medir la actividad eléctrica del cerebro en diferentes estados fisiológicos de la persona, vigía, sueño, etc.

Electrodo.- Dispositivos electrónicos que permiten medir las corrientes iónicas producidas por la distribución de potencial creada en el interior del tejido vivo en corrientes eléctricas.

Eventos Visuales.- reflejan la actividad cerebral producida por el procesamiento de la información visual y pueden ser registrados en la zona occipital, visual de la corteza cerebral.

Interface Cerebral.- Sistemas informáticos que traducen las actividades electrofisiológica del cerebro en señales que pueden ser medibles por un dispositivo electromecánico/electrónico.

Potenciales evocados visuales (PEV).- resultan de los cambios producidos en la actividad bioeléctrica cerebral tras estimulación luminosa.

Ritmos Cerebrales.- Identificación de las frecuencias (Hz) de las señales cerebrales, el estado fisiológico del sujeto.

Señal Cerebral.- Serie de potenciales eléctricos (μV) que fluctúan a través del tiempo.

Sistema Internacional 10-20.- Sistema definido para colocación de electrodos sobre el cuero cabelludo, denominado así porque los electrodos están espaciados entre el 10% y el 20% de la distancia total entre puntos reconocibles del cráneo. Estos puntos clave, a partir de los cuales se

realizan las medidas, son: Nasión, Inión y Punto pre-auricular del pabellón de la oreja derecha e izquierda. El presente estudio utiliza una diadema que lleva incorporados 16 electrodos, y se coloca directamente sobre la cabeza del sujeto. Los electrodos se unen en un conector y éste, a su vez, conecta con el cabezal del EEG (lugar donde se recoge la actividad eléctrica de cada electrodo).

Sistemas Invasivos.- Adquisición de señales cerebrales por medio de electrodos implantados directamente en el cerebro.

Sistemas No Invasivos.- Adquisición de las señales cerebrales por medio de electrodos, colocados en la superficie del cuero cabelludo.

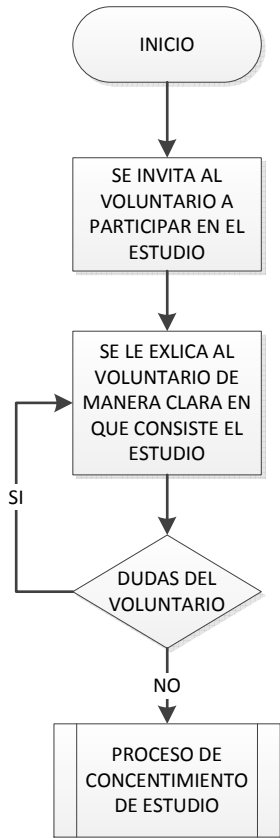
9. MATERIALES Y EQUIPOS

- a) Electroencefalograma portátil marca EMOTIV, modelo "EPOC+": Multicanal de alta resolución con 16 electrodos (14 canales con 2 canales de referencia). Tasa de transferencia de 128-256 bits por canal. Frecuencia de respuesta de 0.16-43 Hz. Resolución de 14-16 bits por canal. Rango dinámico de +/- 4.17mV. Tecnología de sensores salina. Conectividad USB 3.0 inalámbrica 2.4GHz y Bluetooth 4.0.
- b) Módulo de adquisición de datos RAW EEG DATA Bluetooth 4.0
- c) Solución salina para la hidratación de los electrodos.
- d) "Hydrator Pack" para 16 electrodos

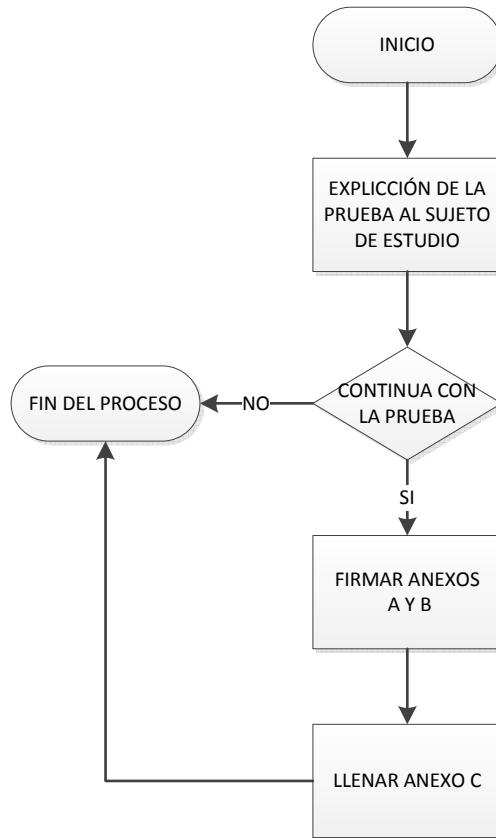
10. METODOLOGÍA

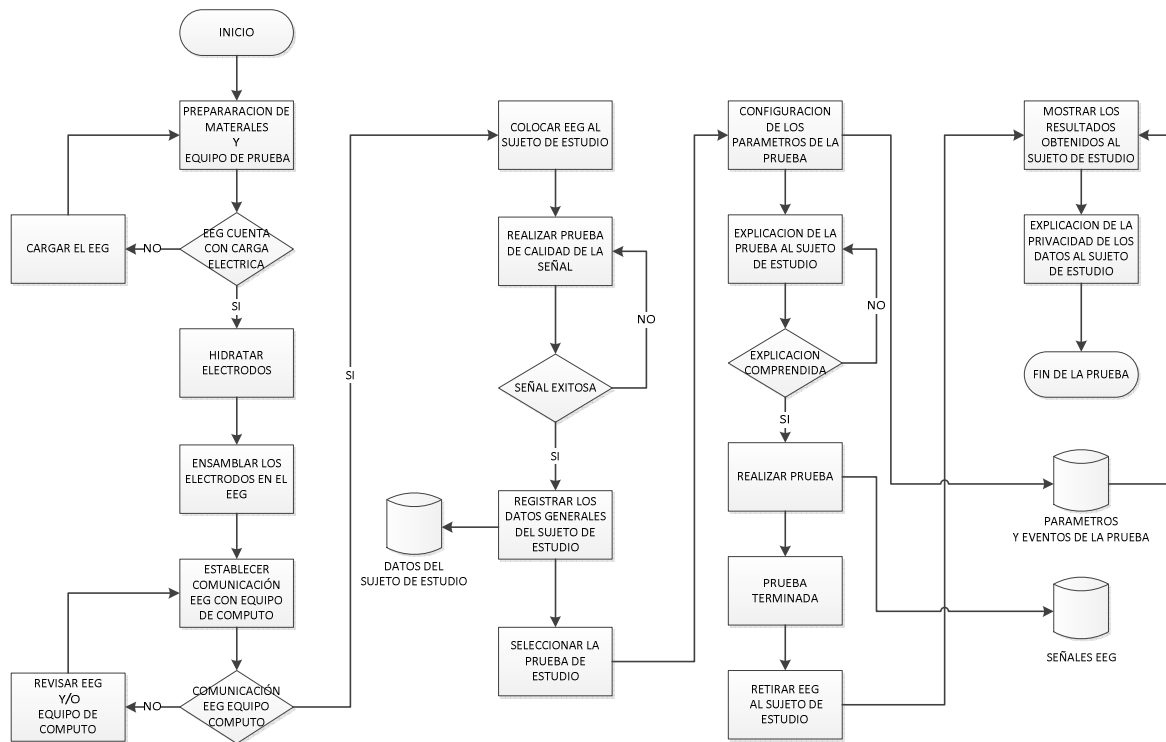
10.1. Diagramas de Flujo

Proceso de invitación al estudio



Proceso de Consentimiento de estudio





Proceso de Obtención de Datos

10.2. Descripción del proceso de la prueba:

1. Se explicará al posible voluntario de manera clara y precisa el objetivo del estudio, las generalidades del proceso de prueba y en qué consisten las pruebas que se le van a realizar; así como se le brindará la oportunidad de realizar preguntas las cuales deberán ser contestadas a su total satisfacción. Si el voluntario y/o el responsable del voluntario deciden no continuar con la prueba, se dará por terminada la sesión.
2. Si el voluntario y/o responsable del voluntario deciden continuar con la prueba, se procederá a firmar la **carta de consentimiento para estudio** (Anexo A), la **carta de confidencialidad** (Anexo B) y posteriormente se llenará el **formulario de registro de datos** (Anexo C).
3. Para el inicio de las pruebas lo primero que se deba hacer es organizar y preparar los materiales y equipos a utilizar (Figura 1):
 - a) Electroencefalograma Epoc+ Emotiv
 - b) Transceiver USB Receiver
 - c) Sistema de Pruebas
 - d) Kit de hidratación de electrodos
 - e) Solución salina




Figura 1. Equipo a Utilizar

4. Asegurarse que el electroencefalograma cuente con carga de energía
5. En caso de ser necesario asegúrese de que el “switch” del electroencefalograma esté en posición de “off”, antes de conectarlo a la corriente eléctrica. Coloque el conector USB al electroencefalograma y a la computadora, o en su caso a la alimentación de corriente. El tiempo estimado de carga al 100% es de 4 hrs. (Figura 2).




Figura 2. Carga de energía del electroencefalograma

6. Hidratar los electrodos con solución salina. Colocar los electrodos en el “Hydator Pack” y aplicarles la solución salina, un par de gotas por electrodo (Figura 3).



Figura 3. Proceso de hidratación de electrodos

7. Ensamblar los electrodos en el electroencefalograma como se muestra en la figura 4.a, Cuando no se estén utilizando los electrodos removerlos del electroencefalograma (Figura 4.b y guardarlos en el “Hydrator Pack”.




Figura 4. (a) ensamble del electrodo (b) remover el electrodo

8. Insertar el receptor Transceiver USB Receiver en el puerto USB de la computadora que contiene el sistema de pruebas y colocar el interruptor de encendido del electroencefalograma (Figura 5)




Figura 5. Colocación del Transceiver USB y encendido del electroencefalograma

9. Realizar la prueba de comunicación entre el Transceiver USB y el electroencefalograma Epoch+ Emotiv
10. Colocar el Electroencefalograma en la cabeza del sujeto de estudio asegurándose de que dicho sujeto esté cómodo y que los electrodos estén colocados en la posición correcta (Figura 6 y 7) y haciendo contacto con el cuero cabelludo.






Figura 6. Colocación del Electroencefalograma




Figura 7. Ubicación de los Electroodos sistema Internacional 10-20

11. Una vez esté el sujeto instrumentado se procede a sentarlo en una silla la cual debe estar a máximo 70 cm aproximadamente de la pantalla que esté, generando el estímulo, procurando que quede lo más cómodo posible ya que esto le va a permitir un mejor confort durante la prueba.
12. Se procede con la prueba de calidad de la señal para asegurarse que el equipo de cómputo recibe la información del electroencefalograma Figura 8.

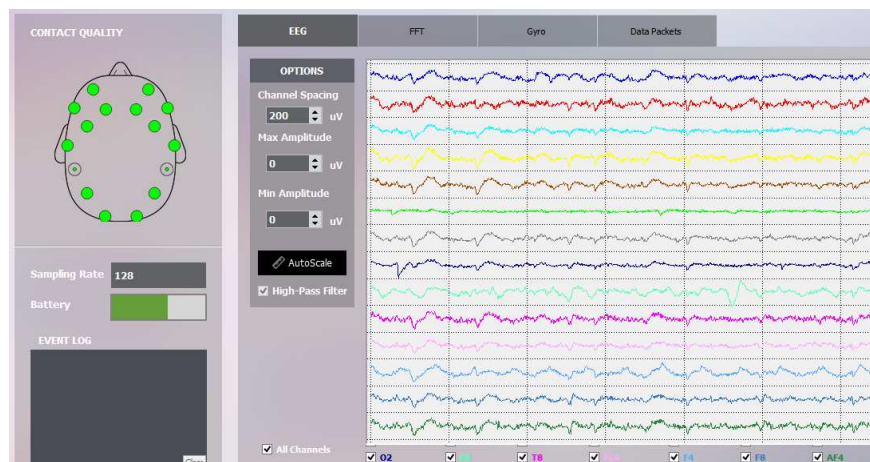


Figura 8. Prueba de correcta calidad de las señales del electroencefalograma.

13. Si la prueba de comunicación es un éxito. Se procede a registrar los datos del sujeto en el sistema
14. Se procede a seleccionar la prueba que realizará el sujeto (descritas en el punto 6 de éste protocolo)
15. Se procede a configurar los parámetros de tiempos e intervalos con base a la prueba seleccionada
16. Se procede con la explicación al sujeto de prueba de la importancia de concentrarse en el estímulo correspondiente a la prueba seleccionada.
17. Se realiza la prueba
18. Al término de la prueba se procederá a retirar el electroencefalograma del sujeto.
19. Se le proporcionará información al sujeto sobre la privacidad de sus datos personales y sobre el libre acceso de las señales generadas, así mismo de cómo puede acceder a las mismas.
20. Se le agradecerá a la persona por su tiempo y por su participación en el estudio

10.3. Recomendaciones para el usuario

Las siguientes recomendaciones permitirán obtener una mejor calidad de la señal obtenida por los electrodos del electroencefalograma

- a) El cabello debe de estar limpio y sin ninguna sustancia artificial como gel o aerosoles
- b) En el caso de las mujeres con cabello largo traer el cabello recogido.
- c) Se recomiendan por lo menos 6 (seis) horas de sueño previas a la realización del estudio
- d) El tiempo de ayuno para la prueba debe ser mínimo de 1 (una) hora
- e) En caso de estar bajo tratamiento médico y estar tomando algún medicamento se recomienda que la ingestión del último medicamento sea 1 (una) hora antes de la prueba

11. FORMULARIOS

El presente estudio cuenta con:

- a) Formulario de Registro de Datos EEG (Anexo C)

12. RIESGOS

El presente estudio no genera riesgos de ningún tipo para el sujeto de estudio, debido a que se realizaron todas las comprobaciones de posibles riesgos eléctricos en el sistema de adquisición de datos, el cual consta de diez y seis electrodos superficiales no invasivos para la toma de las señales cerebrales (EEG) colocados en posiciones específicas en el cuero cabelludo. Sin embargo no se eximen riesgos mínimos al sujeto por presentar reacciones adversas conocidos o previsibles, durante el proceso del estudio.

13. MOLESTIAS

Al participar de esta investigación es posible que el sujeto experimente algún tipo de incomodidad mínima por la colocación de los electrodos o cansancio frente a los estímulos visuales. Para disminuir al máximo este tipo de molestias, se programaron pruebas de corta duración.

14. BENEFICIOS

La presente investigación permitirá obtener un banco de datos de señales de electroencefalograma con características y elementos específicos que permitirá a la comunidad científica utilizar dicha información para el desarrollo de aplicaciones de interfaces cerebrales, las cuales permitirán genera un desarrollo para las poblaciones objetivos descritas en el punto 2 del presente protocolo

15. INCENTIVOS

No hay ningún incentivo económico al participar de este proyecto, así como no se ofrecerán regalos, servicios o algún otro recurso material o económico.

16. GESTIÓN DE LA CONFIDENCIALIDAD DE LOS DATOS

La información proporcionada por el sujeto de estudio y utilizada para el desarrollo del proceso de adquisición de datos será gestionada bajo la “ética de estudio” descrita en el punto 3 del presente protocolo y con base a las cartas presentados en los Anexos A, B. Los datos generados por el presente protocolo serán utilizados únicamente con fines de investigación y que estarán a disponibilidad del público en general institución y/o organización interesada en dichos datos y podrán ser utilizados con base a sus intereses. la información personal proporcionada por los sujetos de estudio en el presente protocolo, estará resguardada y protegida bajo la LEY FEDERAL DE PROTECCIÓN DE DATOS PERSONALES EN POSESIÓN DE LOS PARTICULARES DE LOS ESTADOS UNIDOS MEXICANOS, en su Capítulo II artículos 11, 12, 19, 21, 24, 36, 44, 47; Capitulo III artículos 63, 64, 65, 66 y Capitulo VII artículos 101, 102, 103, 106, 109. La información generada por el presente estudio será presentada bajo los lineamientos descritos en el punto 17 del presente protocolo y por el formulario del Anexo C.

16.1. Procedimiento

El Procedimiento para la gestión de la información proporcionada por los sujetos de estudios y la generada por las pruebas realizadas se describe a continuación:

1. Se explicará al candidato a participar y/o al responsable del candidato a participar, de manera clara y precisa, el objetivo del estudio, las generalidades del proceso de pruebas y se le(s) brindará la oportunidad de realizar preguntas las cuales deberán ser contestadas a su total satisfacción. Si el candidato y/o responsable del candidato de estudio deciden no participar en el estudio, se dará por terminada la sesión.
2. Si el candidato a participar y/o el responsable del candidato a participar deciden participar en el estudio entonces se procederá al llenado de la CARTA DE CONSENTIMIENTO, CARTA DE CONFIDENCIALIDAD y REGISTRO DE DATOS EEG, descritos en los Anexos A, B, C, del presente protocolo
3. El investigador llenará los siguientes campos de la CARTA DE CONSENTIMIENTO:
 - a. Fecha
 - b. No. Registro
 - c. Nombre y Firma del Investigador
 - d. Tel.
 - e. email
4. El sujeto de estudio, el investigador y/o el responsable del sujeto de estudio procederán a llenar los siguientes campos de la CARTA DE CONSENTIMIENTO:

- a. Estado de salud
 - b. Sexo
 - c. Años de edad
 - d. Lentes
 - e. Diestro/zurdo
 - f. Fuma
 - g. Grupo
 - h. Está bajo tratamiento médico
 - i. Toma algún medicamento
 - j. Nombre y firma del sujeto de estudio
 - k. Nombre y firma del responsable del sujeto de estudio (si aplica)
5. El investigador llenará los siguientes campos de la CARTA DE CONFIDENCIALIDAD:
- a. Fecha
 - b. No. Registro
6. El sujeto de estudio, el investigador y/o el responsable del sujeto de estudio procederán a llenar los siguientes campos de la CARTA DE CONFIDENCIALIDAD:
- a. El (la) que suscribe
 - b. Responsable de
 - c. Nombre y Firma del sujeto de estudio
 - d. Nombre y firma del responsable del sujeto de estudio (si aplica)
7. El investigador llenará los siguientes campos de formato de REGISTRO DE DATOS EEG PARA EL ESTUDIO DE INTERFACES CEREBRALES:
- a. No. registro
 - b. Fecha
 - c. Tester ID (identificación del investigador que realizará la prueba)
 - d. Hora
 - e. Test No. (número de prueba a realizar)
 - f. File ID (identificación del archivo que almacenará los datos obtenidos)
 - g. Grupo (grupo de estudio)
 - h. Tipo de estudio
 - i. Datos del estudio
 - j. Identificación de electrodos
 - k. Observaciones (si aplica)
8. La información obtenida por el sujeto de estudio y/o el responsable del sujeto de estudio serán registradas en el sistema informático de pruebas. la CARTA DE CONCENTIMIENTO y la CARTA DE CONFIDENCIALIDAD, serán archivadas en la carpeta “INFORMACION CONFIDENCIAL” (color rosa) y se mantendrá de manera separa del área de pruebas. El REGISTRO DE DATOS EEG PARA EL ESTUDIO DE INTERFACES CEREBRALES, será archivada en la carpeta “DATOS EEG” (color azul) y se mantendrá en el área de pruebas durante toda la duración de las mismas.

16.2. Identificación de archivos de datos

El sistema genera los siguientes archivos de datos

- Archivo de señales de electroencefalograma formato EDF
- Archivo de señales de electroencefalograma formato SCV
- Archivo de eventos formato TXT
- Archivo de datos del sujeto de estudio formato TXT
- Archivo de registro de registro de datos de las señales EEG formato PDF

El formato de identificación de los archivos de señales de electroencefalograma y del archivo de eventos está compuesto de la siguiente manera:

GRUPO	ID DEL SUJETO			TIPO DE DATOS	TIPO DE ESTUDIO	SUB-TIPO DE PRUEBA	INSTANCIA DE LA PRUEBA		EXTENSIÓN DEL ARCHIVO
A	0	0	1	S	M	1	_	1	.ext

Descripción de los campos

- Grupo: Grupo A / B
- ID del Sujeto: No. de Registro
- Tipo de Datos: E → Eventos, S → Señales
- Tipo de Estudio: V → Visual Search, M → Motor Hand Shake, B → 5 Cajas
- Sub-tipo de prueba: (específicamente para la prueba de las 5 cajas) 1 → discriminación simple, 2 → discriminación compuesta, 3 → discriminación combinada
- Instancia de la prueba: número de veces que se repite la prueba
- .ext: Extensión del archivo: EDF → archivo generado por el electroencefalograma, SCV → archivo de exportación de datos de EDF a TXT, TXT → archivo de eventos de las pruebas

17. RESULTADOS

Los resultados obtenidos, y la información generada por el proceso de estudio serán utilizados únicamente con fines de investigación y estarán a disponibilidad del público en general institución y/o organización interesada en dichos datos y podrán ser utilizados con base a sus intereses. La identificación de la pruebas se presentarán de manera anónima y únicamente serán identificados por medio del No. de registro. La información se encontrará disponible en la página web <http://informatica.uaq.mx/academia/doctorado/Santiago/PromepSFF.html>. Así mismo queda estipulado que la información personal del sujeto de estudio estará resguardada y protegida bajo las leyes mexicanas de protección de la información. Los resultados se presentarán bajo el siguiente formato

No. registro	INFORMACIÓN DEL SUJETO					INFORMACIÓN DE LA PRUEBA					
	Grupo	Género	Edad	Condición manual	Visión	Taza transferencia (HZ)	Datos sesión	Tipo estudio	Duración MIN	Localización canales	Tipo de localización de canales
123	A	F	24	DIESTRO	REGULAR	128	A123SV1_1.PDF	VISUAL	2	A123SV1_1.SCV	10-20
45	B	M	14	ZURDO	LENTE	128	A045SM1_1.PDF	MOTORA	4	A045SM1_1.SCV	10-20

18. FORMATOS DE CONFIDENCIALIDAD

El presente estudio cuenta con:

- a) CARTA DE CONSENTIMIENTO PARA ESTUDIO (Anexo A)
- b) CARTA DE CONFIDENCIALIDAD (Anexo B)

19. REFERENCIAS

Diario Oficial de la Federación, 23 de Diciembre de 1986, Reglamento de la Ley General de Salud en Materia de Investigación para la Salud, México D.F.

Ética de la investigación científica, 2014, José Salvador Arellan, Robert T. Hall, Jorge Hernández Arriaga Universidad Autónoma de Querétaro.

Manual básico para enfermeros en electroencefalografía, 2011, Teresa Talamillo García, Enfermería Docente, 94: 29-33.

Pautas Éticas Internacionales Para La Investigación Biomédica En Seres Humanos, 2002, Preparadas por el Consejo de Organizaciones Internacionales de las Ciencias Médicas (CIOMS) en colaboración con la Organización Mundial de la Salud (OMS), Ginebra Suiza

Pautas y orientación operativa para la revisión ética de la investigación en salud con seres humanos, 2012, Organización Panamericana de la Salud, Washington D.C. ISBN 978-92-75-31725-9

Sistema de reconocimiento de patrones de potenciales evocados visuales de estado estacionario, 2013, Jairo Antonio Cuartas Molina, Tesis Maestría en Ingeniería Biomédica, Escuela de Ingeniería de Antioquia, Medellín, Colombia.

Reglamento de la Ley Federal de Protección de Datos Personales en Posesión de los Particulares, texto vigente, publicado en el Diario Oficial de la Federación el 21 de diciembre de 2011

20. FINANCIAMIENTO

El presente estudio fue patrocinado por la Universidad Autónoma de Querétaro, a través de su programa *Fondo de Proyectos Especiales de Rectoría (FOPER)* en su convocatoria 2015 por un monto de \$44,771.00 MXN (cuarenta y cuatro mil setecientos setenta y un peso 00/100 M.N.). La Institución se compromete a proporcionar los fondos económicos para la adquisición del equipo electrónico, el software y los suministros para su operación, así como el acervo bibliográfico y becas para los estudiantes que colaborarán en el proyecto. El investigador responsable y sus colaboradores se comprometen a entregar el manual de operación del estudio, un sistema computacional de pruebas basadas en eventos visuales, el banco de datos generado por las pruebas implementadas y un mapa de identificación de las señales cerebrales con referente a la ubicación espacial en el cuero cabelludo de los electrodos.





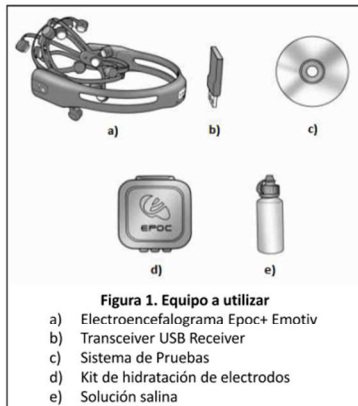
21. CRONOGRAMA DEL ESTUDIO

Actividad	Fecha inicio	Fecha termino
Adquisición de Equipo de laboratorio de adquisición de datos	01/02/2015	15/01/2015
Identificar el funcionamiento de los equipos de adquisición de datos (Electroencefalograma)	15/02/2015	28/02/2015
Identificación del funcionamiento de los diferentes sistemas que lo acompañan a los equipos de adquisición de datos	15/02/2015	28/02/2015
Definir las pruebas a realizar para cada uno de los estados fisiológicos que se desean analizar Establecer la metodología del proceso de implementación de las pruebas	01/03/2015	15/03/2015
Diseñar el manual de operación del protocolo de pruebas	15/03/2015	31/03/2015
Establecer la relación de los ritmos cerebrales Delta, Theta, Beta, Alpha y Gamma con base a su colocación espacial y espectral de los electrodos en el cuero cabelludo	01/04/2015	10/04/2015
Diseñar y elaborara el manual de operación del mapa de identificación de los ritmos cerebrales	13/04/2015	17/04/2015
Analizar, diseñar, implementar y documentar programas informáticos para la detección de estados cerebrales basados en imágenes motoras	01/05/2015	15/05/2015
Analizar, diseñar, implementar y documentar programas informáticos para la detección de estados cerebrales basados en eventos visuales	01/05/2015	15/05/2015
Analizar, diseñar, implementar y documentar programas informáticos para la detección de estados cerebrales basados en ritmos cerebrales P300	16/05/2015	31/05/2015
Analizar, diseñar, implementar y documentar interface de comunicación entre el equipo de adquisición de datos y los programas informáticos de detección de estados cerebrales	16/05/2015	31/05/2015
Diseñar, implementar y documentar el prototipo del sistema de adquisición de datos	01/06/2015	07/06/2015
Implementar sesiones de pruebas para verificar el funcionamiento adecuado del prototipo del sistema de adquisición de datos	07/06/2015	30/06/2015
Diseñar y elaborar el manual del prototipo del sistema de adquisición de datos	07/06/2015	15/06/2015
Implementar el prototipo del sistema de adquisición de datos	01/07/2015	31/07/2015
Generar sesiones de pruebas para la generación del banco de datos.	01/07/2015	31/07/2015
Documentar el proceso de la adquisición de datos con base al protocolo de pruebas.	01/07/2015	31/07/2015
Diseñar y publicar sitio web con el banco de pruebas para su difusión	01/08/2015	15/08/2015
Elaborar y publicar resultados en revistas científicas	01/07/2015	31/08/2015
Generar avances en el desarrollo de tesis doctoral	01/02/2015	31/08/2015
Registrar manuales y prototipo antes derechos de autor	01/08/2015	31/08/2015

GUÍA PREPARACIÓN DE PRUEBAS DE SEÑALES DE ELECTROENCEFALOGRAMA

GUIA PREPARACIÓN DE PRUEBAS DE SEÑALES DE ELECTROENCEFALOGRAMA

- Se explicará al posible voluntario de manera clara y precisa el objetivo del estudio, las generalidades del proceso de prueba y en qué consisten las pruebas que se le van a realizar; así como se le brindará la oportunidad de realizar preguntas las cuales deberán ser contestadas a su total satisfacción. Si el voluntario y/o el responsable del voluntario deciden no continuar con la prueba, se dará por terminada la sesión.
- Si el voluntario y/o responsable del voluntario deciden continuar con la prueba, se procederá a firmar la **carta de consentimiento para estudio**, la **carta de confidencialidad** y posteriormente se llenará el **formulario de registro de datos**.
- Para el inicio de las pruebas lo primero que se deba hacer es organizar y preparar los materiales y equipos a utilizar (Figura 1):
- Asegurarse que el electroencefalograma cuente con carga de energía
- En caso de ser necesario asegúrese de que el "switch" del electroencefalograma esté en posición de "off", antes de conectarlo a la corriente eléctrica. Coloque el conector USB al electroencefalograma y a la computadora, o en su caso a la alimentación de corriente. El tiempo estimado de carga al 100% es de 4 hrs. (Figura 2).
- Hidratar los electrodos con solución salina. Colocar los electrodos en el "Hydrator Pack" y aplicarles la solución salina, un par de gotas por electrodo (Figura 3).
- Ensamblar los electrodos en el electroencefalograma como se muestra en la figura 4.a, cuando no se estén utilizando los electrodos removerlos del electroencefalograma (Figura 4.b y guardarlos en el "Hydrator Pack").
- Insertar el receptor Transceiver USB Receiver en el puerto USB de la computadora que contiene el sistema de pruebas y colocar el interruptor de encendido del electroencefalograma (Figura 5)
- Realizar la prueba de comunicación entre el Transceiver USB y el electroencefalograma Epoc+ Emotiv
- Colocar el Electroencefalograma en la cabeza del sujeto de estudio asegurándose de que dicho sujeto esté cómodo y que los electrodos estén colocados en la posición correcta (Figura 6 y 7) y haciendo contacto con el cuero cabelludo
- Una vez esté el sujeto instrumentado se procede a sentarlo en una silla la cual debe estar a máximo 70 cm aproximadamente de la pantalla que esté, generando el estímulo, procurando que quede lo más cómodo posible ya que esto le va a permitir un mejor confort durante la prueba.
- Se procede con la prueba de calidad de la señal para asegurarse que el equipo de cómputo recibe la información del electroencefalograma.
- Si la prueba de comunicación es un éxito. Se procede a registrar los datos del sujeto en el sistema
- Se procede a seleccionar la prueba que realizará el sujeto (descritas en el punto 6 de éste protocolo)
- Se procede a configurar los parámetros de tiempos e intervalos con base a la prueba seleccionada
- Se procede con la explicación al sujeto de prueba de la importancia de concentrarse en el estímulo correspondiente a la prueba seleccionada.
- Se realiza la prueba
- Al término de la prueba se procederá a retirar el electroencefalograma del sujeto.
- Se le proporcionará información al sujeto sobre la privacidad de sus datos personales y sobre el libre acceso de las señales generadas, así mismo de cómo puede acceder a las mismas.



Base de Datos

No. Registro	INFORMACION DEL SUJETO DE ESTUDIO										INFORMACION DE LA PRUEBA									
	GRUPO	GENERO	EDAD	CONDICION MANUAL	SANO	LENTES	FUMIA	TREATAMIENTO MEDICO	MEDICAMENTOS	HORAS SUEÑO	HORAS AYUNO	TAZA DE TRANSFERENCIA	TIPO DE PRUEBA	NOMBRE PRUEBA	No. EVENTOS	DURACION DEL EVENTO (ms)	DATOS DE LA SESION	REGISTRO DE DATOS	TIEMPO DE ESTABILIZACION	DURACION DE LA PRUEBA (s)
1	A	MASC	48	ZURDO	SI	SI	NO	SI	SI	6	2	128	VISUAL	IMAGE SEARCH	5	250	A0035V1_1.EDF	A0035V1_1.PDF	5	96
1	A	MASC	49	ZURDO	SI	SI	NO	SI	SI	6	2	128	VISUAL	FIVE BOX 1	5	250	A0035B1_1.EDF	A0035B1_1.PDF	5	71
1	A	MASC	50	ZURDO	SI	SI	NO	SI	SI	6	2	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0035M1_1.EDF	A0035M1_1.PDF	25	46
2	A	MASC	22	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0025B1_1.EDF	A0025B1_1.PDF	5	67
2	A	MASC	22	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0025B2_1.EDF	A0025B2_1.PDF	5	70
2	A	MASC	22	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	FIVE BOX 3	20	250	A0025B3_1.EDF	A0025B3_1.PDF	5	70
2	A	MASC	22	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0025M1_1.EDF	A0025M1_1.PDF	25	39
2	A	MASC	22	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0025V1_1.EDF	A0025V1_1.PDF	5	89
3	A	MASC	21	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0035B1_1.EDF	A0035B1_1.PDF	5	67
3	A	MASC	21	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0035B2_1.EDF	A0035B2_1.PDF	5	68
3	A	MASC	21	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 3	20	250	A0035B3_1.EDF	A0035B3_1.PDF	5	66
3	A	MASC	21	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0035M1_1.EDF	A0035M1_1.PDF	25	35
3	A	MASC	21	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0035V1_1.EDF	A0035V1_1.PDF	5	82
4	A	MASC	25	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0045B1_1.EDF	A0045B1_1.PDF	5	65
4	A	MASC	25	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0045B2_1.EDF	A0045B2_1.PDF	5	70
4	A	MASC	25	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 3	20	250	A0045B3_1.EDF	A0045B3_1.PDF	5	69
4	A	MASC	25	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0045M1_1.EDF	A0045M1_1.PDF	25	37
4	A	MASC	25	DIESTRO	SI	NO	NO	NO	NO	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0045V1_1.EDF	A0045V1_1.PDF	5	84
5	A	FEM	21	DIESTRO	SI	SI	NO	NO	SI	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0055M1_1.EDF	A0055M1_1.PDF	5	64
5	A	FEM	22	DIESTRO	SI	SI	NO	NO	SI	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0055M1_1.EDF	A0055M1_1.PDF	25	37
5	A	FEM	23	DIESTRO	SI	SI	NO	NO	SI	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0055V1_1.EDF	A0055V1_1.PDF	5	79
6	A	MASC	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0065B1_1.EDF	A0065B1_1.PDF	5	68
6	A	MASC	23	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0065B2_1.EDF	A0065B2_1.PDF	5	67
6	A	MASC	24	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 3	20	250	A0065B3_1.EDF	A0065B3_1.PDF	5	69
6	A	MASC	25	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0065M1_3.EDF	A0065M1_3.PDF	25	37
7	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0065V1_1.EDF	A0065V1_1.PDF	5	79
7	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0075B1_1.EDF	A0075B1_1.PDF	5	72
7	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0075B2_1.EDF	A0075B2_1.PDF	5	64
7	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 3	20	250	A0075B3_1.EDF	A0075B3_1.PDF	5	71
7	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0075M1_1.EDF	A0075M1_1.PDF	25	35
7	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0075V1_1.EDF	A0075V1_1.PDF	5	82
8	A	FEM	20	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0085B1_1.EDF	A0085B1_1.PDF	5	63
8	A	FEM	20	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0085B2_1.EDF	A0085B2_1.PDF	5	66
8	A	FEM	20	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 3	20	250	A0085B3_1.EDF	A0085B3_1.PDF	5	70
8	A	FEM	20	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0085M1_1.EDF	A0085M1_1.PDF	25	36
8	A	FEM	20	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0085V1_1.EDF	A0085V1_1.PDF	5	88
9	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0095B1_1.EDF	A0095B1_1.PDF	5	67
9	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0095B2_1.EDF	A0095B2_1.PDF	5	64
9	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	FIVE BOX 3	20	250	A0095B3_1.EDF	A0095B3_1.PDF	5	67
9	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	IMAGENES MOTORAS	HAND SHAKE	6	5000	A0095M1_1.EDF	A0095M1_1.PDF	25	36
9	A	FEM	22	DIESTRO	SI	SI	NO	NO	NO	NO	NO	128	VISUAL	IMAGE SEARCH	5	250	A0095V1_2.EDF	A0095V1_2.PDF	5	84
10	A	FEM	21	DIESTRO	SI	NO	SI	NO	NO	NO	NO	128	VISUAL	FIVE BOX 1	20	250	A0105B1_1.EDF	A0105B1_1.PDF	5	70
10	A	FEM	21	DIESTRO	SI	NO	SI	NO	NO	NO	NO	128	VISUAL	FIVE BOX 2	20	250	A0105B2_1.EDF	A0105B2_1.PDF	5	71
10	A	FEM	21	DIESTRO	SI	NO	SI	NO	NO	NO	NO	128	VISUAL	FIVE BOX 3	20	250	A0105B3_1.EDF	A0105B3_1.PDF	5	65

APÉNDICE C

PRODUCTIVIDAD ACADÉMICA

Producto	DESCRIPCIÓN
Artículo Indexado	S.M. Fernandez-Fraga, M. A. Aceves-Fernandez, J.C. Pedraza-Ortega, S. Tovar-Arriaga & J. M. Ramos Arreguin. (Mayo 2018). <i>Feature Extraction of EEG Signal upon BCI Systems Based on Steady-State Visual Evoked Potentials using the Ant Colony Optimization Algorithm</i> . Hindawi Publishing Corporation <i>Discrete Dynamics in Nature and Society</i>
Artículo Arbitrado	S. M. Fernandez-Fraga, M. A. Aceves-Fernandez, J.C. Pedraza-Ortega & J. M. Ramos-Arreguín. (Febrero 2018). <i>Screen Task Experiments for EEG Signals based on SSVEP Brain Computer Interface</i> . International Journal of Advanced Research. ISSN 2320-5407
Artículo Arbitrado	S. M. Fernandez-Fraga, M. A. Aceves-Fernandez, J. Rodríguez-Reséndiz, J. C. Pedraza-Ortega & J. M. Ramos-Arreguín. (Noviembre 2017) <i>Steady-State Visual Evoked Potential (SSEVP) from EEG Signal Modeling Based Upon Recurrence Plots</i> . Evolving Systems. ISSN 1868-6478
Artículo Arbitrado	S. M. Fernández Fraga, M. A. Aceves Fernandez, J. C. Pedraza Ortega, y S. Tovar Arriaga. (Enero - Abril 2017). <i>Topología de la Actividad Cerebral</i> . Komputer Sapiens. ISSN 2007-0691
Artículo Arbitrado	S. M. Fernández-Fraga, M. A. Aceves-Fernandez, J.C. Pedraza-Ortega y S. Tovar-Arriaga. (2016). <i>“EEG Signal Analysis Methods based on Steady State Visual Evoked Potential Stimuli for Development of Brain Computer Interface: A Review”</i> . American Journal of Computer Science and Engineering Survey. ISSN 2349-7238. AJCSES[4][1][2016] pp- 01-18
Memorias de Congresos Nacionales	S. M. Fernández-Fraga y J. Rangel Mondragon. (Mayo 2014). Estado del Arte de las Interfaces Cerebrales. VIII Congreso Internacional de Ingeniería Mecánica y Mecatrónica. Asociación Mexicana de Mecatrónica A.C. pp 22-33. ISBN: 978-607-95347-9-0

Research Article

Feature Extraction of EEG Signal upon BCI Systems Based on Steady-State Visual Evoked Potentials Using the Ant Colony Optimization Algorithm

S. M. Fernandez-Fraga,¹ M. A. Aceves-Fernandez,² J. C. Pedraza-Ortega,² and S. Tovar-Arriaga²

¹Department of Computer Systems Instituto Tecnológico de Querétaro, Av. Tecnológico s/n, Centro, CP 76000, Santiago de Querétaro, Mexico

²Department of Engineering, Universidad Autónoma de Querétaro, Cerro de las Campanas s/n, Centro Universitario, Las Campanas, CP 76010, Querétaro, Mexico

Correspondence should be addressed to M. A. Aceves-Fernandez; marco.aceves@gmail.com

Received 9 December 2017; Revised 16 April 2018; Accepted 5 May 2018

Academic Editor: Seenith Sivasundaram

Copyright © 2018 S. M. Fernandez-Fraga et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

This work presents the use of swarm intelligence algorithms as a reliable method for the optimization of electroencephalogram signals for the improvement of the performance of the brain interfaces based on stable states visual events. The preprocessing of brain signals for the extraction of characteristics and the detection of events is of paramount importance for the improvement of brain interfaces. The proposed ant colony optimization algorithm presents an improvement in obtaining the key features of the signals and the detection of events based on visual stimuli. As a reference model, we used the Independent Component Analysis method, which has been used in recent research for the removal of nonrelevant and detection of relevant data from the brain's electrical signals and also allows the collection of information in response to a stimulus and separates the signals that were generated independently in certain zones of the brain.

1. Introduction

A brain computer interface (BCI) enables direct communication between a brain and a computer translating brain activity into computer commands, thus providing no muscular interaction with the environment [1]. The development of brain computer interface (BCI) systems is mainly based on the information obtained by processing brain signals obtained by electroencephalogram (EEG). Further to obtaining signals, extraction and feature selection steps are vital for the development of applications; the BCI systems based on steady-state visual evoked potentials (SSVEP) have the advantage over other BCI systems because they have a better signal-to-noise ratio (SNR) and faster transfer rate information (ITR) [2]. Additionally it does not require intensive training and requires fewer EEG channels for application development and immunity from artifacts (flicker, movement joints, etc.)

[3, 4]. BCI-SSVEP systems are characterized by using stimuli at different frequencies sensitive to the dynamic processes of the occipital part of the cerebral cortex.

In recent years, algorithms based on swarm intelligence (SI) have recently emerged as a family-based wild populations of ant colony, bees, and swarm individuals algorithms which are capable of producing low give robust computational cost solutions to various complex and optimization problems [5, 6]. The ant colony optimization (ACO) algorithm proposed by Dorigo et al. (1996) is inspired by the foraging behavior of some species of ants. Ants lay pheromones on the ground in order to make a shorter path which eventually will be followed by other members of the colony which increases the probability of other ants following the same path resulting in an optimal way from the nest to the food source. Biologists have shown that many of the behaviors observed at the level

 ISSN NO. 2320-5407	Journal Homepage: - www.journalijar.com INTERNATIONAL JOURNAL OF ADVANCED RESEARCH (IJAR) Article DOI: 10.21474/IJAR01/6568 DOI URL: http://dx.doi.org/10.21474/IJAR01/6568	 INTERNATIONAL JOURNAL OF ADVANCED RESEARCH (IJAR)
---	---	---

RESEARCH ARTICLE

SCREEN TASK EXPERIMENTS FOR EEG SIGNALS BASED ON SSVEP BRAIN COMPUTER INTERFACE.

S. M. Fernandez-Fraga¹, M. A. Aceves-Fernandez², J. C. Pedraza-Ortega² and J. M. Ramos-Arreguín².

1. Instituto Tecnológico de Querétaro, Av. Tecnológico s/n esq. Mariano Escobedo, Centro, 76000 Santiago de Querétaro, México.
2. Universidad Autónoma de Querétaro, Cerro de las Campanas S/N, Querétaro, México.

Manuscript Info

Manuscript History

Received: 07 December 2017
 Final Accepted: 09 January 2018
 Published: February 2018

Key words:-

Steady State Visual Evoked Potential, SSVEP, Brain Computer Interface, BCI, EEG Signal Analysis.

Abstract

Development BCI system based steady state visual evoked potential (SSVEP), require establish the characteristics of the stimuli presented the user for optimal development of the extraction of signal characteristics; for it is necessary to determine the stimulation system and the evidence perform for detecting events. There are many types of stimulators that can be used to evoke the SSVEP: monitors include cathode ray tube (CRT) and liquid crystal display (LCD) or an array of light emitting diode (LED). This paper aims to show the different tests and methodologies that have been presented in different studies for generating visual stimuli in a short period of time.

Copy Right, IJAR, 2018.. All rights reserved.

Introduction:-

Brain Computer Interfaces (BCI) are computer systems that translate the electrophysiological brain activity signals that can be measurable by an electro / electronic device. BCI aim to provide a channel of non-muscle communication for sending commands to the outside world using the electrical activity of the brain. Brain interfaces monitor the brain activity of the user and translate this signals into commands without activating any muscle or peripheral nerve [16].

Brain states are the result of different patterns of neural interaction. These patterns result in waves, which are characterized by different amplitudes and frequencies. The human brain electrical activity present due to two causes. The first is internal, that is, due to inadvertent operation and control of respiration, digestion etc. and will of the individual, to move your body, speak or think, etc. The second cause of brain activity is the occurrence of external stimuli, through a bodily sense.

BCI systems can be classified according to their implementation:

- **Invasive systems:** Are implanted directly into the brain and its main application is in the area of prosthesis to restore limb movement.
- **Non-invasive systems:** The signal acquisition is performed using electrodes placed on the scalp surface (Figure 1) [3].

Corresponding Author:- M. A. Aceves-Fernandez.

Address:- Universidad Autónoma de Querétaro, Cerro de las Campanas S/N, Querétaro, México.

1716



Steady-state visual evoked potential (SSVEP) from EEG signal modeling based upon recurrence plots

S. M. Fernandez-Fraga¹ · M. A. Aceves-Fernandez² · J. Rodríguez-Resendiz² · J. C. Pedraza-Ortega² · J. M. Ramos-Arreguín²

Received: 28 August 2017 / Accepted: 21 November 2017
© Springer-Verlag GmbH Germany, part of Springer Nature 2017

Abstract

Dealing with electroencephalography (EEG) signals is often not simple. Steady-state visual evoked potentials (SSVEP) are signals even more difficult to determine or detect accurately. Given their non-stationary, lack of predictability, quality of recorded signal or a considerable amount of noise embedded in the signal to be many of the factors that make an analysis of SSVEP signals a hard and time-consuming task. Since EEG signals are non-stationary signals, using nonlinear features such as recurrence quantification analysis (RQA) may be more descriptive than other traditional methods for investigating these signals. The demonstrated ability of recurrence quantification analysis to detect very subtle patterns in time series and extract signals buried in large amounts of noise may be useful for this type of signal. The proposed technique, recurrence quantification analysis, demonstrates the ability to extract signals up to a very low signal-to-noise ratio and to allow an immediate appreciation of their degree of periodicity for SSVEP signals. In this contribution, many experiments on 30 subjects and three separate visual tests for each subject using a commercial apparatus have been performed. RQA was carried out for all valid tests, and patterns were found. Additional tests were carried out to detect false-positive trends, thus demonstrating that this technique is feasible to detect SSVEP events with moderate accuracy. Lastly, the results were compared with results from other methods, and the advantages of using RQA tools above other traditional methods were highlighted.

Keywords EEG · SSVEP · RQA · Recurrence plots · BCI

1 Introduction

Linear approaches of time series analysis are often not sufficient to analyze some type of data. In the last two decades, a great variety of non-linear techniques has been developed to analyze data of complex systems (Tanio et al. 2009).

One of the problems using other methods to detect the signal is that once it has been established that there is a good probability for the existence of a signal, there still remains the problem of locating the signal itself. This is particularly

important when the change of a signal exists but is embedded with other signals and background noise, which make it even more difficult detect such changes.

Overcoming the difficulties with non-stationary data series, the method of recurrence plots (RP) has been introduced (Marwan et al. 2013; Palmieri and Fiore 2009). An additional quantitative analysis of recurrence plots has been developed to detect transitions in complex systems (Marwan et al. 2006).

RPs are graphical representations of the amount of time at which two states of a system are close to each other, this is, they exist in the same phase space neighborhood. RPs have been vastly documented, gaining popularity over the past decade. With these graphical representations, the dynamics of a high-dimensional system may be studied.

One of the basic graphical tool of RPs is called recurrence quantification analysis or RQA. RQA provides a way to measure different statistical features found in the graphic visualization that may escape the observational representation that a naked eye may give a Recurrence Plot. For instance,

✉ M. A. Aceves-Fernandez
marco.aceves@gmail.com

S. M. Fernandez-Fraga
sfernandez@mail.itq.edu.mx

¹ Computer Department, Instituto Tecnológico de Querétaro, Av. Tecnológico s/n esq. Mariano Escobedo, Centro, 76000 Santiago de Querétaro, Mexico

² Faculty of Engineering, Universidad Autónoma de Querétaro, Cerro de las Campanas S/N, 76000 Querétaro, Mexico

ARTÍCULO ACEPTADO

Topología de la Actividad Cerebral

Santiago Miguel Fernández Fraga, Marco Antonio Aceves-Fernández, Jesús Carlos Pedraza Ortega y Saúl Tovar Arriaga

En los últimos años, en el campo de la inteligencia artificial, se han desarrollado tecnologías que permiten evitar los canales de comunicación convencionales (es decir, el habla y/o los movimientos de los músculos) entre el cerebro de un usuario y una computadora. Las Interfaces Computadora Cerebro monitorean la actividad cerebral del usuario y traducen sus intenciones en órdenes. El conocimiento del proceso eléctrico del cerebro, particularmente el cómo se obtienen, miden y cuantifican las señales cerebrales, es información necesaria para el desarrollo de las interfaces cerebrales.

El presente documento presentará la forma en que las señales cerebrales son representadas por medio de un electroencefalograma, cómo se pueden identificar dichas señales con referencia a su frecuencia y estado fisiológico del usuario, así como su ubicación en el espacio físico del cuero cabelludo en conjunto con la posición de los electrodos que permiten la obtención de las señales. Se obtuvo la topología de la actividad cerebral que nos permitirá relacionar las diferentes ondas cerebrales, el estado fisiológico y funcional del cerebro con la colocación espacial de los electrodos del Sistema Internacional 10-20, el cual es descrito posteriormente.

Introducción

En el área de la Inteligencia Artificial, se están desarrollando sistemas capaces de interpretar las señales

eléctricas del cerebro para traducirlas a comandos de computadora. Esta tecnología se conoce como Interfaz Computadora Cerebro (BCI, por sus siglas en inglés *Brain Computer Interface*), Interface Cerebro Máquina (BMI, por sus siglas en inglés *Brain Machine Interface*) o Interface Cerebro Computadora (ICC).

El BCI es un sistema que traduce la actividad electrofisiológica de un sistema nervioso orgánico en señales que pueden ser medibles por un dispositivo electromecánico. Este sistema tiene por objeto proporcionar un canal de comunicación no-muscular para el envío de comandos al mundo exterior utilizando la actividad eléctrica del cerebro, por lo cual permite la interacción entre el cerebro humano y una computadora.

Las tecnologías BCI implican el uso de dispositivos alámbricos y/o inalámbricos que detectan las ondas cerebrales tanto en el nivel consciente como en el inconsciente. En estos sistemas se requiere primeramente determinar los mecanismos neurológicos o procesos empleados por un usuario para generar señales de control, las cuales son generadas en diferentes ubicaciones del cerebro. La **Topología Cerebral** es una importante herramienta para ubicar las ondas cerebrales en las distintas regiones del cerebro. El mapeo del cerebro es capaz de capturar una ventana de la actividad cerebral, analizar los datos, y crear una representación visual para cada lóbulo del cerebro y cada onda específica del cerebro.

En el área de la Inteligencia Artificial, se están desarrollando sistemas capaces de interpretar las señales eléctricas del cerebro para traducirlas a comandos de computadora.

Señales Cerebrales de Electroencefalograma

Una señal de Electroencefalograma (EEG, por sus siglas en inglés *ElectroEncefaloGram*) se compone de una serie de potenciales eléctricos (μV) que fluctúan a través del tiempo en diferentes canales. Cada canal representa un electrodo colocado en el cuero cabelludo. Cada equipo EEG tiene una cierta velocidad de muestreo a cuantificar, la cual indica el número de cambios por segundo que una señal de salida puede tener (Figura 1).

Las neuronas se disparan periódicamente y, dependiendo del tipo de actividad, la periodicidad del disparo cambia. Cuando la región del cerebro está implicada en un cierto tipo de actividad, todas las neuronas en esa

región cambian con la misma periodicidad y esas fluctuaciones en conjunto se presentan en las señales EEG [1].

El criterio de normalidad es difícil de definir, debido a la variación entre individuos, al estado de alerta y a la edad, ya que estas variables fisiológicas, tienen una relación muy estrecha con las características del EEG. La amplitud de las señales, se encuentran en el rango de 0 a 300 mV con un ancho de banda de 0.5 a 100 Hz. La mayor parte del tiempo, son asíncronas y no tienen un patrón. La aparición de patrones, se asocia a la existencia de patologías cerebrales o a ciertas ondas de funcionamiento normal.

EEG Signal Analysis Methods Based on Steady State Visual Evoked Potential Stimuli for the Development of Brain Computer Interfaces: A Review

S. M. Fernandez-Fraga¹, M.A. Aceves-Fernandez*², J.C. Pedraza-Ortega² and S. Tovar-Arriaga²

¹Instituto Tecnológico de Querétaro, Av. Tecnológico s/n esq. Mariano Escobedo, Centro, 76000 Santiago de Querétaro, México

²Universidad Autónoma de Querétaro, Cerro de las Campanas S/N, Querétaro, México

Address for Correspondence

Universidad Autónoma de Querétaro, Cerro de las Campanas S/N, Querétaro, México

E-mail: marco.aceves@uaq.mx

ABSTRACT

Recently, brain computer interface (BCI) research has increased because of its application value in neural engineering and neuroscience, BCI Systems can provide online communication between a human or animal brain and external devices without depending on the normal output pathways of peripheral nerves and muscles. BCI applications include communication devices for disabled people, neuroprostheses and games. The most popular BCIs is based on steady state visual evoked potential (SSVEP) that can be recognized through detecting the dominant frequency components in the recorded electroencephalography (EEG) signals. BCI performance depends on correctly and fast decoding the user intentions and is critical to employ a reliable signal processing methods to detect and extract the components of de EEG signals recording. In this paper, mathematical tools used to design brain computer interface (BCI) systems based on electroencephalogram (EEG) signals obtain by visual stimulus are reviewed.

Keywords: Brain Computer Interface, BCI; Steady State Visual Evoked Potential, SSVEP; EEG Signal Analysis.

Estado del Arte de las Interfaces Cerebrales

Fernández Fraga Santiago Miguel, Rangel Mondragón Jaime
Facultad de Informática, Universidad Autónoma de Querétaro

Resumen

*En los últimos años se han desarrollado tecnologías en el campo de la inteligencia artificial que permitan pasar por alto los canales de comunicación convencionales entre el cerebro de un usuario y una computadora (como los músculos o el habla). Las **interfaz cerebro computadora** (Brain Computer Interface, BCI) monitorean la actividad cerebral del usuario y traducen sus intenciones en órdenes sin activar ningún músculo o nervio periférico [10]. Los sistemas BCI permiten controlar dispositivos electrónicos y/o mecánicos por medio de las ondas cerebrales. Los sistemas BCI han demostrado su aplicabilidad en varios contextos: la conducción de un robot o silla de ruedas, prótesis de funcionamiento, la selección de cartas de un teclado virtual, navegación en Internet o en realidades virtuales, el control de juegos de computadora, y algunos otros. Este tipo de sistemas es una forma natural para aumentar las capacidades humanas al proporcionar un nuevo enlace de interacción con el mundo exterior y es especialmente relevante como una ayuda para las personas con discapacidad. El presente artículo pretende mostrar una introducción a los sistemas BCI para describir de manera general las bases tecnológicas de su funcionamiento.*

Palabras claves: Interfaz Cerebro Computadora, Interfaz Cerebro Máquina, Sistemas BCI, BCI, BMI, ICC,

1. Introducción

1.1 Proceso Eléctrico de las Neuronas

El cerebro humano está formado por células especializadas llamadas neuronas. Las neuronas se componen de un cuerpo celular, un núcleo, las dendritas y un axón [4] (Figura 1).




Figura 1. Componentes de la neurona

Las neuronas son células eléctricamente excitables, procesan y transmiten información vía señales químicas y eléctricas. Las señales eléctricas se generan por cambios en la carga eléctrica de la membrana de la neurona que cubre a toda la célula. Las neuronas tienen un potencial eléctrico en reposo, el cual es la diferencia de potencial entre el interior de la célula y el espacio extracelular. El potencial en reposo fluctúa como resultado de los impulsos que llegan de otras neuronas a través de las sinapsis. La sinapsis es una unión funcional intercelular especializada entre neuronas, donde se lleva a cabo la transmisión del impulso nervioso, el cual se inicia con una descarga química que origina una corriente eléctrica en la membrana de la célula. La membrana de la célula contiene canales iónicos donde iones de sodio (Na^+), potasio (K^+), y cloruro (Cl^-) y Calcio (Ca^{2+}) se concentran durante los procesos químicos en la célula. La concentración de iones crea diferencias de potencial en la membrana. Los cambios en la tensión en la membrana generan potenciales post-sinápticos los cuales causan el flujo eléctrico a lo largo de la membrana y las dendritas.

Cuando la diferencia de potencial es sumada en la zona de activación del axón alcanza el rango de los -43 mV, se dispara el axón mediante la generación de un potencial de acción en los $+30$ mV que va a lo largo del axón para

APÉNDICE D
PROYECTO DE INVESTIGACIÓN



La Universidad Autónoma de Querétaro
y la Secretaría de la Rectoría

Otorgan el presente

RECONOCIMIENTO

A

**Santiago Miguel
Fernández Fraga**

Por su participación como
Responsable de Proyecto

FOPER 2015

"Fondo de Proyectos Especiales de Rectoría"

Santiago de Querétaro, Qro., noviembre de 2015


Dr. Gilberto Herrera Ruiz
RECTOR


Dra. Rocío Peniche Vera
TITULAR DE LA SECRETARÍA DE LA RECTORÍA



Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: ACEVES FERNANDEZ MARCO ANTONIO
FERNANDEZ FRAGA SANTIAGO
GARCIA GARCIA ROBERTO
MADERA MADERA MIGUEL ANGEL
PEDRAZA ORTEGA JESUS CARLOS
SEPULVEDA AVILA CARLOS NOE

TITULO: SISTEMAS DE PRUEBAS PARA ESTIMULOS NEURO MOTORES Y NEUROVISUALES V1

RAMA: PROGRAMAS DE COMPUTACION

TITULAR: UNIVERSIDAD AUTONOMA DE QUERETARO (CON FUNDAMENTO EN EL ARTICULO 103 PRIMER PARRAFO DE LA L.F.D.A.)

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en lo establecido por los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-010713204000-01

México D.F., a 15 de enero de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



INSTITUTO NACIONAL
DEL DERECHO DE AUTOR
REGISTRACIÓN DEL DERECHO DE AUTOR
100, PASEO DE LA REFORMA