



Diseño de un sistema de adquisición de señales encefalográficas a partir de AFE

**Winston Slam Anaya Torres
Andrés Felipe Serrano Cubides**

**Facultad de Ingeniería
Ingeniería Electrónica
Ibagué, 2019**





Diseño de un sistema de adquisición de señales encefalográficas a partir de AFE

Winston Slam Anaya Torres
Andrés Felipe Serrano Cubides

Trabajo de grado que se presenta como requisito parcial para optar al título de:
Ingeniero Electrónico

Directora:
M.Sc. Ing. Luisa Fernanda Gallo Sánchez
Profesora Universidad de Ibagué

Facultad de Ingeniería
Ingeniería Electrónica
Ibagué, 2019





Resumen

Nuestro cerebro produce impulsos eléctricos que viajan a través de las neuronas, estos impulsos son llamados ondas cerebrales, dependiendo del estado mental del sujeto en cuestión, estas ondas se dividen en 4 tipos: delta, theta, alfa y beta. Este proyecto busca determinar el nivel de concentración de las personas a partir de un Analog Front End (AFE). Para realizar este estudio, la recopilación de la base de datos de Electroencefalografía (EEG) se llevó a cabo por medio de la tarjeta de adquisición ADS1299EEG-FE de Texas Instruments con su software respectivo. Posteriormente en el software MATLAB se implementaron cuatro métodos de clasificación entre los que se encuentran el método 1, que usa un análisis de densidad espectral de potencia (PSD) y clasifica mediante una red neuronal y un umbral de relación entre potencias de bandas alfa y beta, el método 2, que realiza la transformada de Hilbert Huang (HHT) y clasifica mediante una red neuronal, el método 3, que hace la clasificación por medio de patrones comunes espaciales (CSP) y el método 4, que utiliza la Transformada Discreta de Wavelet (DWT), estos métodos permiten determinar el estado mental de los pacientes (concentrado o no concentrado), con precisión de acierto de: FFT 85%, HHT 74%, CSP 87%, DWT 70%, para base de datos adquirida con la AFE. Finalmente se selecciona el método que logró mejores resultados para la finalidad de proyecto.

Palabras clave: Electroencefalografía, ondas cerebrales, red neuronal, estado mental, procesamiento, concentración.

Abstract

Our brain produces electrical impulses that travel through neurons, these impulses are called brain waves, depending on the mental state of the subject in question, these waves are divided into 4 types: delta, theta, alpha and beta. This project seeks to determine the level of concentration of people from an Analog Front End (AFE). To carry out this study, the compilation of the Electroencephalography (EEG) database was carried out using the Texas Instruments ADS1299EEG-FE acquisition card with its respective software. Subsequently, four classification methods were implemented in the MATLAB software, four methods were implemented, including method 1, which uses Power Spectral Density Analysis (PSD) that classifies using a neural network and a relationship between powers of alpha and beta bands, method 2, Hilbert Huang's Method (HHT) that classifies with a neural network, method 3, Common Spatial Pattern Classification (CSP), and method 4, Discrete Wavelet Transformed (DWT). These methods allow the mental state of patients to be determined (concentrated or not concentrated) with accuracy of success: FFT 85%, HHT 74%, CSP 87%, DWT 70%, for database acquired with AFE. Finally, the method that gave the best results is selected for the purpose of the project.

Keywords: Electroencephalography, brain waves, neural network, mental state, processing, concentration.





Contenido

Resumen	V
Lista de ilustraciones.....	VIII
Lista de Tablas.....	IX
Lista de Anexos	IX
Lista de Abreviaturas.....	X
Introducción	1
Planteamiento y justificación del problema	3
Objetivos.....	4
Metodología	5
1. Estado del arte	7
2. Marco teórico	11
2.1. Técnicas de Procesamiento Digital de Señales, empleadas en la señal EEG	12
2.2. Dispositivos Analog Front End (AFE).....	14
3. Implementación.....	15
3.1. Adquisición.....	15
3.2. Pre procesamiento.....	17
3.3. Procesamiento.....	18
3.3.1. Método 1.....	19
3.3.2. Método 2.....	21
3.3.3. Método 3.....	23
3.3.4. Método 4.....	25
4. Resultados	27
4.1. Validación.....	27
4.2. Pruebas finales.....	29
5. Conclusiones y recomendaciones.....	31
5.1. Conclusiones	31
5.2. Recomendaciones	32
Referencias.....	33
Anexos.....	36



Lista de ilustraciones

Ilustración 2.1. "Sistema 10/20 EEG"	11
Ilustración 3.2. "Configuración física de la AFE y posición de los electrodos"	16
<i>Ilustración 3.3. "Artefacto de la AFE".....</i>	<i>16</i>
Ilustración 3.4. "Señales antes y después del filtrado".	18
Ilustración 3.5. "Diagrama de bloques Método de clasificación por densidad espectral de potencia".....	19
Ilustración 3.6."FFT de la señal de entrada y DSP de la FFT obtenida".	20
Ilustración 3.7. "Red neuronal Elman backproagation".....	20
Ilustración 3.8. "Diagrama método de Hilbert Huang".....	21
Ilustración 3.9. "Transformada Hilbert Huang".....	22
Ilustración 3.10. "Red neuronal Feed-forward backpropagation".....	22
Ilustración 3.11. "Diagrama método 3".	23
Ilustración 3.12. "Clases Entrenamiento antes y después de Filtrado Espacial". Fuente: MATLAB, de los autores.	24
Ilustración 3.13. "Diagrama método 4".	25
Ilustración 3.14. "Espectros de frecuencia de las Wavelets".	26
Ilustración 4.15. "Densidad Espectral de Potencia con datos de PowerLab".....	29
Ilustración 4.16. "Densidad espectral de potencia con datos de PhysioNet".....	30



Lista de Tablas

Tabla 4.1. "Comparación de métodos de procesamiento".	28
---	----

Lista de Anexos

Anexo A. Tabla de diferentes métodos usados para detectar nivel de concentración.	36
Anexo B. Estado de concentración para 4 pacientes con cada método evaluando las actividades propuestas.	37
Anexo C. Manual básico para instalación y uso de ADS1299EEGFE-PDK	57
Anexo D. Códigos de MATLAB utilizados en los métodos para determinar estado de concentración.	58
Anexo E. Tabla resultados de clasificación de estado de concentración con cada algoritmo para base de datos obtenida con AFE.	67
Anexo F. Tabla resultados de validación con base de datos de PhysioNet y base de datos de Powerlab.	71



Lista de Abreviaturas

Abreviatura	Término
AD	Convertor análogo digital
AFE	Analog Front End
BCI	Brain Computer Interfaz- Interfaz cerebro computadora
CI	Circuitos integrados
CSP	Common Spatial Pattern – Patrón Espacial Común
DWT	Transformada Discreta de Wavelet
EEG	Electroencefalograma
EMD	Descomposición de modo empírico
FFT	Fast Fourier Transform – Transformada rápida de Fourier
FN	Falsos negativos
FNIRS	Espectroscopia de infrarrojo cercano funcional
FP	Falsos Positivos
HHT	Transformada de Hilbert Huang
Hz	Hertz
IMF	Funciones de modo intrínseco
IRMf	Resonancia Magnética funcional
PET	Tomografía por emisión de positrones
PSD	Densidad espectral de potencia
QEEG	Quantitative EEG- Electroencefalograma cuantitativo
REM	Movimientos oculares rápidos
SVM	Support Vector Machine – Máquina de vectores de soporte
TDAH	Trastorno de Déficit de Atención e Hiperactividad
VN	Verdaderos positivos
VP	Verdaderos Negativos



Introducción

Después de que Hans Berger en 1929 desarrollara el dispositivo que ahora se conoce como electroencefalograma (EEG) [1], que tiene la capacidad de registrar potenciales eléctricos generados por la actividad cerebral, ha existido un gran interés en el desarrollo de métodos de comunicación entre cerebro y computadora, basados en la actividad neuronal generada por el cerebro, dando con ello lugar al nacimiento de lo que hoy se conoce como interfaces cerebro - máquina o “Brain-Computer Interface” (BCI) cuya meta principal es proporcionar al usuario canales de comunicación de la actividad cerebral sin la interferencia de los nervios periféricos y músculos, con la finalidad de interpretar las emociones, sensaciones y deseos del usuario, lo cual tiene innumerables aplicaciones, entre las que se encuentran las dirigidas a personas con incapacidades motrices, las que a partir de la señal capturada pretenden conocer la intención del sujeto y las que sirven como entrenamiento para controlar las señales cerebrales (Neurofeedback).

La interfaz cerebro - máquina es una tecnología que facilita la comunicación entre el cerebro y los dispositivos externos [2]. Un sistema BCI se basa en el reconocimiento en tiempo real de diferentes estados mentales de la actividad cerebral, lee diferentes señales cerebrales producidas en las diferentes regiones del cerebro humano y traduce estas señales en acciones y comandos para diversas aplicaciones. El primer paso de un modelo BCI general es la adquisición de señales por medio de un electroencefalógrafo en donde las señales se recolectan desde el cerebro en forma de ondas analógicas, y luego, por medio del computador, se convierten en valores numéricos digitales.

El EEG refleja la actividad eléctrica que se produce en el cerebro como resultado del procesamiento neuronal y del flujo de señales a través de las células nerviosas, las fibras nerviosas y las sinapsis. Se sabe que la respuesta EEG del cerebro varía con diferentes tipos de cambios en los estados mentales, como las diferentes etapas del sueño y la vigilia, los diferentes estados emocionales, el rendimiento cognitivo como el razonamiento y la toma de decisiones. etc. El EEG tiene la ventaja sobre otras herramientas de imágenes cerebrales funcionales, como la tomografía por emisión de positrones¹ (PET), la resonancia magnética funcional (IRMf), la espectroscopia de infrarrojo cercano funcional² (fNIRS) en que esta no es invasiva, pues la señal EEG se

¹ Un positrón es una partícula de tipo elemental cuya carga eléctrica resulta igual a la que posee el electrón, aunque positiva. Por esta característica, se dice que el positrón es la antipartícula de esta partícula subatómica [39].

² La fNIR mide los cambios del nivel de oxígeno en el córtex pre-frontal de los sujetos humanos.



captura por medio de electrodos o canales que se encuentran en diferentes lugares en el cuero cabelludo del usuario [3] y tiene una resolución temporal muy superior, aunque dependiendo de la aplicación y tipo de procesamiento de la señal a obtenerse, esta puede ser de tipo invasivo, en el cual es necesaria la utilización de electrodos profundos y electrodos subdurales, que se colocan de forma intracraneal en el individuo [4]. Por lo tanto, el alcance de las señales de EEG como un marcador psicofísico para monitorear estados mentales estresantes ha ido ganando importancia especialmente en el dominio de la BCI y la evaluación en línea de la carga de trabajo, la fatiga y el estrés mental.

Este proyecto, en su primera fase hace parte de un Macro proyecto, liderado desde la Facultad de Ingeniería de la Universidad de Ibagué, que pretende desarrollar juegos basados en la tecnología para optimizar el proceso de aprendizaje en niños y así mejorar su rendimiento académico; este mismo proyecto en su segunda fase desarrollará en los capítulos siguientes un Neurofeedback para medir los niveles de concentración a partir del EEG obtenidos.

El objetivo de esta asistencia de investigación es explorar y comparar el rendimiento de varios algoritmos de clasificación de estados de concentración. Para la selección de métodos se efectuó una revisión del estado del arte sobre las distintas formas de procesamiento de señal EEG (Anexo A), se realizó una base de datos con 30 personas, de cada una de ellas se escogieron 4 archivos de datos, donde se efectuaron diferentes tareas de concentración y no concentración (relajación, ojos cerrados, lectura, desarrollo de operaciones matemáticas).

La adquisición de estos datos se realizó con la tarjeta AFE ADS1299EEGFE-PDK de Texas Instruments. Los AFE, son circuitos integrados (CI's) de última generación que tienen incorporados amplificadores, filtros conversores AD de última gama y bloques funcionales típicos de los equipos para adquirir biopotenciales, y se han convertido en una alternativa atractiva debido a su alta integración, bajo consumo, fiabilidad, bloques adicionales y su bajo costo, y son empleados para el desarrollo de equipos donde se precisa alguna de estas características [5]. Para esta investigación se utilizó un solo canal de adquisición con dos electrodos en las posiciones FP1 y A2 del sistema 10-20 (ver Capítulo 3.1 selección de un solo electrodo). El pre-procesamiento de la señal se realizó con el software MATLAB. Se aplicaron 4 métodos de detección de concentración los cuales son: análisis de densidad espectral de potencia (PSD), Transformada de Hilbert Huang (HHT), Common Spatial Pattern (CSP) y Transformada discreta de

El sistema fNIR ofrece a los investigadores una monitorización en tiempo real de la oxigenación de los tejidos en el cerebro mientras el sujeto ejecuta una tarea o recibe un estímulo [40].



Wavelet (DWT) con clasificador de Support Vector Machine (SVM). Finalmente se muestran los resultados obtenidos, la elección del mejor algoritmo y la validación con una base de datos de PhysioNet, y con el PowerLab.

Planteamiento y justificación del problema

En general las señales biomédicas son muy difíciles de adquirir. Cada vez que se pretende realizar una aplicación con señales biomédicas, es necesario desarrollar todo el sistema de adquisición, y las interferencias siempre son un problema. Dentro de las bioseñales, la señal electroencefalográfica (EEG), es una de las más complicadas de adquirir eficientemente, debido a que presenta muy bajo nivel de señal y al ruido presente generado por las múltiples fuentes de interferencia electromagnética presentes. Emplear dispositivos electrónicos convencionales en esta tarea, hace que las dificultades aumenten debido a las numerosas conexiones que hay que realizar, debido a que se requieren varios canales de adquisición. Es por esto, que utilizar dispositivos que mejoren estas condiciones se hace imperioso y los AFE (Analog front end), desarrollados hace pocos años por diferentes casas fabricantes de Circuitos Integrados son ideales para mejorar estas condiciones.

En Colombia, está incipiente el diseño de equipos electromédicos, y en particular de equipos para adquisición de señales electroencefalográficas en los que además, se involucren dispositivos de última tecnología como los AFE y tengan adicionalmente bajo costo y menor consumo de potencia. La ventaja de incluir dispositivos AFE en los productos finales, radica en la fiabilidad que se consigue debido a que internamente se encuentran integrados amplificadores y filtros programables, convertidores análogo-digital muy eficientes y múltiples canales, además de bloques adicionales de gran utilidad en bioseñales como son el circuito de detección de desconexión de derivación entre otros, lo que permite realizar un procesamiento en menor tiempo, con menor consumo de potencia y la posibilidad de ser incluidos en sistemas embebidos para aplicaciones finales, lo que abre otro campo de futura experimentación para nuestro grupo de investigación, en el diseño de equipos médicos portátiles a partir de dispositivos SoC (System on chip) y DSPs (Digital Signal Processor) y en la utilización de estos integrados en el desarrollo de aplicaciones para dispositivos móviles.

Pero no solo en la adquisición de la señal se presentan problemas; para detectar niveles de concentración a partir de esta, se requiere una buena selección de características que permitan la discriminación de las señales, lo cual se dificulta al ser una señal de baja amplitud y con muchas similitudes en diferentes estados de la persona (Dormido,



despierto, pensando, etc.). Los métodos de detección de concentración pueden usarse en diversas aplicaciones, como en el diagnóstico de afecciones neurocognitivas, por ejemplo, el déficit de atención o el trastorno de hiperactividad (TDAH). Además, se pueden usar para monitorear el rendimiento de los niños al momento de estudiar.

El Equipo de EEG pretende desarrollar herramientas didácticas basadas en tecnología, para mejorar el aprendizaje en niños de los municipios del Tolima; y donde a partir de este equipo, se realizará (en los capítulos siguientes) un Neurofeedback, que permitirá monitorear el nivel de concentración que ha alcanzado el niño, todo esto para que en aplicaciones futuras, se pueda aumentar mediante esta terapia su nivel de concentración y por ende, se mejorará su desempeño escolar.

Por lo tanto, la pregunta para este proyecto que se presenta, se centra en: ¿es posible a partir de algoritmos matemáticos determinar el nivel de concentración a partir de señales EEG obtenidas a partir de un dispositivo AFE?

Objetivos

- Analizar y procesar los datos obtenidos mediante la adquisición de señales encefalográficas a partir de un AFE.
- Realizar una exploración de los métodos matemáticos empleados en la actualidad para el procesamiento de señales EEG y determinar 4 de los algoritmos de mejor desempeño en cuanto a complejidad y tiempo computacional, para medir el nivel de concentración en un individuo.
- Implementar los algoritmos seleccionados para determinar el nivel de concentración y comparar los resultados para seleccionar el mejor.
- Desarrollar un procedimiento para generar una base de datos con mínimo 20 individuos a los que se les determine el nivel de concentración.
- Validar el algoritmo escogido a partir de la comparación con el polígrafo Powerlab de ADInstruments.



Metodología

Primero que todo, se realizó una exhaustiva búsqueda sobre los métodos de análisis y clasificación de señales encefalográficas para determinar el estado de concentración y la mejor forma de adquirir señales de este tipo, tras esto, se seleccionaron los mejores 4 métodos teniendo en cuenta su precisión y complejidad (Anexo A). Posteriormente, se creó una base de datos de señales EEG de 30 sujetos ejecutando actividades que requieren y que no requieren concentración, dichas señales fueron adquiridas con la tarjeta ADS1299EEGFE-PDK de Texas Instruments, para lo cual fue necesario una profunda investigación sobre el funcionamiento de la tarjeta. Los 4 métodos fueron implementados en MATLAB versión R2019A para posteriormente ser validados y comparados entre ellos para seleccionar el método más eficaz para el objetivo principal de este proyecto, adicionalmente, al método seleccionado se le realizaron pruebas con bases de datos externas, una con señales adquiridas con el PowerLab DAQ modelo 26T de ADInstruments con el software libre (stand- alone) Scope For Windows y otra con una base de datos de PhysioNet.





1. Estado del arte

En 1870, Fritsch y Hitzig, médicos militares del ejército prusiano, observaron que, al estimular mediante corriente galvánica determinadas áreas laterales de los cerebros, descubiertos de algunas de las bajas de la batalla de Sedán, se producían movimientos en el lado opuesto del cuerpo [6].

En 1928 Hans Berger ideó un método que prometía una investigación de la actividad eléctrica cerebral, descubriendo lo que se conoció como “ritmo de Berger”. Sin embargo, debido a su falta de conocimientos técnicos, no fue hasta algunos años después que se reconoció su importancia.

Fue en 1934 cuando a raíz de una demostración pública ante un auditorio británico en una reunión de la Sociedad de Fisiología, en Cambridge, Adrián y Matthew verificaron por primera vez el ritmo de Berger. Berger, utilizando las mejoras introducidas por Adrián, siguió avanzando hasta donde le permitía su técnica, observando por ejemplo que cuando el sujeto abría los ojos o resolvía algún problema mentalmente se alteraba el ritmo regular [1] .

Los métodos de detección de concentración pueden usarse en diversas aplicaciones, como en el diagnóstico de afecciones neurocognitivas tales como el déficit de atención o el trastorno de hiperactividad (TDAH). Además, se pueden usar para monitorear y mejorar el rendimiento en los deportes, los juegos, la conducción, etc. o para evaluar el estrés relacionado con el trabajo. Los métodos de detección de concentración también se pueden usar para monitorear la efectividad de la medicación, como en los ensayos clínicos de medicamentos o la efectividad de la terapia y la rehabilitación como el Biofeedback [7] .

Cowan y Prell [8] propusieron utilizar los EEG recolectados desde el lóbulo frontal del cerebro del sujeto y definieron un indicador de atención que es inversamente proporcional a una transformación matemática de una medida de amplitud del lóbulo frontal del EEG, este está dentro de la banda de frecuencia de 0-11 Hz. Sin embargo, dado que la amplitud del EEG cambia con el tiempo y varía significativamente en diferentes sujetos, el método en Cowan y Prell no puede proporcionar un nivel cuantificable de atención.

Monastra y Lubar [9] describieron un método para calcular un índice de atención para la detección de la concentración. Este índice de atención se calcula como el promedio de la relación de potencia theta sobre beta para cada una de las siguientes tareas que



realizará el sujeto. En estas tareas, el sujeto debe mantener los ojos abiertos con una mirada fija (utilizada como referencia), leer, escuchar o dibujar. El cálculo del índice de atención se muestra en la ecuación (1.1) donde $EEGpower_{theta}^{Task}$ es la potencia theta, $EEGpower_{beta}^{Task}$ es la potencia beta y N es el número total de tareas realizadas. La banda theta se define entre 4 y 8 Hz, mientras que la banda beta se define entre 13 y 21 Hz.

$$Attention\ Index = \frac{1}{N} \sum_{Task=1}^N \frac{EEGpower_{theta}^{Task}}{EEGpower_{beta}^{Task}}$$

Ecuación 1.1. Índice de atención

Aunque el índice de atención propuesto por Monastra y Lubar mejora el cálculo del índice de atención de Cowan and Prell, sigue aun sin proporcionar una cuantificación adecuada de estado de concentración de una persona.

Varios investigadores se han centrado en el reconocimiento de los estados cerebrales de concentración y relajación en los últimos años. Xueni Li y Yufeng [10] estudiaron Biofeedbacks de EEG en el tratamiento del trastorno por déficit de atención con hiperactividad. Entrenaron a los sujetos a concentrarse con la ayuda de la retroalimentación de varios oscilogramas de EEG en tiempo real.

Yanbing Zhang [11] investigó la característica del EEG, la mioelectricidad y el estado de ánimo cuando los sujetos se relajaban y obtuvieron el índice sintético del estado del cerebro después de varios minutos de recopilación de datos. Aunque este índice no era un determinante de peso para el estado de relajación, su análisis permitió definir pautas para una mejor selección de las características de este estado.

Huiche Science Company inventó el mini coche de control mental [12] en 2014, cuyo objetivo era ayudar a las personas a concentrarse mejor. A pesar de su contribución, sus métodos tuvieron algunas limitaciones: En primer lugar, los EEGs que utilizaban siempre tenían muchas derivaciones, lo que lo hace complejo para que los usuarios los usaran, además de esto, la otra limitación fue la respuesta que tenía el coche era lenta, ya que se procesaban muchas matrices de datos debido a la cantidad de electrodos, haciendo que el experimento no diera los mejores resultados, puede notarse en este caso la importancia de la simplicidad y velocidad del procesamiento.



Los avances tecnológicos recientes han aumentado el alcance de las capacidades de grabación de EEG mediante el uso de densos grupos de electrodos, incluidos conjuntos de 128, 256 y 512 electrodos conectados al cráneo. La inspección visual de estos conjuntos de datos masivos es complicada para las técnicas de análisis existentes basadas en EEG. Por lo tanto, la extracción optimizada de características de los datos de EEG relevantes es esencial para mejorar la calidad de las evaluaciones de rendimiento cognitivo, especialmente porque afecta directamente el rendimiento de un clasificador. Además, las características más expresivas mejoran el rendimiento de clasificación; por lo tanto, la extracción de características se ha convertido en el paso más importante en la clasificación de datos EEG.

Varios investigadores como Doppelmayr y Zarjam [13] ahondaron en la búsqueda de “Quantitative-EEG” (QEEG) para evaluar la actividad neuronal durante las tareas cognitivas. Utilizaron características de dominio de tiempo y frecuencia, como entropía, espectro de potencia, coeficientes autorregresivos y bandas de frecuencia individuales, etc. Las características de frecuencia dependen de la actividad neuronal y se agrupan en varias bandas; delta, theta, alfa, beta y gamma; que se han vinculado a procesos cognitivos [14].

Con el desarrollo de nuevas tecnologías y la mejora de sistemas de EEG se buscaba lograr una interpretación de las ondas cerebrales que a simple vista podrían parecer totalmente aleatorias, para ello se buscó tratar las señales crudas del EEG y aplicar distintos métodos matemáticos con un procesamiento basado en métodos estadísticos que permiten obtener información que haga posible entender que suceden a estas ondas ante distintas situaciones como estímulos externos, concentración, accionamientos cognitivos, influencia de sustancias, enfermedades neurológicas, etc. ,con el objetivo de lograr una comprensión más detallada de la actividad cerebral.

Actualmente la mayoría de los proyectos de investigación sobre BCI, dependen directamente de clasificadores basados en distintas técnicas de aprendizaje automático. Sin embargo, el problema principal radica en la elección de cómo se extraerán las características de estas señales de control. Otro método un poco más complejo de desarrollar matemáticamente hablando es el uso de Wavelets [15], estos son representaciones integrables reales o complejas de funciones por series ortogonales, siendo una de las transformaciones tiempo-frecuencia más usadas hoy en día. Dichas transformaciones permiten extraer características que pasando por un procedimiento de pre procesamiento pueden separarse señales generadas tanto cognitivamente como por estímulos externos. Una de los métodos más recientes y con mejores resultados, radica



en el uso de la transformada de Hilbert-Huang [16] , lo que permite obtener información de fase y frecuencias instantáneas.

Las asistencias de investigación que dan lugar a este documento, tienen por objetivo evaluar algunos métodos que permitan determinar el estado de concentración a partir de una buena selección de características; con la información anteriormente expuesta y luego de realizar una rigurosa clasificación de los métodos reportados en la literatura se resumen en el Anexo A, donde se incluye una tabla con la síntesis de métodos usados en otras investigaciones, con un breve resumen de cada uno, la complejidad con la que se desarrolla, algunos datos determinantes como precisión y sensibilidad, además de la forma en que se validó cada método.



- Ondas Theta: Tienen frecuencias entre 4 Hz y 8 Hz, están presentes en el sueño REM (Movimientos Oculares Rápidos) y en estados de meditación profunda.
- Ondas Alfa: Con frecuencias entre 8 Hz y 14 Hz se encuentran en estados de relajación, pensamientos tranquilos, momentos previos al sueño y ojos cerrados.
- Ondas Beta: Tienen frecuencias entre 14 Hz y 30 Hz se registran cuando se está despierto y en plena actividad mental (concentración, preocupación, estados de alerta), la ausencia de estas ondas puede significar déficit de atención, sobre todo en niños, mientras que un exceso de estas, puede involucrar ansiedad o trastornos obsesivos-compulsivos.

Estos dos últimos tipos de onda serán los explorados a lo largo de este estudio, clasificando el estado mental de los sujetos de prueba en Concentración o No concentración, que corresponden a las ondas beta y alfa respectivamente.

Aunque inicialmente un EEG se ha diseñado para poder registrar la actividad cerebral que emite un individuo, estos sensores serán capaces de registrar las actividades eléctricas que surjan de sitios distintos al cerebro. Toda esta actividad que es percibida por los sensores y que no viene del cerebro (ruido) se denomina artefactos. En función del origen, se pueden dividir en artefactos fisiológicos y extra-fisiológicos. Los primeros son generados por el paciente, pero por fuentes diferentes a la de estudio, por ejemplo, de sus respiraciones. Por otro lado, los artefactos extra-fisiológicos, surgen externamente del individuo (entorno) [20].

Los métodos de procesamiento que se utilizaron en esta investigación fueron escogidos tras una búsqueda de los métodos más usados (Anexo A), se seleccionaron teniendo en cuenta su eficiencia y complejidad. Algunos conceptos serán esclarecidos a continuación para el desarrollo de estos métodos.

2.1. Técnicas de Procesamiento Digital de Señales, empleadas en la señal EEG

La transformada rápida de Fourier (FFT) es un algoritmo que permite a partir de una señal en el dominio del tiempo, obtener su equivalente en el dominio de la frecuencia; el rango de frecuencias que cubre este análisis depende de la frecuencia de muestreo utilizada para adquirir la señal de entrada, siendo la frecuencia máxima a la salida de la FFT igual a la mitad de la de muestreo [21]. Esta transformada permite observar el espectro de frecuencias de la señal de origen de una manera fácilmente descifrable, pudiendo identificar en algunas ocasiones en que banda de frecuencia se encuentra el



sujeto con tan solo ver la FFT graficada, tiene como desventaja que los artefactos presentes en el momento de la toma de datos afectan el resultado de la transformada en gran medida, aunque estos hayan durado poco tiempo.

Tal como lo realiza la transformada de Fourier, es muy común en el análisis digital de señales ver estas en el dominio de la frecuencia, pero en ocasiones es necesario ir más allá. La transformada de Hilbert Huang permite obtener una relación con la mitad de información en el dominio del tiempo y la otra mitad en el dominio de la frecuencia [22]. Este método funciona mediante la descomposición de modo empírico (EMD) que descompone señales reales en secuencias de funciones oscilatorias moduladas en amplitud y frecuencia, estas secuencias son llamadas funciones de modo intrínseco (IMF) [23]. De manera similar a la FFT, esta transformada permite ver de forma gráfica la banda de frecuencia en la que se encuentra el sujeto, pero en este caso, los artefactos no afectan tanto la señal, en la salida puede observarse la frecuencia a la que se encontraba el sujeto a lo largo de la toma de datos y no de forma general, como desventaja debe destacarse que de acuerdo al número de IMF's usados, la señal puede simplificarse demasiado, haciendo que se pierda mucha información durante el proceso.

Entre los métodos de clasificación más utilizados en este tipo de aplicaciones, se encuentran las redes neuronales, estas son unidades de procesamiento que tienen la cualidad de adaptarse y aprender según un entrenamiento previo [24] y están conformadas por neuronas conectadas entre sí por medio de capas. Las neuronas realizan determinadas operaciones a una señal de entrada para producir unos valores en la salida dependiendo del entrenamiento que se les haya aplicado.

Common Spatial Pattern o Patrón Espacial Común (CSP) es una técnica matemática usada en el procesado de señales para separar señales multivariantes en subcomponentes con distintas varianzas. Un filtro CSP maximiza la varianza de las señales filtradas de EEG de una clase de movimientos mientras que la minimiza para las señales de la otra clase. El desarrollo de esta técnica surge de manera natural cuando se intenta maximizar la diferencia de varianzas entre las dos señales filtrándolas espacialmente [25]. El algoritmo CSP calcula los filtros espaciales que maximizan la proporción de varianza de los datos derivados de las dos clases. En consecuencia, las señales extraídas discriminan de manera óptima dos clases diferentes de EEG mientras que revelan patrones espaciales de diferentes clases [26]. Este método tiene como ventaja que permite buena discriminación de las características de dos clases con el uso de los filtros espaciales, y, como desventaja, que tiene un rendimiento limitado cuando dispone de una pequeña cantidad de datos de entrenamiento.



La Transformada Wavelet es una herramienta matemática desarrollada a mediados de los años 80. El aspecto temporal de las señales es preservado. La Transformada Wavelet provee análisis multiresolución con ventanas dilatadas. El análisis de las frecuencias de mayor rango se realiza usando ventanas angostas y el análisis de las frecuencias de menor rango se hace utilizando ventanas anchas [8]. Las Wavelets, funciones bases de la Transformada Wavelet, son generadas a partir de una función Wavelet básica, mediante traslaciones y dilataciones. Estas funciones permiten reconstruir la señal original a través de la Transformada Wavelet inversa. La Transformada Wavelet no es solamente local en tiempo, sino también en frecuencia [27]. Esta Transformada tiene como ventaja que es eficiente para el análisis local de señales no estacionarias y de rápida transitoriedad y mapea la señal en una representación de tiempo-escala. Como desventaja tiene que el tiempo de computo es mayor ya que realiza un análisis de acuerdo a cada nivel de descomposición que se le realizó a la señal.

Una Máquina de vectores de soporte (SVM) es un clasificador discriminativo definido formalmente por un hiperplano separador. En otras palabras, dados los datos de entrenamiento etiquetados (aprendizaje supervisado), el algoritmo genera un hiperplano óptimo que categoriza nuevos ejemplos. En dos espacios dimensionales, este hiperplano es una línea que divide un plano en dos partes, donde en cada clase hay uno de los lados [28].

2.2. Dispositivos Analog Front End (AFE).

Los AFEs son una nueva generación de circuitos integrados que poseen múltiples dispositivos: amplificadores operacionales, filtros y otros circuitos de acondicionamiento de señal programados internamente, todos dentro de un mismo chip, para obtener el mejor rendimiento al entregar una señal con bajo ruido, y de rango dinámico. Las ventajas de estos dispositivos en EEG es que permiten realizar la adquisición más portable, con señales de bajo ruido, con uso de múltiples canales y alta fiabilidad. Como ejemplo de estos dispositivos se encuentra el ADS1299 de Texas Instruments.

El dispositivo ADS1299EEG-FE es un conversor analógico digital delta-sigma ($\Delta\Sigma$) de ocho canales de bajo ruido de 24 bits de muestreo simultáneo (ADCs) con un amplificador de ganancia programable (PGA) incorporado, referencia interna y un oscilador integrado. El ADS1299 incorpora todas las características comúnmente requeridas para aplicaciones de electroencefalograma extracraneal (EEG) y electrocardiografía (ECG). Con sus altos niveles de integración y un rendimiento excepcional, este dispositivo permite la creación de sistemas de instrumentación médica escalables a un tamaño, potencia y costo general significativamente reducidos [29].



3. Implementación

3.1. Adquisición

La tarjeta ADS1299EEGFE-PDK de Texas Instruments especializada en la adquisición de los datos EEG, permite una recopilación de señales biopotenciales, usa hasta ocho canales de grabación síncrona de bajo ruido que pueden recopilar múltiples señales simultáneamente; un convertidor analógico digital de alta resolución de 24 bits (ADC), una relación de rechazo en modo común de -110 dB y un ruido interno muy bajo, lo que garantiza la precisión de la detección de biopotenciales; un amplificador de ganancia programable ajustable de 1–24 veces (PGA); una frecuencia de muestreo de un solo canal programable hasta 16 kHz que garantiza que el ancho de banda de las señales sea suficiente; y un circuito integrado de pierna derecha accionada que reduce aún más la interferencia ambiental. [5]. El registro de los datos fue realizado empleando la derivación monopolar FP1-A2 del sistema 10-20 como entrada positiva y referencia respectivamente (ver Ilustración 3.2), esta configuración fue seleccionada, debido a que es la empleada en estudios similares a este, reportados en la literatura, como los realizados por: Edla y Mangalorekar [2], Aziz y Shapiai [16], Subasi [30], Verma y Duhan [31], ya que en esta zona es donde se ubican las ondas alfa y beta, además de que el uso de un solo electrodo simplifica en gran medida el procesamiento y reduce el tiempo computacional necesario para este. La configuración física de la tarjeta y de software utilizada corresponde a lo indicado en el manual del AFE [32] para la adquisición de señales monopolares.

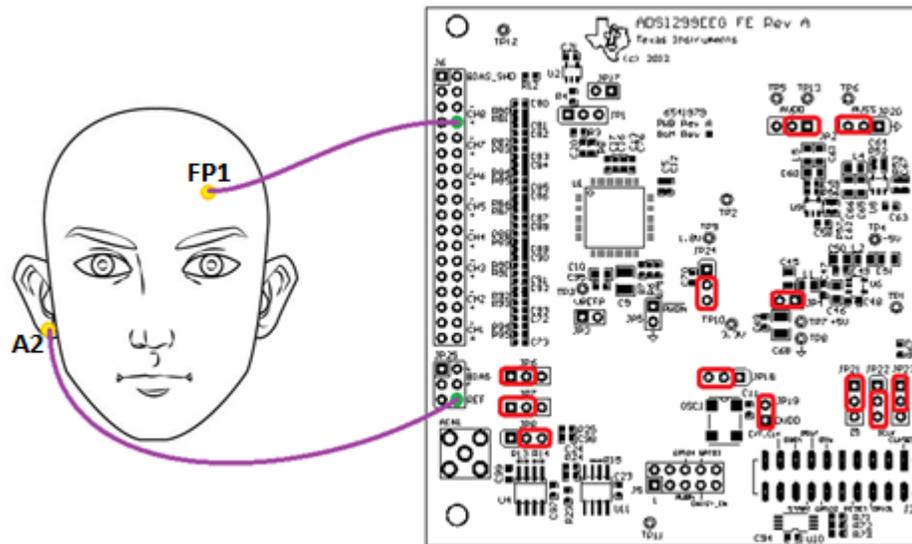


Ilustración 3.2. "Configuración física de la AFE y posición de los electrodos".
Fuente: Imagen modificada por los autores [32]

La frecuencia de muestreo utilizada fue de 250 Hz, se decidió tomar 8,192 segundos de datos correspondientes a 2048 muestras, con el fin de mejorar el desempeño de la transformada de Fourier [33], para esto fue necesario capturar 3048 muestras de información, para corregir el artefacto generado por la AFE al inicio de la señal muestreada (ver *Ilustración 3.3*), para posteriormente eliminar los primeros 1000 valores y obtener los 8 segundos de señal deseados.

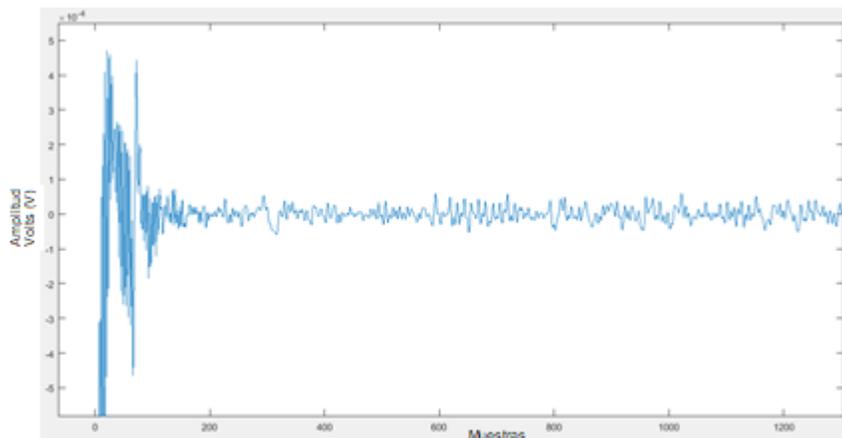


Ilustración 3.3. "Artefacto de la AFE".
Fuente: MATLAB, de los autores



Se tomaron datos de 30 personas, 10 mujeres y 20 hombres, entre 11 y 24 años. Esta toma de datos se realizó en un entorno controlado, sin interferencia sonora, eléctrica y electromagnética. Antes de la recolección de los datos, a cada individuo se le realizaron pruebas de electrooculografía para verificar que la adquisición de la tarjeta estuviera correcta.

A los sujetos de prueba se les indicó realizar las siguientes actividades para recolectar los datos:

- Cerrar los ojos durante 10 minutos.
- Leer un texto durante 20 minutos aproximadamente.
- Realizar una serie de operaciones matemáticas mentalmente, previamente preparadas.

De las grabaciones recolectadas de cada individuo, por cada actividad se seleccionaron los archivos que tuvieran menos artefactos de EEG, tras un previo filtrado realizado por el software de la tarjeta. El software usado es el ADS1299EEGF-PDK-SW: Software for ADS1299EEGF-PDK, su instalación y configuración se realizó de acuerdo a lo plasmado en el manual desarrollado durante la asistencia (Anexo C). El software permite el uso de 3 filtros digitales en el pre procesamiento de la señal: un pasa altos un pasa bajos y un Notch. Por cada sujeto de prueba, se tomaron 2 datos de la primera actividad, un dato de la segunda y uno la tercera, para formar 4 datos por persona, 120 en total.

3.2. Pre procesamiento

Se realizó un filtrado digital mediante el software de la ADS1299EEGF-PDK de Texas Instruments, la estrategia de filtrado que arrojó los mejores resultados, y por lo tanto fue escogida, es la siguiente:

- Filtro pasa altos:
 - Frecuencia de corte: 5Hz.
 - Orden: 3.
- Filtro pasa bajos:
 - Frecuencia de corte: 40Hz.
 - Orden: 8.
- Filtro Notch:
 - Frecuencia Notch: 60Hz.
 - Orden: 5.



Este filtrado permitió una mejor visualización de la señal de las grabaciones realizadas a cada individuo, además de detectar posibles fallas en el momento de la grabación (artefactos extra fisiológicos como ruido electromagnético derivados de algunos dispositivos, ruido mecánico, artefactos de corriente alterna o movimientos de personas alrededor del paciente). Es importante colocar un buen filtro pasa altos ya que esto permitirá reducir los artefactos fisiológicos (Parpadeo, respiración, etc. Todo esto en un rango aproximado de 0.5 Hz a 4 Hz con movimientos musculares que pueden llegar hasta los 6 Hz [20]). En la Ilustración 3.4 se pueden observar señales adquiridas y filtradas con la AFE de sujeto en estado de concentración y no concentración.

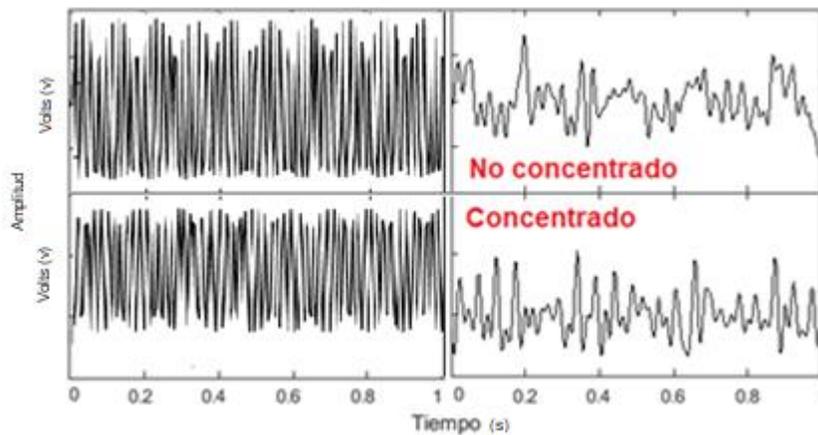


Ilustración 3.4. "Señales antes y después del filtrado".
Fuente: Autores

3.3. Procesamiento

De acuerdo a los objetivos de esta asistencia de investigación, se realizó un estudio sobre métodos de procesamiento de señales de EEG, tras la cual se escogieron e implementaron los 4 métodos que daban mejores resultados, teniendo en cuenta su eficiencia y complejidad, todos con el mismo objetivo, una salida binaria que identifique el estado mental del sujeto: "Concentrado" o "No concentrado". Esto con el fin de tener posibilidad de comparación y de escogencia de la mejor opción para implementar como algoritmo en el proyecto final. Para su implementación se usó el software MATLAB, ya que es un programa de manejo sencillo que permite la manipulación de una gran cantidad de datos, además de ofrecer una gran variedad de librerías y herramientas versátiles que permiten simplificar en gran medida la complejidad matemática de los métodos y algoritmos seleccionados.

A continuación, se describen los 4 métodos seleccionados:



3.3.1. Método 1

Este método comúnmente usado en este ámbito consiste en clasificar señales EEG mediante una red neuronal como lo realiza Verma y Bhatia [31] o mediante un umbral seleccionado según las relaciones de potencias entre bandas, como lo realiza Monastra y Lubar [9] en estados de concentrado o no concentrado, pero en estos casos la señal debe ser tratada previamente para obtener la DSP de esta.

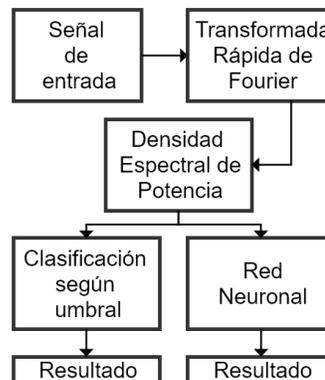


Ilustración 3.5. "Diagrama Método 1".

Fuente: Autores.

En este caso (ver Ilustración 3.5), a la salida de la FFT se obtiene una señal que corresponde al voltaje en función de la frecuencia, para el análisis de EEG se requiere la potencia en función de la misma, para esto es necesario calcular la densidad espectral de potencia o DSP, este valor es igual al cuadrado del valor absoluto de cada elemento a la salida del FFT, en la Ilustración 3.6 se puede observar una ausencia casi total de las ondas beta durante el estado de no concentración, al cambiar de actividad (concentración), estas ondas se hacen presentes, también se ven disminuidas las ondas alfa.

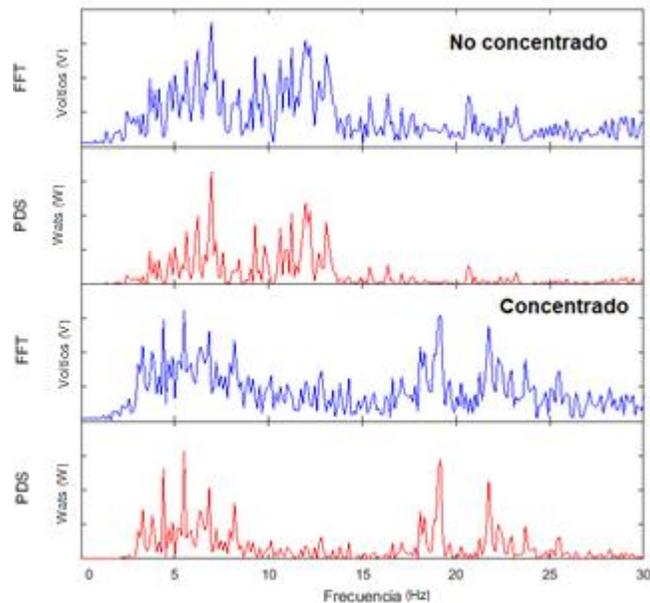


Ilustración 3.6. "FFT de la señal de entrada y DSP de la FFT obtenida".
Fuente: MATLAB, de los autores.

En cuanto a la clasificación mediante red neuronal, se diseñó una red neuronal de tipo Elman Backpropagation de dos capas (ver Ilustración 3.7), esta es una red Feedforward, las cuales se caracterizan por ser simples, pues la información va en una sola dirección (desde la entrada hacia la salida). Las redes Elman son una variación de estas con la diferencia de que tienen conexiones recurrentes, cuando una capa se conecta a ella misma o a alguna capa anterior [34].

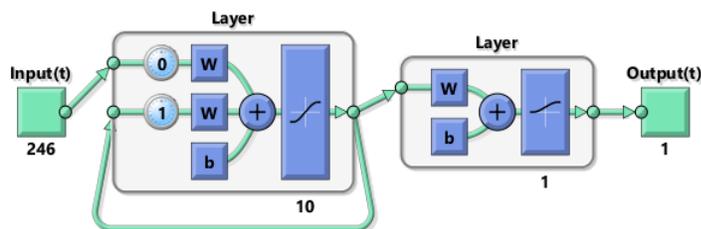


Ilustración 3.7. "Red neuronal Elman backpropagation".
Fuente: MATLAB, de los autores.

La red fue entrenada con los datos de 10 sujetos de prueba, la configuración de esta que otorgó mejores resultados en cuanto a precisión fue con una función de transferencia tan-sigmoide para la primera capa, log-sigmoide para la segunda, función Levenberg-Marquardt para el entrenamiento y error cuadrático medio para el desempeño.



Otro camino explorado para la clasificación consiste en definir una relación entre potencias de las bandas alfa y beta, para esto se usaron los mismos datos de entrenamiento de la red neuronal, y se calculó la relación entre la potencia de estas bandas para así definir un umbral, finalmente se concluyó que siempre que la potencia en beta sea mayor al 81,3% del total de la potencia en alfa se considera que el sujeto se encuentra en estado de concentración.

El código de este método puede encontrarse en el Anexo D.

3.3.2. Método 2

Este método se basa en una investigación propuesta que usa la HHT para extraer las características tiempo-frecuencia de señales de concentración y no concentración, dichas características son la entrada de una red neuronal encargada de clasificar los resultados entre uno de los 2 estados mentales mencionados [16].

Tal como se muestra en la Ilustración 3.8, el primer paso consiste en la descomposición en modo empírico (EMD), se calculan los envolventes superior e inferior de la señal para hallar su promedio, esto se realiza una determinada cantidad de veces [23]. Cada vez que esto se realiza, se corresponde a una función en modo intrínseco (IMF), tal como en el estudio realizado por Aziz y Shapiai [16], el mejor desempeño se obtuvo con un solo IMF.

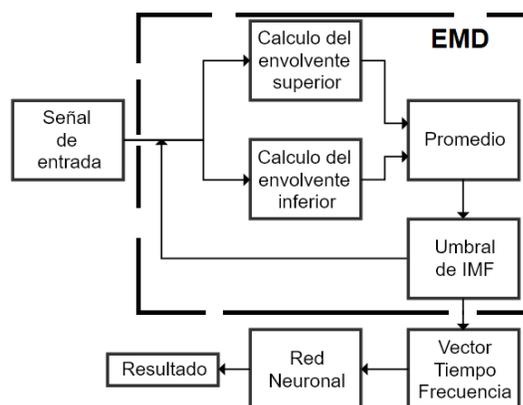


Ilustración 3.8. "Diagrama Método 2".

Fuente: De los autores.

El algoritmo utilizado como base para este proyecto es el propuesto por Manuel Duarte Ortigueira [35]. Tras el cálculo del EMD se procede a transformar la señal de voltaje en Asistencia de investigación. Ingeniería Electrónica, 2019



función del tiempo a una función de frecuencia en función del mismo, en la Ilustración 3.9 se puede ver la diferencia de las señales tiempo-frecuencia para estado de concentración y no concentración, pues durante el primer estado, estas señales oscilan mayormente entre 10 y 15Hz, rango correspondiente a las ondas alfa mientras que en el estado de concentración, se acumulan alrededor y por encima de los 20Hz (ondas beta).

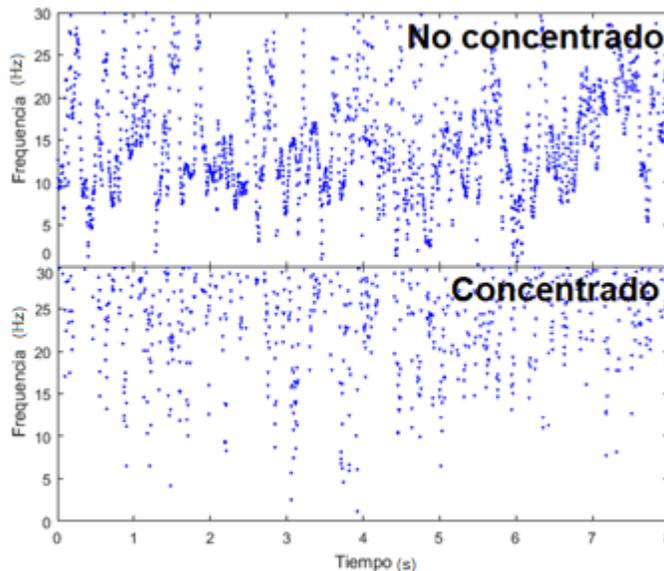


Ilustración 3.9. "Transformada Hilbert Huang".
Fuente: MATLAB, de los autores.

De forma similar al método anterior, la red neuronal (ver Ilustración 3.10) que aportó mejores resultados para Hilbert Huang fue una red de tipo Feed-forward backpropagation de dos capas.

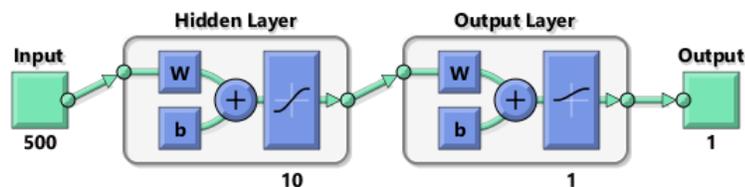


Ilustración 3.10. "Red neuronal Feed-forward backpropagation".
Fuente: MATLAB, de los autores.

Esta red fue también entrenada con los datos de 10 sujetos de prueba, la configuración de esta que logró mejores resultados fue con una función de transferencia tan-sigmoide



para la primera capa, log-sigmoide para la segunda, función gradiente descendente para el entrenamiento y error cuadrático medio para el desempeño.

El código de este método puede encontrarse en el Anexo D.

3.3.3. Método 3

Este método usa CSP, el acrónimo CSP hace referencia a Common Spatial Patterns, es una técnica matemática usada en el procesamiento para separar señales multivariables en subcomponentes con distintas varianzas.

El método utilizado en este trabajo es mostrado en la Ilustración 3.11.

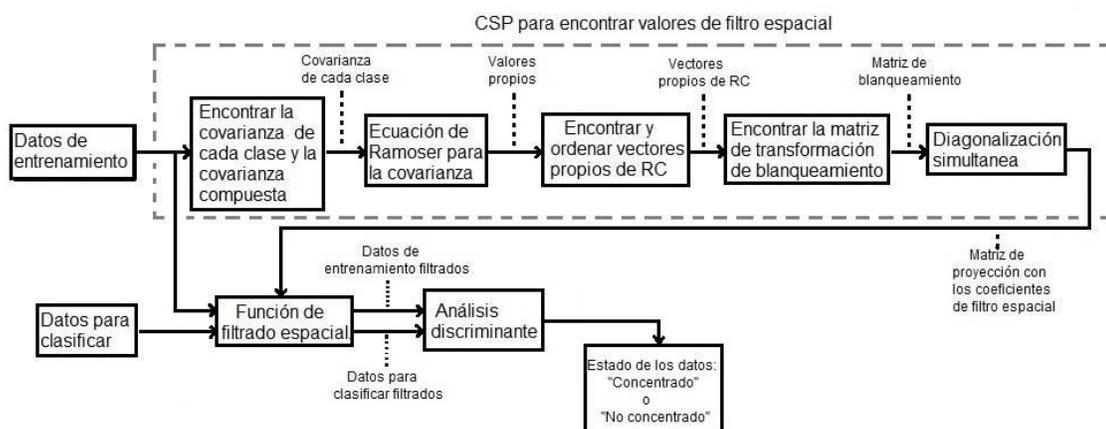


Ilustración 3.11. "Diagrama Método 3".

Fuente: Autores

El diagrama de bloques tiene como entradas los "Datos de entrenamiento" tomados antes de la sesión de grabación de las actividades correspondientes a estados de concentración y no concentración, por otro lado, los "Datos para clasificar" son los archivos para determinar el estado de concentración.

En los "Datos de entrenamiento" se ingresan 4 archivos, los cuales se dividen en dos clases (Clase 1 No Concentrado, Clase 2 Concentrado), estos se ingresan en forma de matriz (4x4), en la que la primera columna corresponde a Clase 1 y la segunda columna a clase 2.



Como primer paso se obtienen los Coeficientes del filtrado espacial, que son las características de los datos de entrenamiento, lo cual va a permitir que el clasificador tenga una mejor discriminación y así obtener una mejor clasificación. El método para la extracción de estos coeficientes es el propuesto por Ethridge y Weaver [36] .

Este algoritmo implementado en MATLAB, en su inicio, encuentra la covarianza de cada clase, este valor permite encontrar valores propios de cada estado, en un siguiente paso, se ordenan los valores propios para formar los vectores con los que se halla la matriz de blanqueamiento, posteriormente se diagonaliza, y así encontrar los coeficientes para el filtrado espacial de las señales.

En una segunda medida, los coeficientes obtenidos de los datos de entrenamiento se ingresan a la función de Filtrado Espacial, lo cual permitirá separar las señales con distintas varianzas, de acuerdo a las características de entrenamiento. El resultado de las señales de las clases antes y después del filtrado se puede observar en la Ilustración 3.12, donde el filtro maximiza la varianza de la clase 1 y minimiza la de la clase 2.

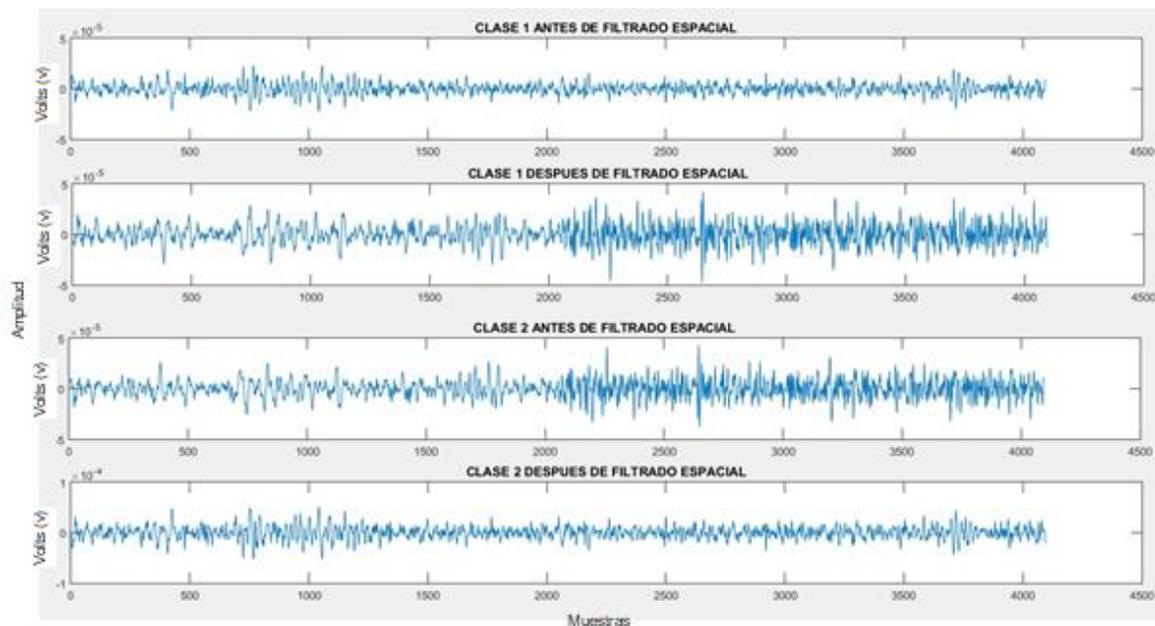


Ilustración 3.12. "Clases Entrenamiento antes y después de Filtrado Espacial". Fuente: MATLAB, de los autores.

La ilustración 3.12 se realizó con datos de entrenamiento del paciente 1 (Anexo B) se observa que los filtros espaciales cambian la amplitud de la clase 1 (No concentración) y



la clase 2 (Concentración), modificando la varianza. Esto lo realiza para tener una mejor discriminación de las clases en el momento de la clasificación.

Luego de usar los Datos de entrenamiento se procede a ingresar las señales de las actividades realizadas por los individuos a la función de Filtrado Espacial. Esto permitirá realizar la clasificación de la señal con las características obtenidas de los datos de entrenamiento. Se ingresó por cada actividad realizada los datos de 4 individuos.

Como último paso, se realiza el análisis discriminante de las señales que pasan por el Filtro Espacial, este análisis realiza la comparación de la media de la señal filtrada a clasificar a través de los grupos de características de las clases obtenidas a partir de los datos de entrenamiento. Como resultado se obtiene el estado de concentración del individuo.

El código de este método puede encontrarse en el Anexo D.

3.3.4. Método 4

Este método se basa en el propuesto por Armin, Mumtaz, Subhani, Saad y Malik [14]. Este algoritmo entrena un clasificador SVM con características obtenidas a partir de la Transformada Discreta de Wavelet (DWT) (Ver Ilustración 3.13).

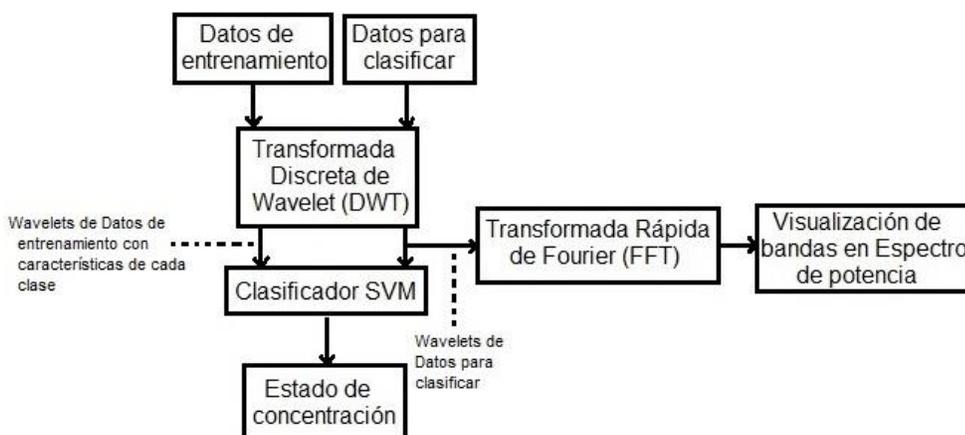


Ilustración 3.13. "Diagrama Método 4".

Fuente: Autores.

Como primer paso se seleccionan los Datos de entrenamiento, uno con características de estado de concentración y otro con características de no concentración.



El segundo paso del diagrama es aplicar la DWT, esta permite una descomposición de la señal, a partir de un filtrado sucesivo de paso alto y bajo de una serie de tiempo con una tasa de muestreo descendente de 2. El filtro de paso alto es la wavelet "madre" discreta y el filtro de paso bajo es su versión "espejo".

De la descomposición de las wavelet de la señal, se aplica la FFT para observar sus espectros en cada banda de frecuencia. La Ilustración 3.14 muestra los espectros de frecuencia obtenidos con el sujeto 1 de prueba.

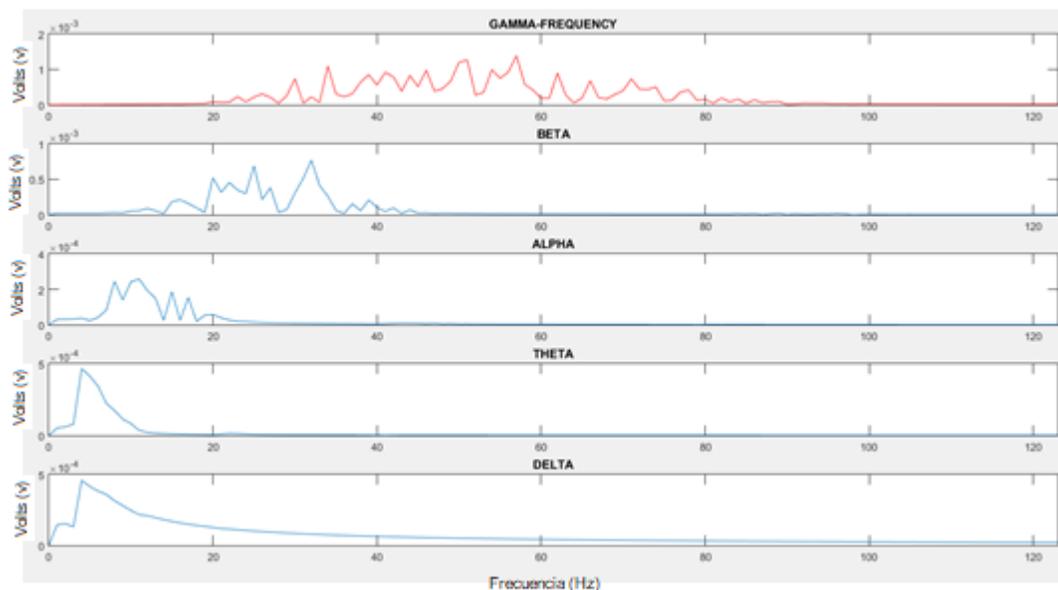


Ilustración 3.14. "Espectros de frecuencia de las Wavelets".

Fuente: MATLAB, de los autores.

Para el entrenamiento del clasificador SVM, se utilizan las Wavelets de los datos de entrenamiento, esto permite dar características a cada clase a partir de la DWT. Luego de entrenar el clasificador, se ingresan las Wavelets obtenidas de los datos para clasificar. El SVM asocia las características de los datos ingresados con las características de cada clase, ya separadas por el clasificador, y como resultado, se obtiene el estado de concentración del individuo en estudio.

El código de este método puede encontrarse en el Anexo D.



4. Resultados

Para cada uno de los métodos propuestos se realizó una interfaz, esta muestra si el sujeto está o no concentrado según los resultados del análisis y adicionalmente se visualiza la señal o señales de entrada, además de otras gráficas del procesamiento en los casos en que estas sean útiles, se muestran los resultados para 4 sujetos en (Anexo B). Los resultados de cada señal procesada por cada uno de los métodos pueden encontrarse en el anexo F.

4.1. Validación

Para la comparación entre los cuatro métodos, los algoritmos se evaluaron en términos de tiempo computacional, sensibilidad, selectividad, especificidad y F1 score, estos valores se calculan mediante el número de verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP) y falsos negativos (FN) obtenidos tras aplicar los algoritmos correspondientes a toda la base de datos sin contar las señales usadas para los entrenamientos de estos.

$$\text{Sensibilidad} = \frac{VP}{VP+FN} * 100\%$$

Ecuación 4.1.

$$\text{Selectividad} = \frac{VP}{VP+FP} * 100\%$$

Ecuación 4.2.

$$\text{Especificidad} = \frac{VN}{VN + FP} * 100\%$$

Ecuación 4.3.

$$\text{Precisión} = \frac{\text{Sensibilidad} + \text{Especificidad}}{2} * 100\%$$

Ecuación 4.4.

$$\text{F1 score} = 2 \times \frac{\text{Selectividad} \times \text{Sensibilidad}}{\text{Selectividad} + \text{Sensibilidad}} * 100\%$$

Ecuación 4.5.



En la Tabla 4.1 puede observarse la comparación de todos los métodos implementados teniendo en cuenta el tiempo computacional. Se tomó el 40% de la base de datos para el entrenamiento, por lo que los datos siguientes se calcularon a partir del 60% restante para la validación.

Tabla 4.1. "Comparación de métodos de procesamiento".

Término a evaluar	Método 1		Método 2	Método 3	Método 4
	Red	Umbral			
Sensibilidad	70%	95%	63%	93%	65%
Selectividad	88%	79%	81%	82%	72%
Especificidad	90%	75%	85%	80%	75%
Precisión	80%	85%	74%	87%	70%
F1 score	78%	86%	70%	88%	68%
Tiempo de cómputo (s) ³	0,28	0,21	0,37	2,32	2,65

Fuente: De los autores

Aunque los valores descritos en la tabla parecen bajos, se encuentran dentro del umbral de estudio de análisis de señales de EEG, como se observa en los resultados de investigaciones realizados por Edla y Mangalorekar [2], Monastra y Lubar [9], Bachivan y Rish [15], Aziz y Shapiai [16], Verma y Duhan [31], Vézard y Legrand [37].

Para seleccionar el mejor método, se le dio un valor del 90% al F1 Score y un 10% al tiempo computacional, de la siguiente manera:

$$ValorFinal = F1\ Score - \left(0.1 * \frac{Tiempo}{TiempoMax}\right) * 100\%$$

Ecuación 4.6.

Donde el Tiempo máximo hace referencia a los 2.65s del método 4.

De esta manera se obtuvieron los siguientes valores para cada método:

Método 1: 77% con red y 85% con umbral.

Método 2: 69%

Método 3: 79%

Método 4: 58%

³ El tiempo de computo se calculó en un computador con procesador Intel Core i3-2328M CPU @ 2.20GHz con 4 GB de RAM



El método seleccionado es el método 1 con umbral de relación de frecuencia. Aunque el método 3 muestra unos mejores resultados en cuanto a precisión, el método 1 requiere una menor cantidad de tiempo computacional, esencial para este Macroproyecto, pues para una correcta retroalimentación, se requiere determinar el estado mental del sujeto lo más rápido posible durante las actividades que realice. Este método también es bastante simple y fácil de modificar en caso de ser necesario un cambio a futuro.

4.2. Pruebas finales

El método escogido fue sometido a una prueba usando datos de entrada tomados de la herramienta PowerLab DAQ modelo 26T de ADInstruments con el software libre (stand-alone) Scope For Windows. Para esto se tomaron 48 datos de 4 sujetos, ejecutando las mismas actividades realizadas en la construcción de la base de datos con la tarjeta AFE. Al aplicarse el algoritmo, el 75% de los datos fueron clasificados correctamente, obteniendo una eficiencia menor que con la base de datos principal pero considerablemente buena teniendo en cuenta la variación en el proceso de adquisición. En la Ilustración 4.15 se puede apreciar la diferencia entre densidad espectral de potencia de 2 señales de no concentración y concentración respectivamente.

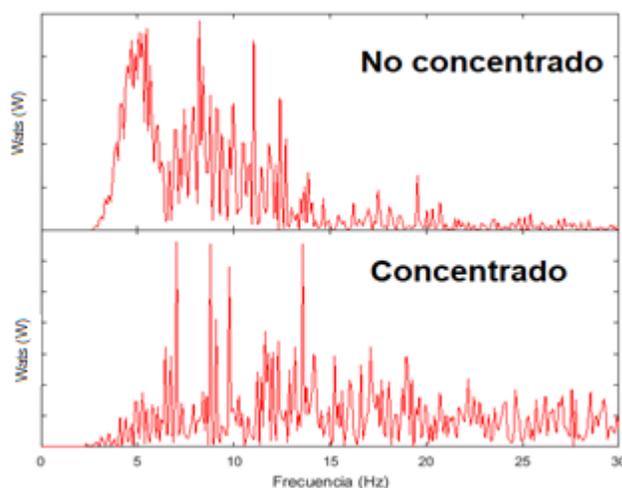


Ilustración 4.15. "Densidad Espectral de Potencia con datos de PowerLab".

Fuente: MATLAB, de los autores

Adicionalmente desde la base de datos de PhysioNet [38] se tomaron datos de 36 sujetos realizando actividades aritméticas, el algoritmo desarrollado fue puesto a prueba con estos datos, de los cuales, clasificó correctamente el 80% de estos datos, teniendo



en cuenta que esta base de datos asegura la legitimidad de las señales EEG en ella, los resultados son bastante positivos. Se aprecia en la Ilustración 4.16 el DSP de dos señales que el algoritmo clasificó como concentrado y no concentrado de la base de datos de PhysioNet.

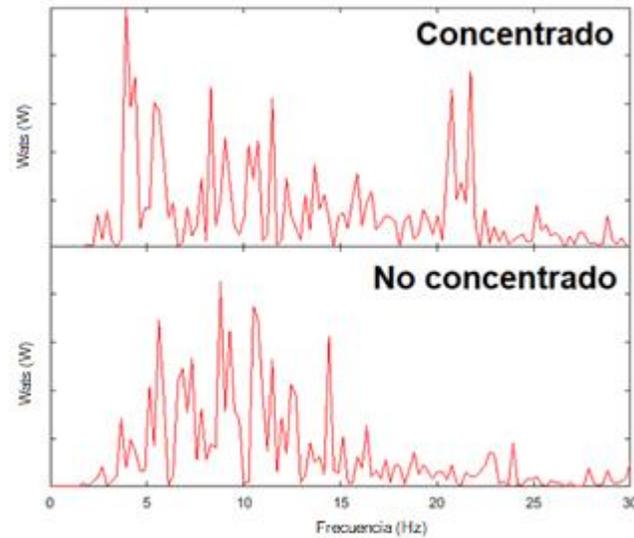


Ilustración 4.16. "Densidad espectral de potencia con datos de PhysioNet".
Fuente: MATLAB, de los autores.

En el anexo E puede encontrarse una tabla con los resultados de las pruebas con cada señal tras el procesamiento.



5. Conclusiones y recomendaciones

5.1. Conclusiones

- Se logró recolectar una amplia cantidad de información sobre los métodos de clasificación de señales encefalográficas según el nivel de concentración para seleccionar los 4 mejores.
- Se creó una base de datos con 30 personas realizando actividades de concentración y no concentración, con las cuales se logró entrenar y validar cada uno de los 4 métodos.
- Se implementaron los 4 métodos seleccionados como los mejores y se compararon y validaron para encontrar el mejor.
- Se realizaron pruebas finales con bases de datos externas como Powerlab y Physionet, corroborando el correcto funcionamiento del método finalmente escogido.
- El filtrado de las señales de EEG es bastante importante para analizarlas, pues los artefactos tanto fisiológicos como no fisiológicos se encuentran muy presentes, afectando el procesamiento de estas, sumado al bajo nivel de señal que se captura desde los electrodos.
- El método 1 demostró ser bastante eficiente a pesar de su simplicidad, con esto se manifiesta porque a pesar de ser de los métodos más básicos, sigue siendo de los más usados en la actualidad.
- Aunque a que el método 2 ha demostrado ser muy confiable, en este caso, no pudo alcanzar un rendimiento tan bueno como con los otros métodos, puesto que requiere una gran cantidad de datos y potencia de hardware de la que no se disponía para entrenar la red neuronal de forma correcta.
- El método 3 muestra una precisión baja al tener pocas muestras de entrenamiento, por lo que fue necesario evaluar varios archivos al tiempo para mejorar esto, lo que derivó en que su tiempo computacional aumentara.
- En el método 4, aunque permite una mejor discriminación (debido a su descomposición) de las bandas donde se enfoca este estudio, implica un aumento de cálculo computacional; además, las características obtenidas no son determinantes al momento de la clasificación.
- La validación, aunque arrojó buenos resultados, indica que se puede mejorar un poco más, tanto la adquisición de datos, como la selección de características del método, para que así se obtenga una mejor clasificación. Esta validación al realizarse con base de datos validadas por un dispositivo de excelente



adquisición como el Powerlab, y, una base de datos confiable como las de PhysioNet, le da un peso importante a la investigación realizada.

- Con lo probado en este estudio y lo leído en estudios anteriores, puede apreciarse que métodos de procesamiento muy largos o complejos pueden dar resultados negativos con respecto a otros más sencillos. Para esta aplicación es esencial el tiempo de procesamiento ya que se busca que determine el estado del paciente al instante.
- Tras un extenso estudio en el campo del análisis digital de señales EEG para determinar el estado de concentración y la implementación de los métodos de procesamiento más usados y con mejores resultados, puede concluirse que el método de análisis de densidad espectral de potencia es el más adecuado para el objetivo principal de este macroproyecto debido a su alta eficiencia, poca complejidad y bajos requisitos computacionales para su correcto funcionamiento.
- Con base en la experiencia de la investigación, se elaboró un artículo científico “Clasificación de estado de concentración de señales EEG adquiridas con AFE” que se encuentra en revisión para ser sometido a una revista indexada.

5.2. Recomendaciones

- Durante la toma de datos es importante cerciorarse de que estos se adquieran correctamente, pues en caso de captar solo ruido, este puede confundirse fácilmente con señales de EEG.
- Es importante seleccionar correctamente los datos de entrenamiento para una mejor clasificación, ya que estos datos permiten diferenciar las características de cada estado, además de las características de cada sujeto, permitiendo una mayor precisión en cada método.
- Se recomienda tener un ambiente controlado al momento de realizar la adquisición de los datos, se recomienda un lugar sin ruido, con iluminación aceptable y en lo posible sin ninguna interferencia electromagnética, todo esto para una buena base de datos.
- Como limitación se tuvo que el software de la tarjeta AFE requiere guardar los datos manualmente, ya que no lo hace de forma automática, por lo que a futuro se podría desarrollar un software que permita hacerlo, ya que mejorará el tiempo de retroalimentación con el usuario. No obstante, esta limitante se resolverá con la asistencia de investigación asociada a este proyecto, que emplea directamente el AFE de Texas para la adquisición de la señal EEG, desarrollado por Henry Bocanegra y que se empalmará con el algoritmo desarrollado en esta parte del proyecto de investigación.



Referencias

- [1] E. Niedermeyer y F. L. Da Silva, *Electroencephalography: basic principles, clinical applications, and related fields*, Sixth edition ed., Philadelphia USA: Wolters Kluvert, 2001.
- [2] D. R. Edla, K. Mangalorekar, G. Dhavalikar y S. Dodia, «Classification of EEG data for human mental state analysis using Random Forest Classifier,» de *Procedia Computer Science*, India, 2018.
- [3] R. Aler Mur, A. Vega, I. M. Galván León y N. Antonio J, «Multi-objective metaheuristics for preprocessing EEG data in brain–computer interfaces,» pp. 373-390, 2012.
- [4] G. Schalk y E. C. Leuthardt, «Brain-Computer Interfaces Using Electrographic Signals,» 2011.
- [5] J. Yanbing, W. S. Oluwarotimi, L. Xueyu , W. Xin, P. Oluwagbenga Idowu, L. Peng, C. Fei, Z. Mingxing , G. Yanjuan, W. Fengxia, C. Shixiong y L. Guanglin, «Effective Biopotential Signal Acquisition: Comparison of Different Shielded Drive Technologies,» *Applied Sciences.*, vol. 8, 2018.
- [6] C. A. Aldana Ramirez y E. Buitrago Bolivar, «Actualidad en la investigación de electroencefalograma - resonancia magnética funcional simultáneos en el estudio de epilepsia y dolor,» *Revista Cubana de Investigaciones Biomédicas*, 2013.
- [7] H. Zhang, C. Guan, A. S. Hamadi Charef, C. Wang y K. S. Phu, «Method And System For Concentration Detection». Estados Unidos Patente US8862581B2, 14 Octubre 2014.
- [8] J. D. Cowan y A. J. Prell, «Method for determining an individual's intensity of focused attention and integrating same into computer program». Estados Unidos Patente US5983129A, 9 Noviembre 1999.
- [9] V. J. Monastra y J. F. Lubar, «Quantitative Electroencephalographic (QEEG) process and apparatus for assessing attention deficit hyperactivity disorder». Estados Unidos Patente US6097980A, 1 Agosto 2000.
- [10] Z. Xiong, S. Shi y H. Xu, «Controlled study of the effectiveness of EEG biofeedback training on children with attention deficit hyperactivity disorder,» *Journal of Huazhong University of Science and Technology*, 2005.
- [11] Y. Zhang, Z. Li, J. Xu y T. Zhu, «The influence of relaxation training on EEG and mood».
- [12] Huiche Science Company, «Kether,» [En línea]. Available: <https://kether.cn/index.html>. [Último acceso: 7 Diciembre 2018].



- [13] M. Doppelmayr, W. Klimesh y P. Sauseng, «Intelligence related differences in EEG-bandpower,» *Neuroscience letters*, pp. 309-13., 2005.
- [14] H. Armin, W. Mumtaz, A. Subhani, M. Saad y A. Malik, «Classification of EEG Signals Based on Pattern Recognition Approach,» *Frontiers in Computational Neuroscience*, 2017.
- [15] P. Bashivan, I. Rish y S. Heisig, «Mental State Recognition via Wearable EEG,» Memphis, TN, USA, 2016.
- [16] F. A. Abdul Aziz, N. A. Setiwan, M. I. Shapiay y Y. Mitsukura, «Classification of Human Concentration in EEG Signals using Hilbert Huang Transform,» de *International Journal of Simulation: Systems, Science and Technology.*, Malasia, 2017.
- [17] L. Boquete Vázquez y R. Barea Navarro, «Actividades en ingeniería biomédica en el departamento de Electrónica de la Universidad de Alcalá,» 2003.
- [18] T. Talamillo García, «Manual básico para enfermeros en electroencefalografía,» *Enfermería Docente*, pp. 94: 29-33, 2011.
- [19] E. A. Sciotto, «Ondas cerebrales, conciencia y cognición,» *Researchgate*, 2018.
- [20] R. A. Alagia Gimeno, Procesamiento de artefactos en EEG para aplicaciones, Valencia, España, 2018.
- [21] J. G. Proakis y D. K. Manokalis, Digital Signal Processing, Third Edition ed., Prentice Hall , 2009.
- [22] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung y h. H. Liu, «The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis,» *Royal Societyy*, vol. 454, nº 1971, 8 Marzo 1998.
- [23] F. A. Marengo Rodriguez, «Transformada de Hilbert-Huang y sus aplicaciones en ingeniería y ciencias,» Rosario, Argentina, 2013.
- [24] D. J. Matich, «Redes Neuronales: Conceptos Básicos y Aplicaciones,» 2001.
- [25] F. J. Olías Sánchez, Estudio del método Common Spatial Patterns y sus variantes en interfaces cerebro ordenador, Sevilla, España: Universidad de Sevilla, 2016.
- [26] I. Xygonakis, A. Athanasiou, N. Pandria , D. Kugiumtzis y P. D. Bamidis, «Decoding Motor Imagery through Common Spatial Pattern Filters at the EEG Source Space,» *Computational Intelligence and Neuroscience*, vol. 2018, nº 7957408, p. 10, 2018.
- [27] A. Ortega Tello y E. Hernandez Hernandez, «Transformada Wavelet Curso,» 2006, pp. 50-62.
- [28] S. Patel, «SVM (Support Vector Machine)—Theory,» 3 Mayo 2017. [En línea]. Available: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector->



- machine-theory-f0812effc72. [Último acceso: 13 Febrero 2019].
- [29] Texas Instruments, ADS1299-x Low-Noise, 4-, 6-, 8-Channel, 24-Bit, Analog-to-Digital Converter for EEG and Biopotential Measurements, National Instrument, 2017.
- [30] A. Subasi, «Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients,» de *Expert Systems with Applications*, Kahramanmars, Turquía, ELSEVIER, 2005, pp. 603-840.
- [31] D. Verma, D. Bhatia y M. Duhan, «Neural Network Training to Recognize Mental State,» *Department of Electronics and Communication Engineering, Deenbandhu Chhotu Ram University of Science*, 2012.
- [32] Texas Instruments, *EEG Front-End Performance Demonstration Kit*, 2016.
- [33] A. Franco García, «Transformada rápida de Fourier (I),» 2016. [En línea]. Available: http://www.sc.ehu.es/sbweb/fisica3/datos/fourier/fourier_1.html. [Último acceso: 27 Enero 2019].
- [34] I. M. Galván y J. M. Valls, «REDES DE NEURONAS ARTIFICIALES,» Madrid, España, 2017.
- [35] M. Duarte Ortigueira, «Hilbert-Huang Transform,» MathWorks, 31 Marzo 2016. [En línea]. Available: <https://www.mathworks.com/matlabcentral/fileexchange/19681-hilbert-huang-transform>. [Último acceso: 4 Febrero 2019].
- [36] J. Ethridge y W. Weaver, «Common Spatial Patterns,» MathWorks, 7 Febrero 2009. [En línea]. Available: <https://la.mathworks.com/matlabcentral/fileexchange/22915-common-spatial-patterns>. [Último acceso: 2 Febrero 2019].
- [37] L. Vézard, P. Legrand, M. Chavent, F. Faïta-Aïnseba y L. Trujillo, «EEG classification for the detection of mental states,» de *Applied Soft Computing*, Tijuana, Baja California, México, ELSEVIER, 2015, pp. 113-131.
- [38] I. Zyma, S. Tukaev, I. Seleznov, K. Kiyono, A. Popov, M. Chernykh y O. Shpenkov, «EEG Durin Mental Arithmetic Tasks,» *PhysioNet*, 2018 Diciembre 18. [En línea]. Available: <https://physionet.org/physiobank/database/eegmat/>. [Último acceso: 26 Febrero 2019].
- [39] J. Perez Porto y A. Gardey, «Definicion.de,» 2013. [En línea]. Available: <https://definicion.de/positron/>. [Último acceso: 15 Marzo 2019].
- [40] Bionic Iberica S.A., «Bionic,» [En línea]. Available: <http://www.bionic.es/product/espectroscopia-funcional-del-infrarrojo-cercano-fnirs/>. [Último acceso: 15 Marzo 2019].



Anexos

Anexo A. Tabla de diferentes métodos usados para detectar nivel de concentración.

Método	Resumen	Complejidad	Eficiencia	Validación
CSP	Este es un método y un sistema para la detección de la concentración. El método para la detección de la concentración incluye los pasos para extraer características temporales de las señales del cerebro; clasificar las características temporales extraídas utilizando un clasificador para obtener una puntuación x_1 , extrae las características espectro-espaciales de las señales cerebrales; selecciona las características espectro-espaciales que contienen información discriminativa entre los estados de concentración y no concentración del conjunto de características espectro-espaciales extraídas; clasifica las características espectro-espaciales seleccionadas utilizando un clasificador para obtener una puntuación x_2 , combinando las puntuaciones x_1 y x_2 para obtener una puntuación única; y determina si el sujeto está en un estado de concentración basado en la puntuación única. Sistema 10-20	1. Matriz de CSP y red neuronal 2. Cálculo de estadísticas y Red neuronal Se fusionan los datos	14,8% mejor que monastr y lubar	Se aplica este estudio experimental a 5 sujetos participantes.
Monastr y Lubar	El proceso comprende un método de escaneo que obtiene datos cuantitativos de EEG de un electrodo colocado en un solo sitio craneal activo (Cz, el vértice). Se obtienen múltiples periodos cortos (90 segundos) de EEG digitalizado. Se examina la potencia electrofisiológica en dos bandas de frecuencia (theta: 4-8 Hz; beta: 13-21 Hz). Con computador se realiza una Selección de Transformación Rápida de Fourier y se analiza estadísticamente la potencia en estas bandas de frecuencia de EEG específicas. Se obtiene un índice neurométrico al calcular la proporción de la potencia electrofisiológica registrada dentro de la banda theta y la banda beta, mientras que el individuo mantiene una mirada fija. A partir de entonces, la persona a la que se le realiza la prueba de TDAH se evalúa bajo condiciones que requieren un comportamiento atento (lectura, escucha, dibujo). Se calcula una relación de potencia theta / beta para cada una de estas tareas. Finalmente, se calcula un promedio de las relaciones de potencia a lo largo de la línea de base, las tareas de lectura, escucha y dibujo, y se obtiene un Índice de Atención y se compara con una base de datos obtenida a través de las evaluaciones de una muestra normativa de individuos que no tienen TDAH o cualquier otro trastorno neurológico. La evaluación de la presencia y la gravedad del TDAH se determina a partir de esta comparación. 1 electrodo	FFT Relacion theta beta (manualmente)	Presición 94% comparando con DCM IV Sensibilidad 86% Especificidad 98%	DCM IV Con sus propios datos Personas diagnosticadas con TDAH
Calculo de CI	Este estudio valida la idea de que el TDAH (Trastorno por Déficit de Atención / Hiperactividad) interfiere con la transición de una tarea a otra y esta interferencia puede cuantificarse mediante un Índice de consistencia (IC) derivado de una representación matemática específica de los datos del EEG.	FFT Se calcula la potencia en cada banda Cambio de potencia entre 2 tareas <- calculo de CI	Coincide con los criterios del DCM IV 88% en niños 67% en niñas	DCM IV Con sus propios datos Personas diagnosticadas con TDAH
Random Forest	Se usó un solo electrodo seco (fp1 del sistema 10/20), se tomaron datos de 40 sujetos (33 hombres y 7 mujeres). Las características de las señales de EEG se extraen con medidas estadísticas como media, desviación estándar y amplitudes máximas y mínimas; se utiliza el clasificador random forest. Se busca predecir los estados mentales como meditación y concentración. Se utiliza neurosky mindwave mobile que entrega 8 valores correspondientes a las sub-bandas.	Características estadísticas (media, desviación estándar, máximos y mínimos). Clasificador Random Forest. Matriz de confusión.	La precisión es del 75%, 80% para detectar concentración 70% no-concentración	Con sus propios datos
CSP 2	Es un método para detectar estados de alerta (está pensado para pilotos y personal médico). Este método puede ayudar a detectar posibles desviaciones de este estado. Se propone un sistema de clasificación binaria ("relajado" y "normal"). Se tomaron datos de 50 sujetos (todos diestros) en ambos estados de alerta (116 datos) con 58 electrodos (sistema 10/10), se eligieron 19 sujetos para hacer el análisis. Se usó un algoritmo genético para seleccionar el mejor número de electrodos (9). Para predecir el estado de alerta se usó CSP (Common Spatial Pattern) acoplado a LDA (Linear Discriminant Analysis). Es demasiado costoso en tiempo.	CSP con dos conjuntos de filtros especiales con 3 números de pares. Normalización de datos. Proyección de datos. Estrategia LOO (Leave One Out).	71% de precisión. El algoritmo tarda 4.21*10 ⁴ s en dar una respuesta en un computador con Windows 8 núcleos 2.8GHz Intel Core i7 2920XM processors and 16GB 2.5GHz RAM	Con sus propios datos
Fourier y Red	Se utiliza la FFT (Fast Fourier Transform). Seguida de una Red neuronal para clasificar en estados de concentración y no-concentración Se utiliza un electrodo (fp1 del sistema 10/20).	FFT. DSP. Red neuronal.	77% de precisión	Con sus propios datos
Hilbert Huang	Se utiliza la HHT (Hilbert Huang Transform). Consiste en 2 pasos, primero se usa EMD (Empirical Mode Decomposition) para descomponer la señal en un conjunto de IMF (Intrinsic Mode Functions) Luego se utiliza la transformada para obtener el espectro de potencia para extraer las características importantes de las sub-bandas. Se utiliza un ELM (Extreme Learning Machine) como clasificados para distinguir los 2 estados mentales. Se utiliza un electrodo (fp1 del sistema 10/20).	HHT Red neuronal.	Entre 72 y 85% de precisión	Con sus propios datos
Wavelets	Busca detectar estados de alerta, adormecimiento y sueño. Se utiliza la transformada Wavelet y una ANN (Artificial Neural Network). A la salida de la red neuronal se encuentran 3 salidas discretas correspondientes a los 3 estados mentales mencionados. Las señales fueron obtenidas de 20 sujetos (16 mujeres y 14 hombres) con un índice de masa corporal de 32,427,3kg/m ³ . Una arquitectura ANN 15-32-3, con función de transferencia tan-sigmoide para la primera capa y función log-sigmoide para la segunda capa, es la estructura óptima para esta aplicación. Se encontró que el BP flexible es el mejor algoritmo de entrenamiento. 1 electrodo	Transformada Wavelet Características estadísticas. Red neuronal	93% de precisión 89% de sensibilidad 90% de selectividad	Con sus propios datos 2 neurologos con experiencia
Wavelets 2	Busca detectar cambios en la actividad mental. Videos educativos y videos de gatos. Usan 4 Electrodo. Se tomaron datos de 6 mujeres.	Transformada Wavelet Red Neuronal	75% de precisión	Con sus propios datos
CSP 3	CSP Modelo SVM y Red neuronal para comparar	CSP Support Vector Machine Red neuronal	93% de precisión con SVM 87% de precisión con red neuronal	Con sus propios datos

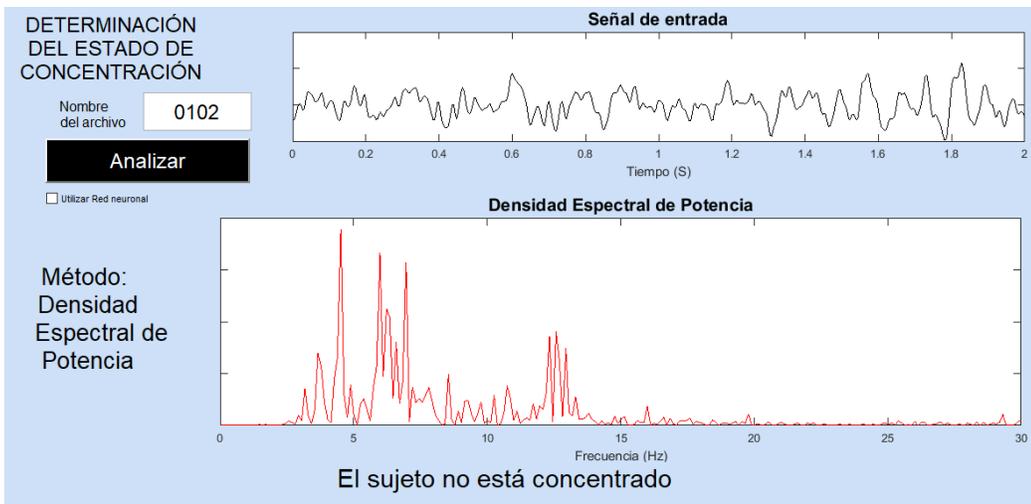
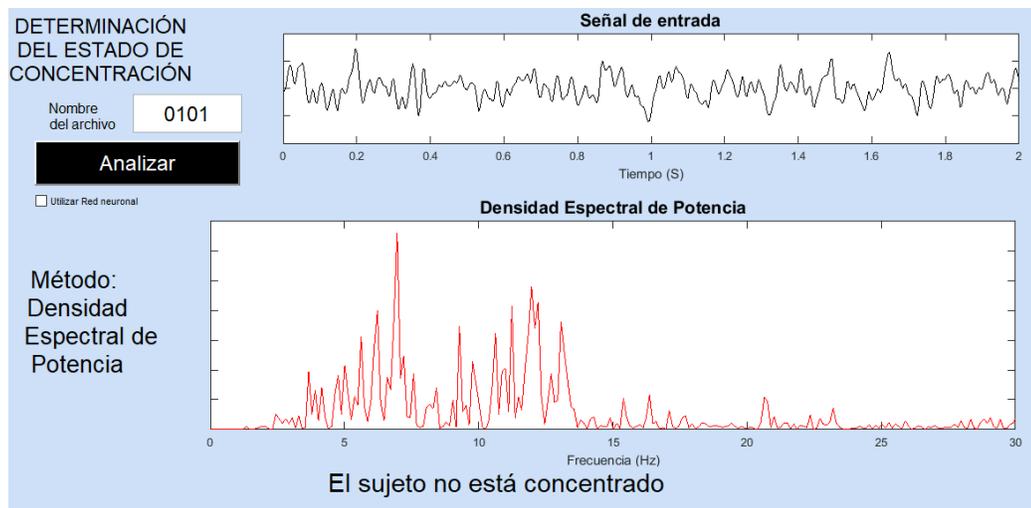
Para una mejor visualización de la tabla de métodos revisar archivo adjunto.

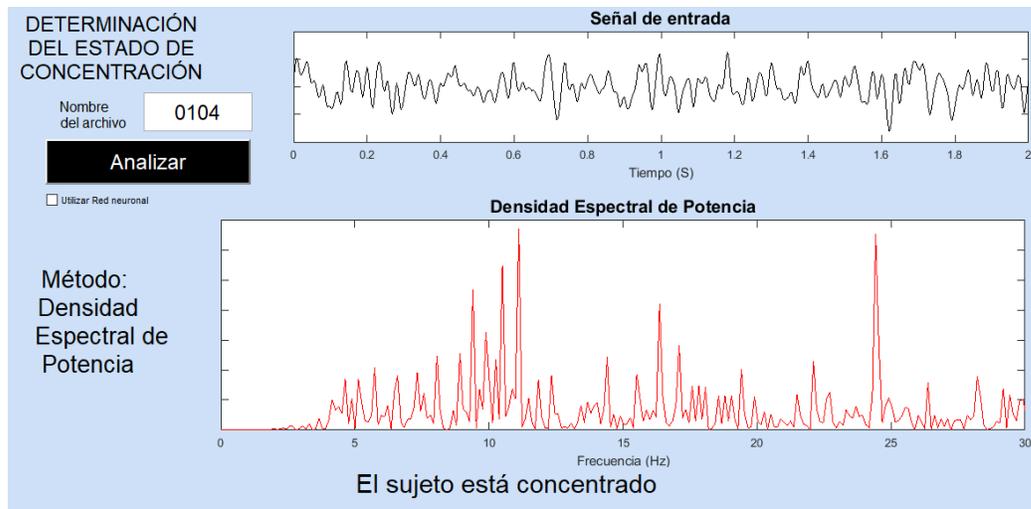
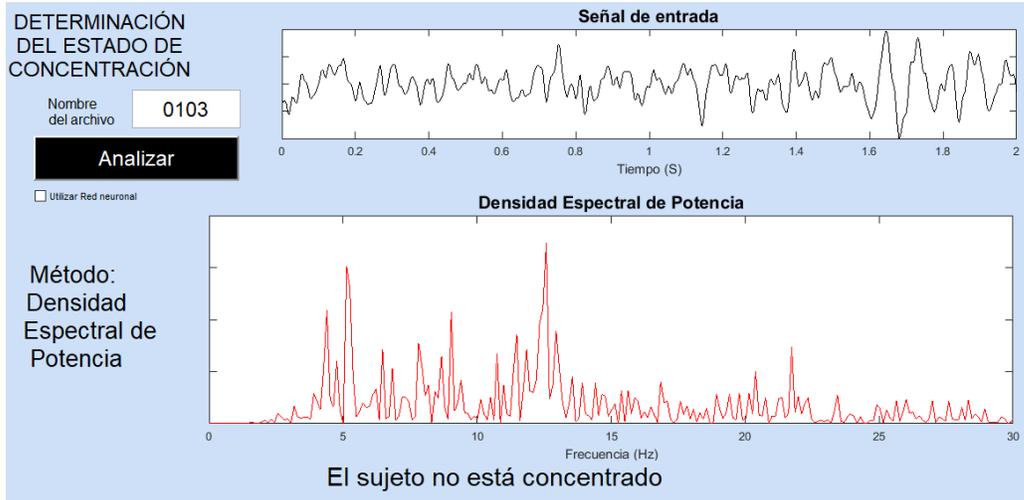


Anexo B. Estado de concentración para 4 pacientes con cada método evaluando las actividades propuestas.

En el siguiente anexo se adjunta los resultados al aplicar cada uno de los métodos propuestos para 3 pacientes, se incluyen los pantallazos de la interfaz con la clasificación que hizo cada algoritmo con las actividades realizadas de cada paciente.

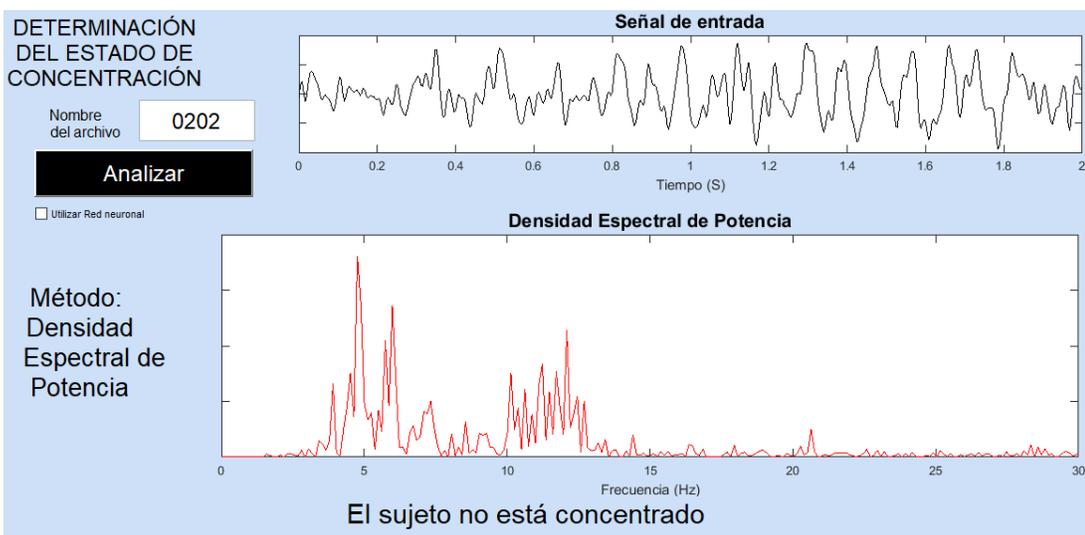
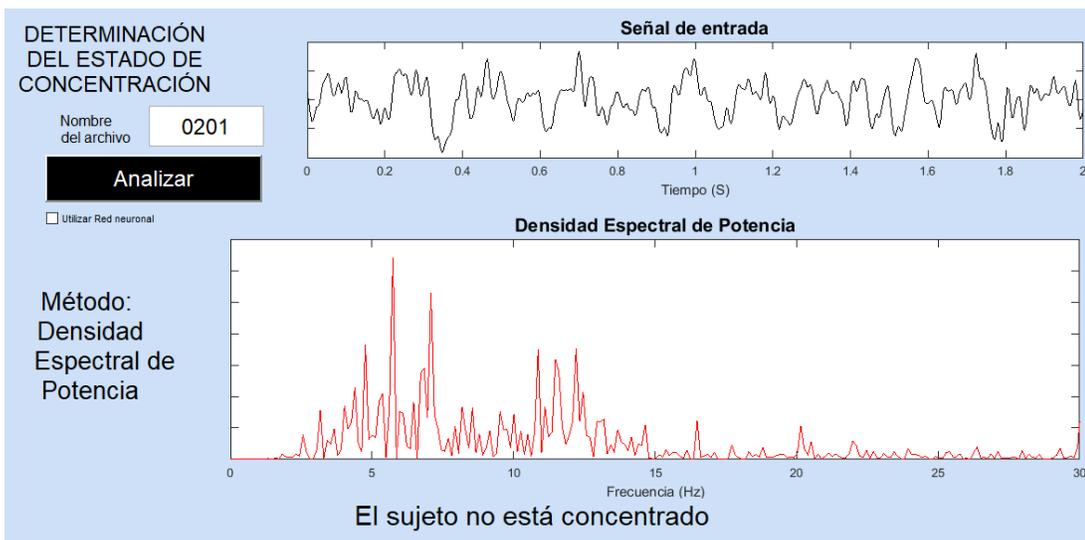
Paciente 1 Método 1.

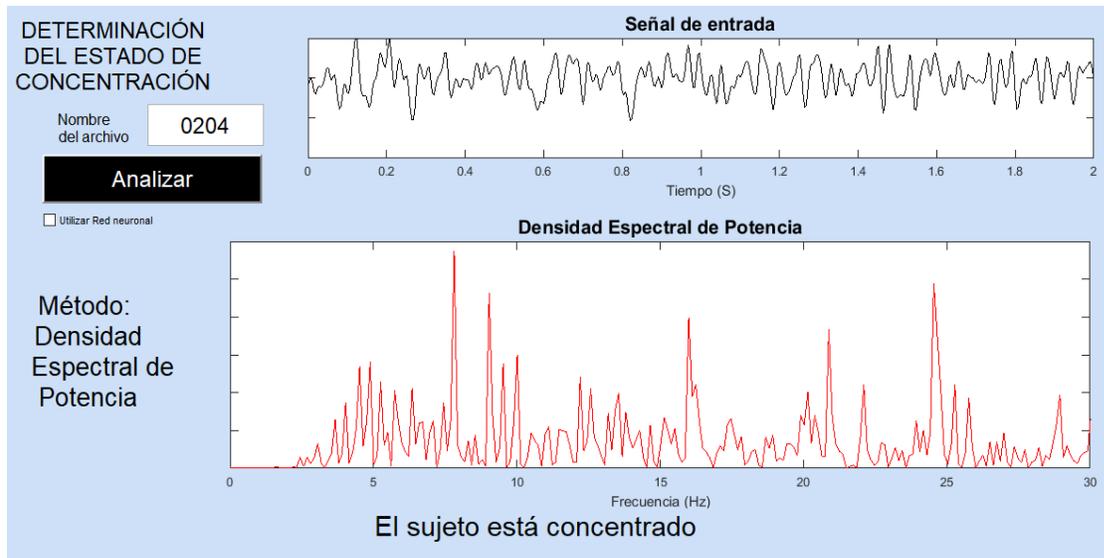
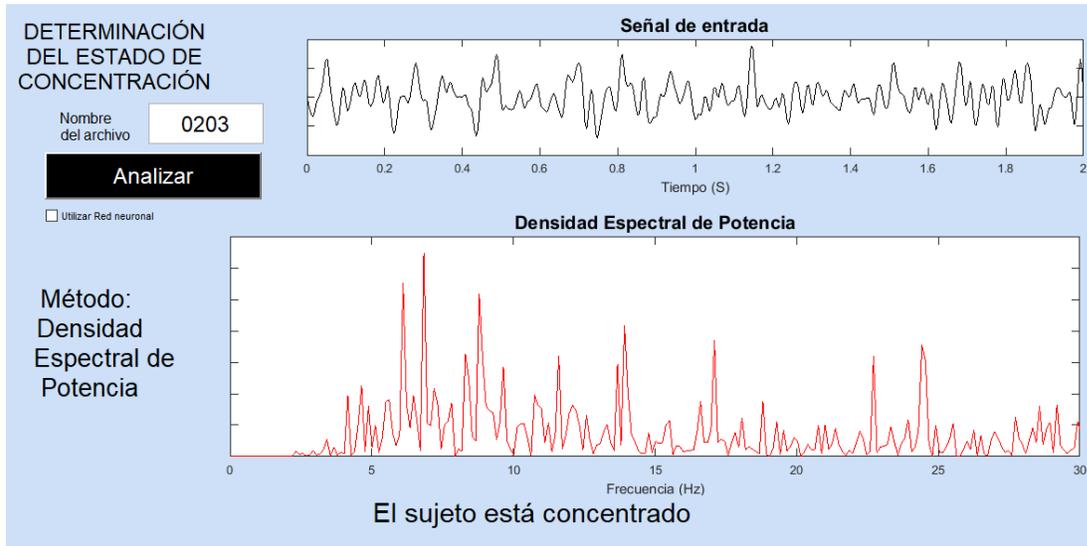






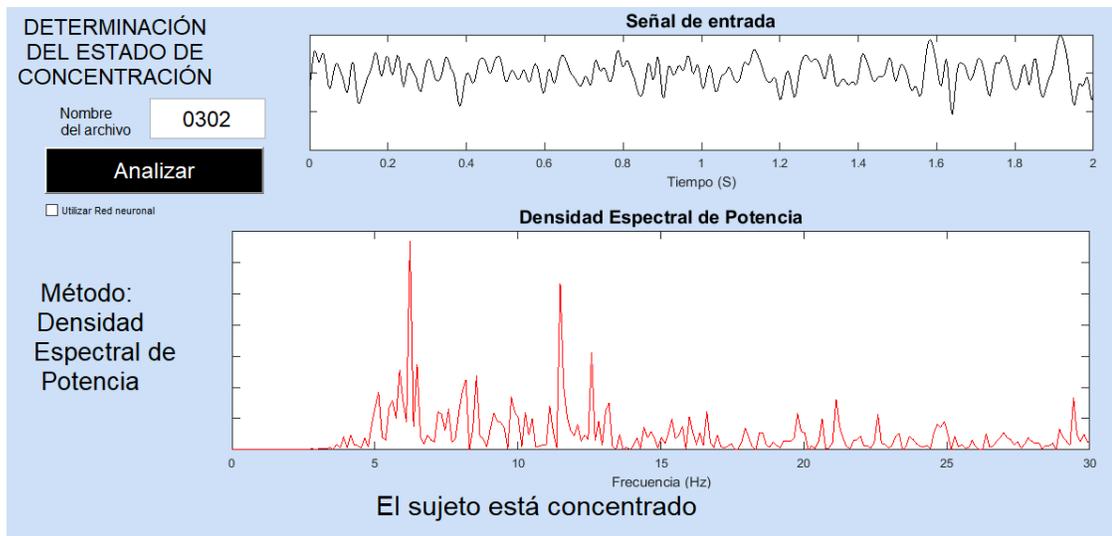
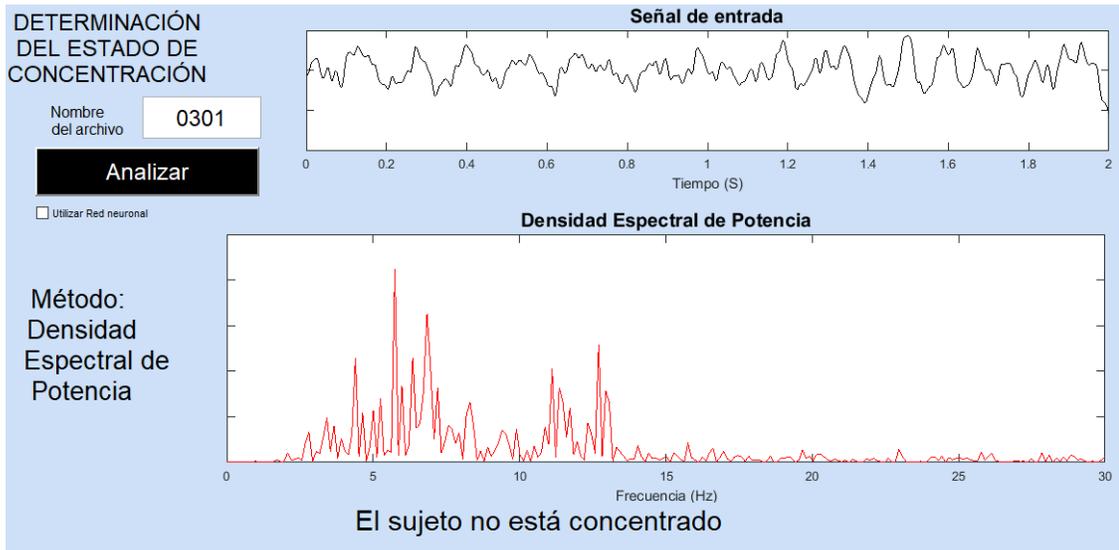
Paciente 2 Método 1.

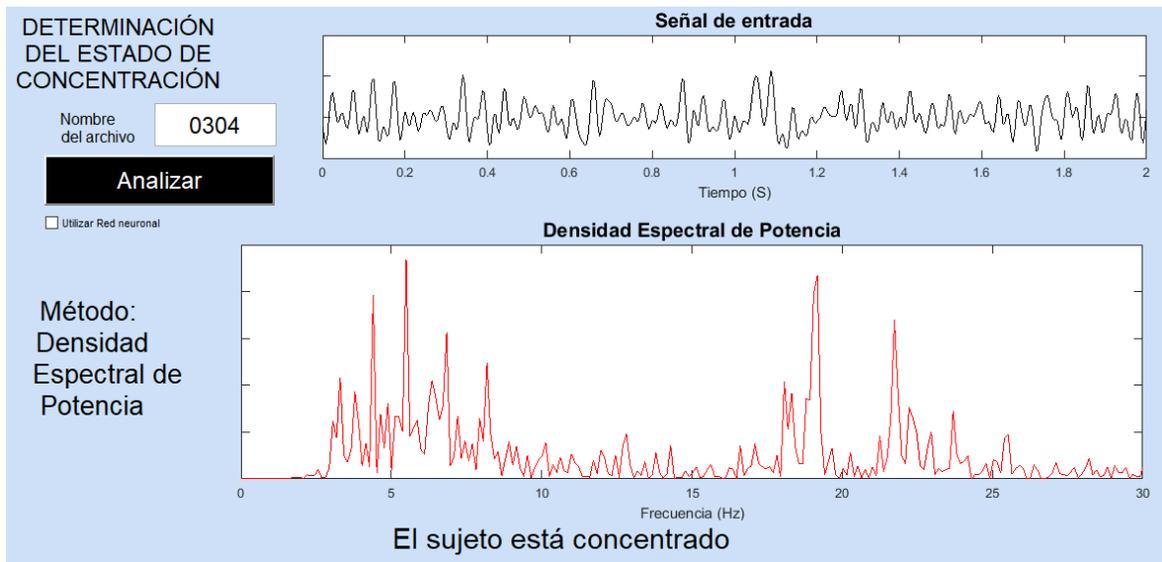
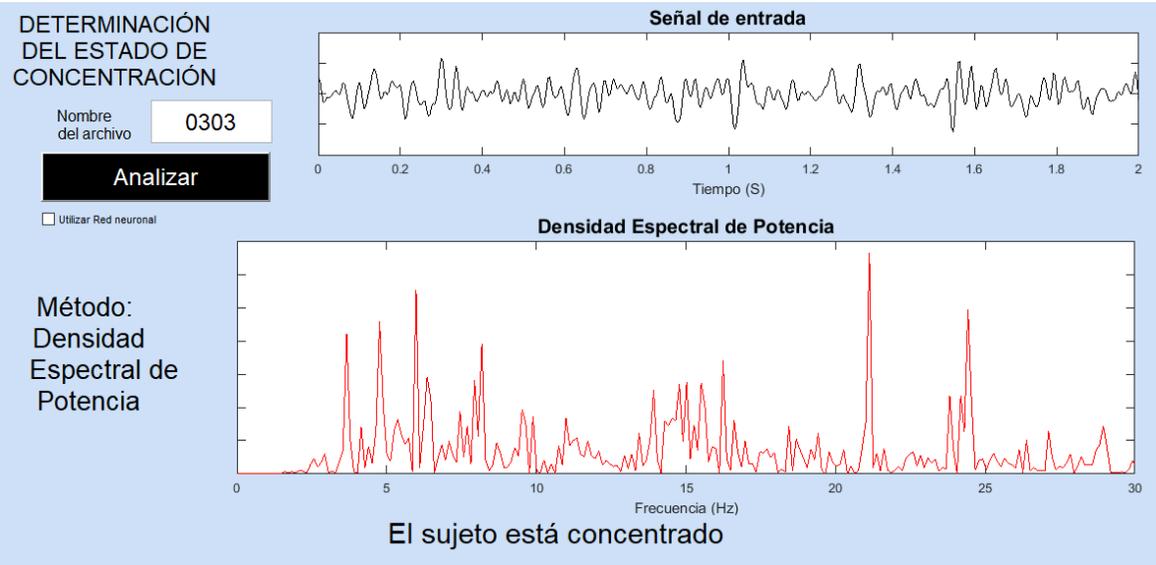






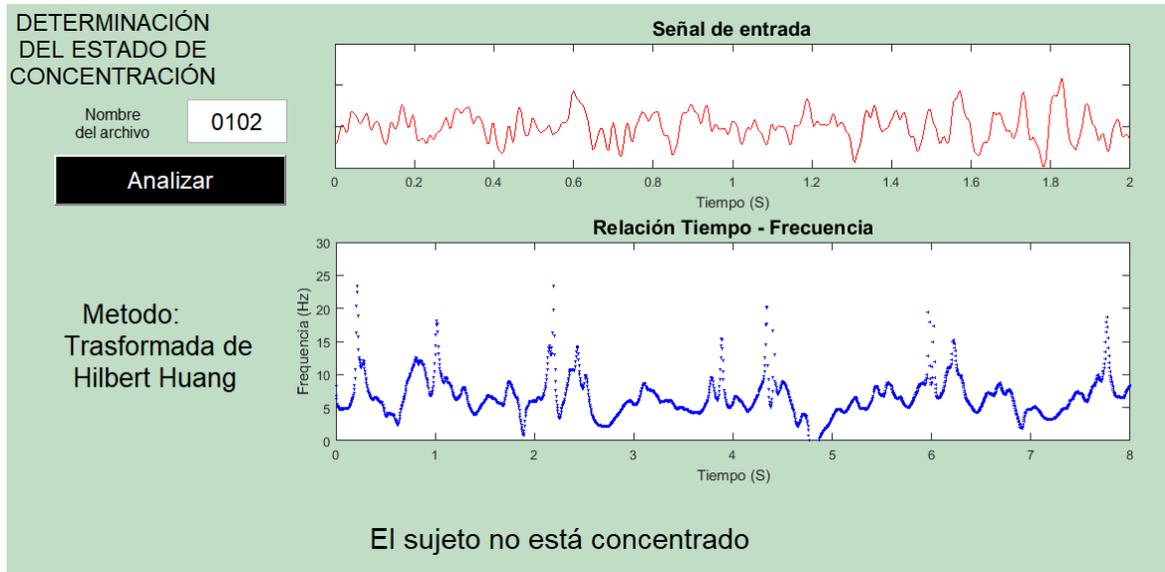
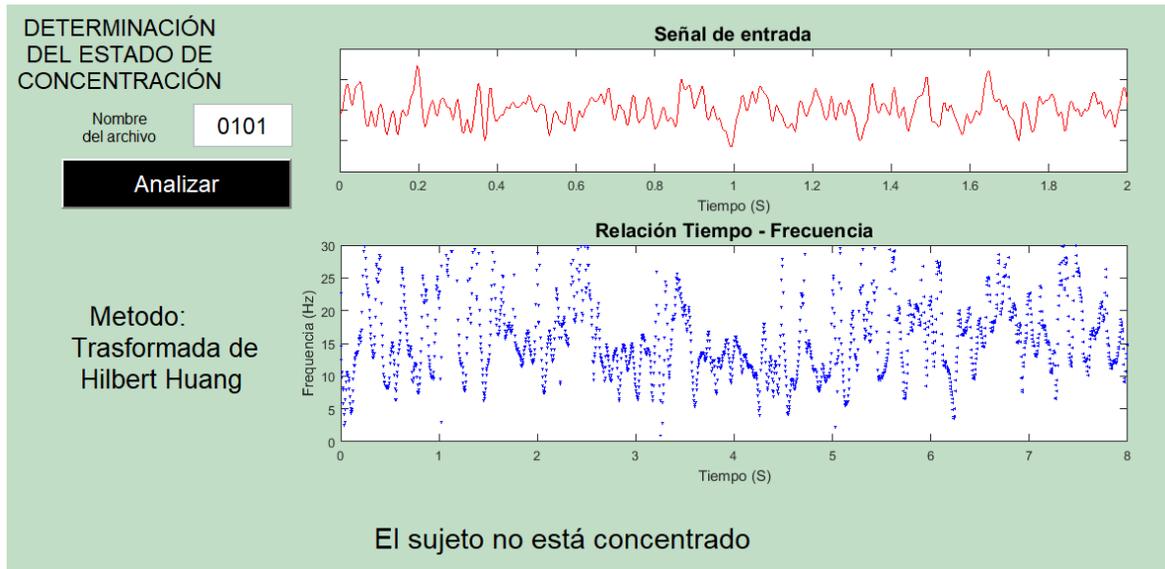
Paciente 3 Método 1.







Paciente 1 Método 2.



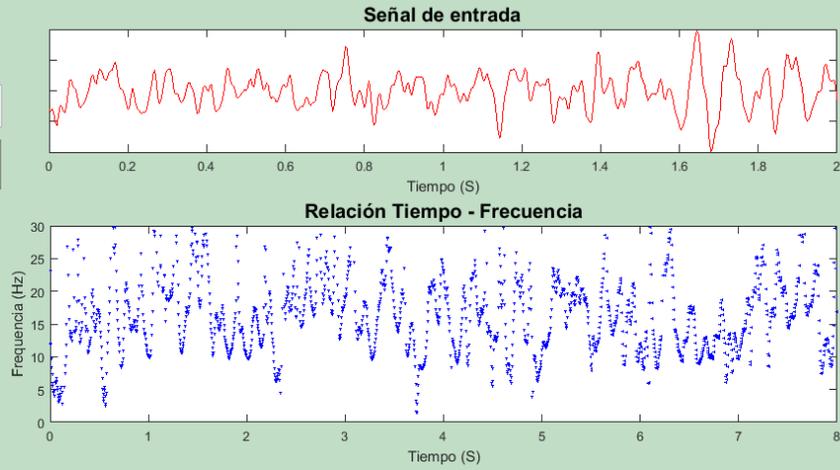


DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombre del archivo 0103

Analizar

Metodo:
Trasformada de Hilbert Huang



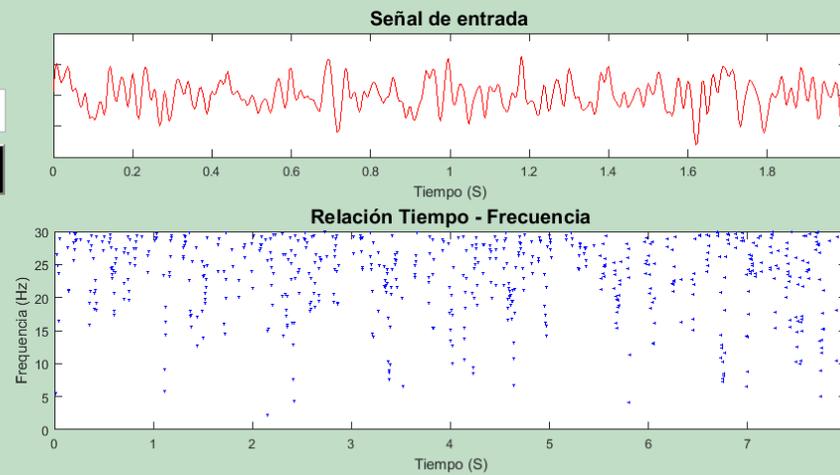
El sujeto está concentrado

DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombre del archivo 0104

Analizar

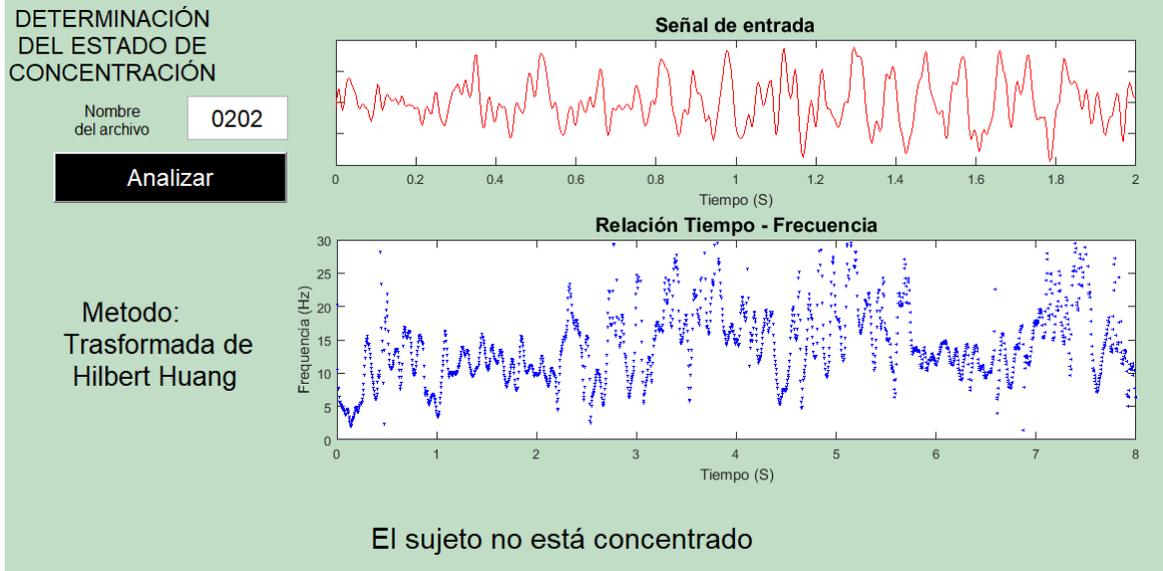
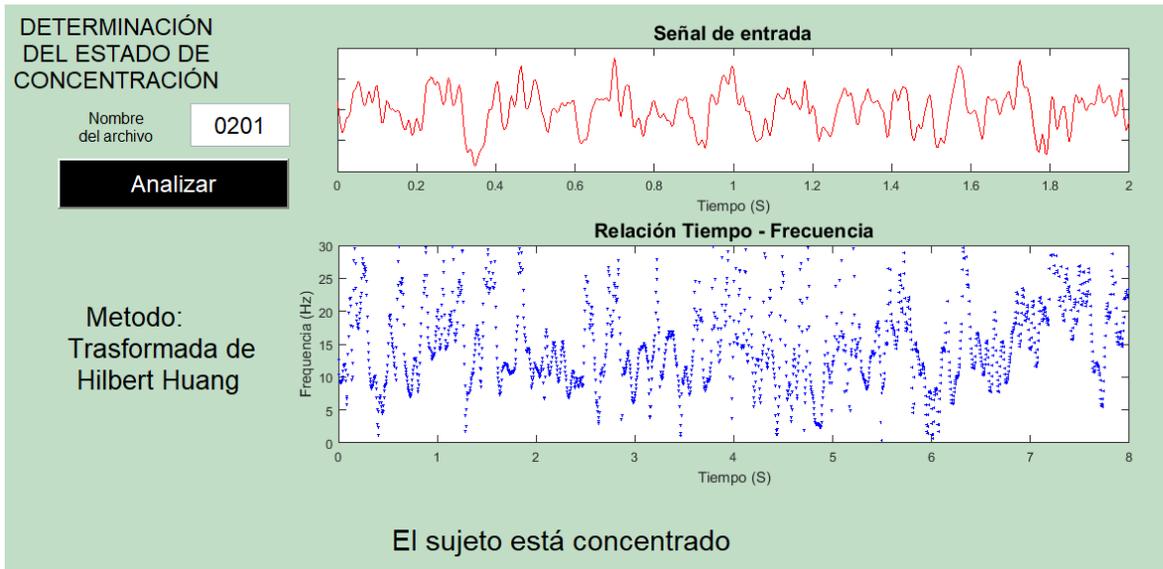
Metodo:
Trasformada de Hilbert Huang

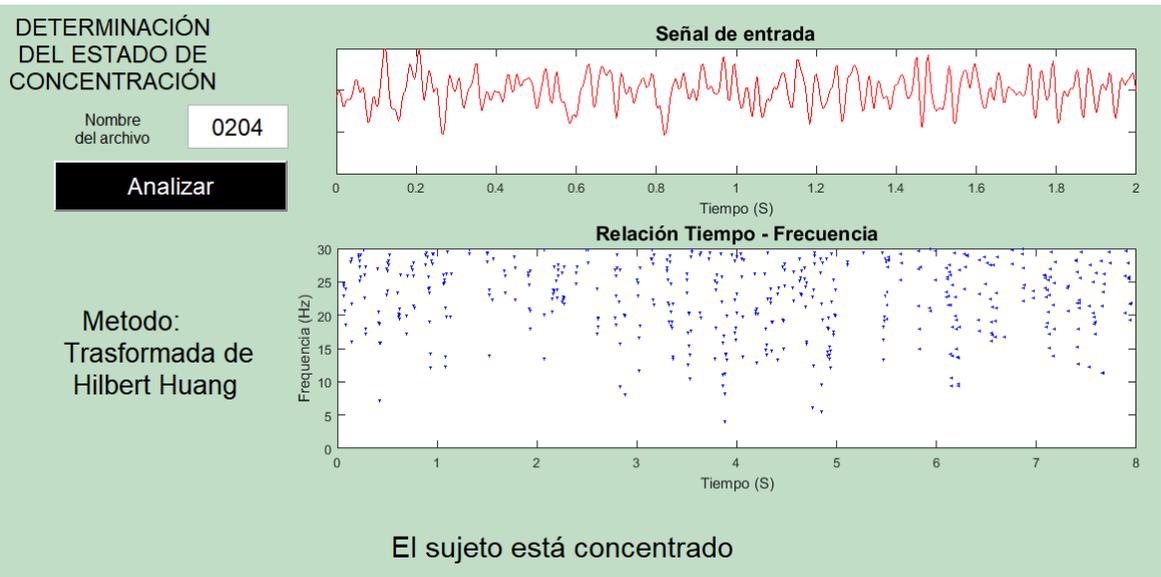
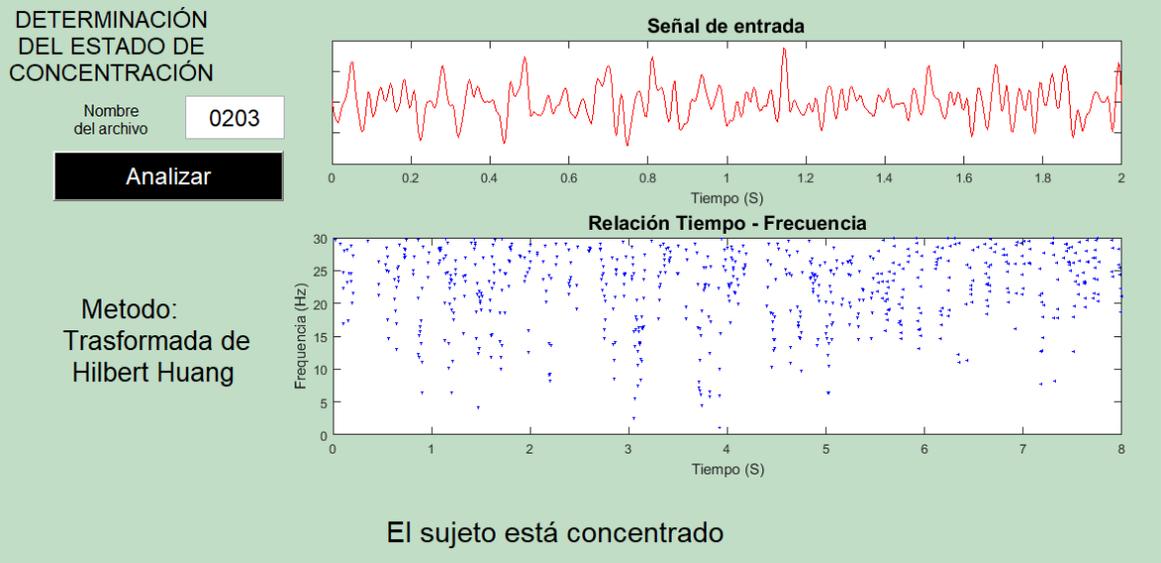


El sujeto está concentrado



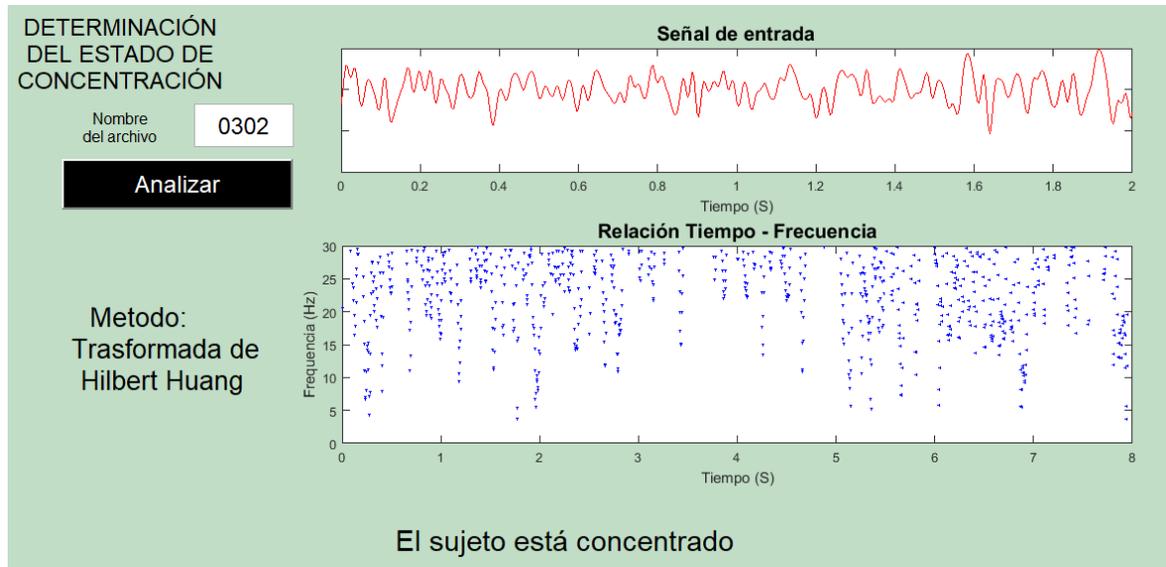
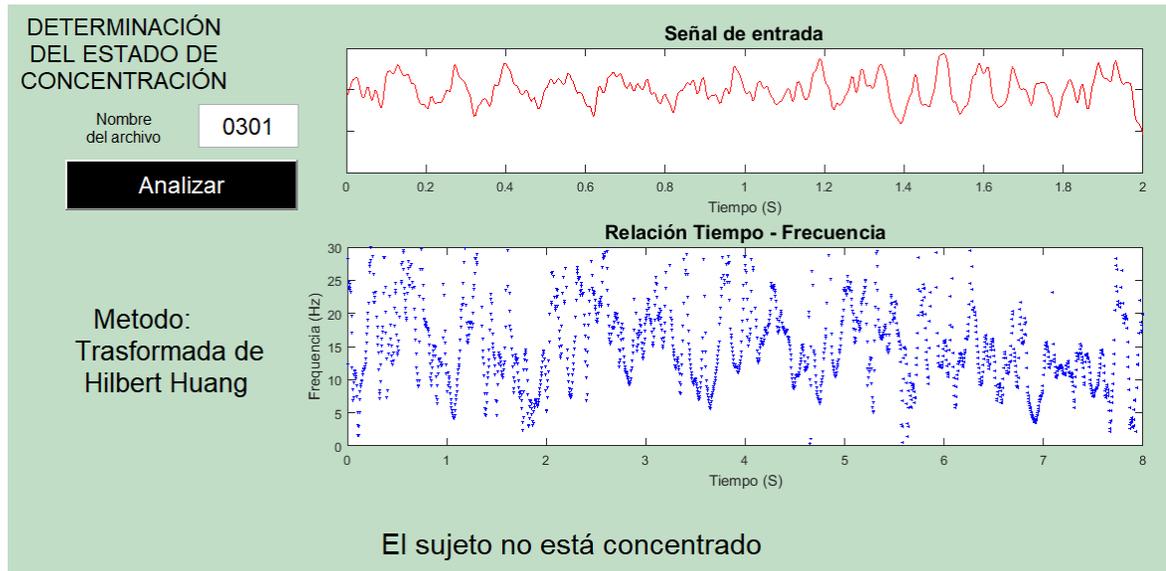
Paciente 2 Método 2.







Paciente 3 Método 2.



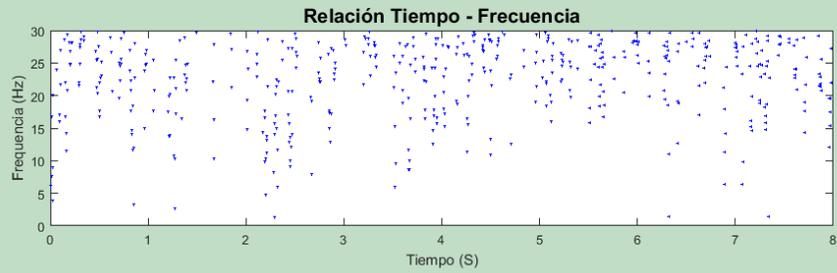
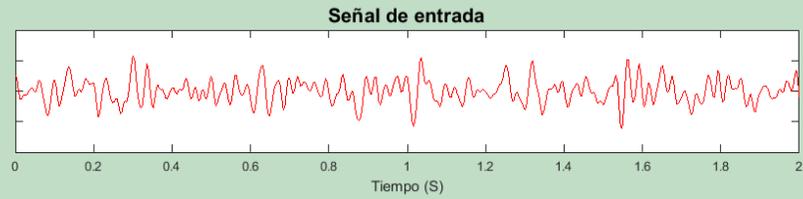


DETERMINACIÓN
DEL ESTADO DE
CONCENTRACIÓN

Nombre
del archivo 0303

Analizar

Metodo:
Trasformada de
Hilbert Huang



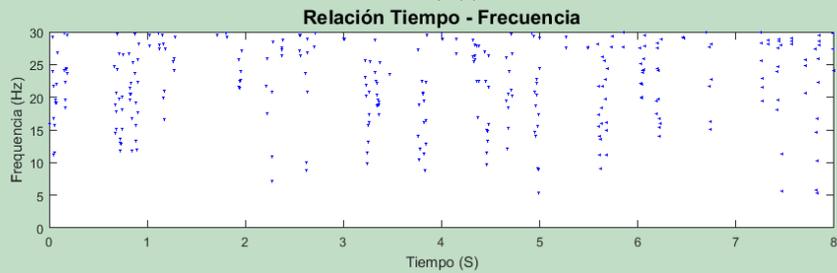
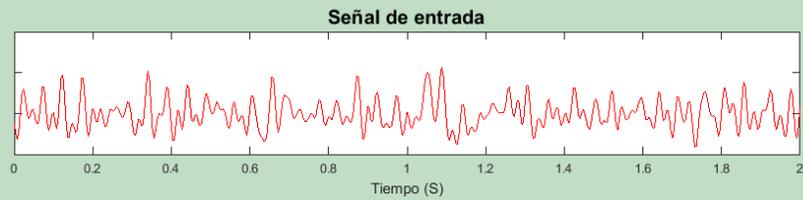
El sujeto está concentrado

DETERMINACIÓN
DEL ESTADO DE
CONCENTRACIÓN

Nombre
del archivo 0304

Analizar

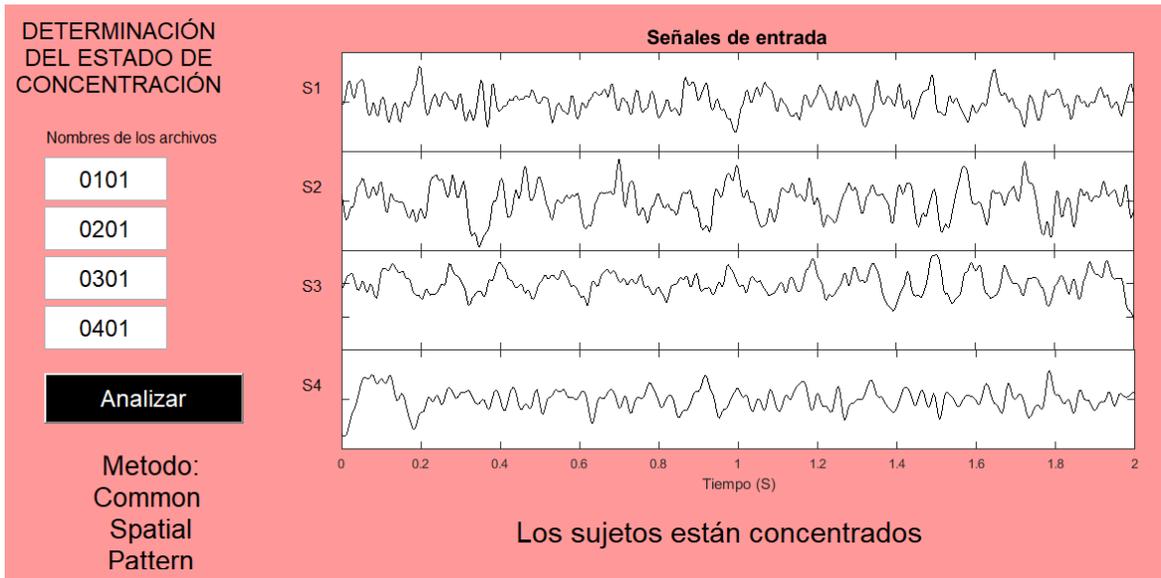
Metodo:
Trasformada de
Hilbert Huang



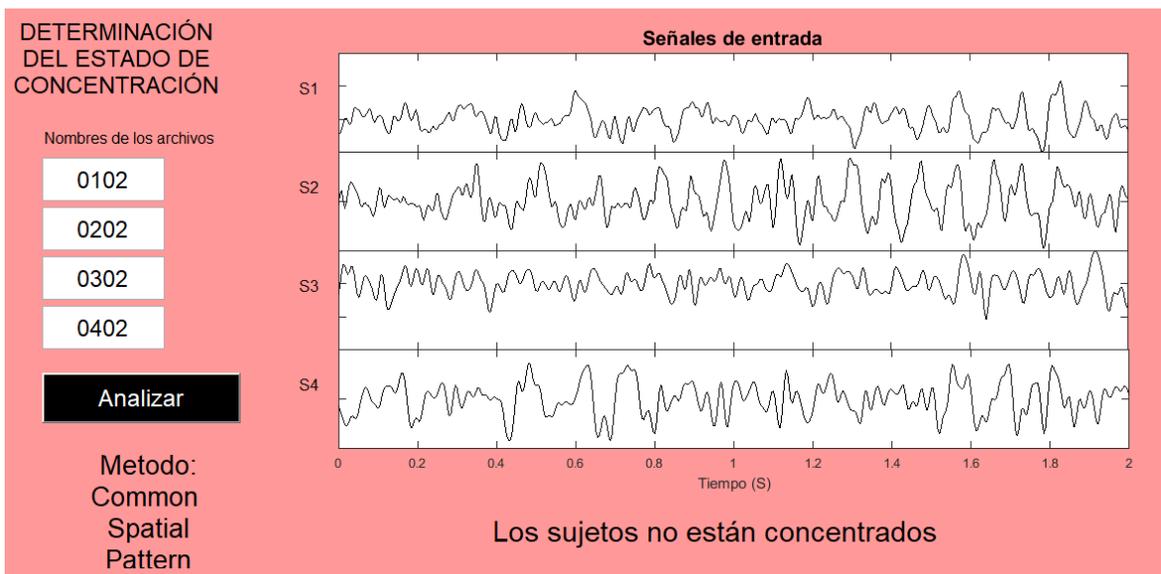
El sujeto está concentrado



Actividad 1 para sujetos 1,2,3,4 Método 3.



Actividad 2 para sujetos 1,2,3,4 Método 3.





Actividad 3 para sujetos 1,2,3,4 Método 3.

DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombres de los archivos

0103

0203

0303

0403

Analizar

Metodo:
Common
Spatial
Pattern

Señales de entrada

Los sujetos están concentrados

Actividad 4 para sujetos 1,2,3,4 Método 3.

DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombres de los archivos

0104

0204

0304

0404

Analizar

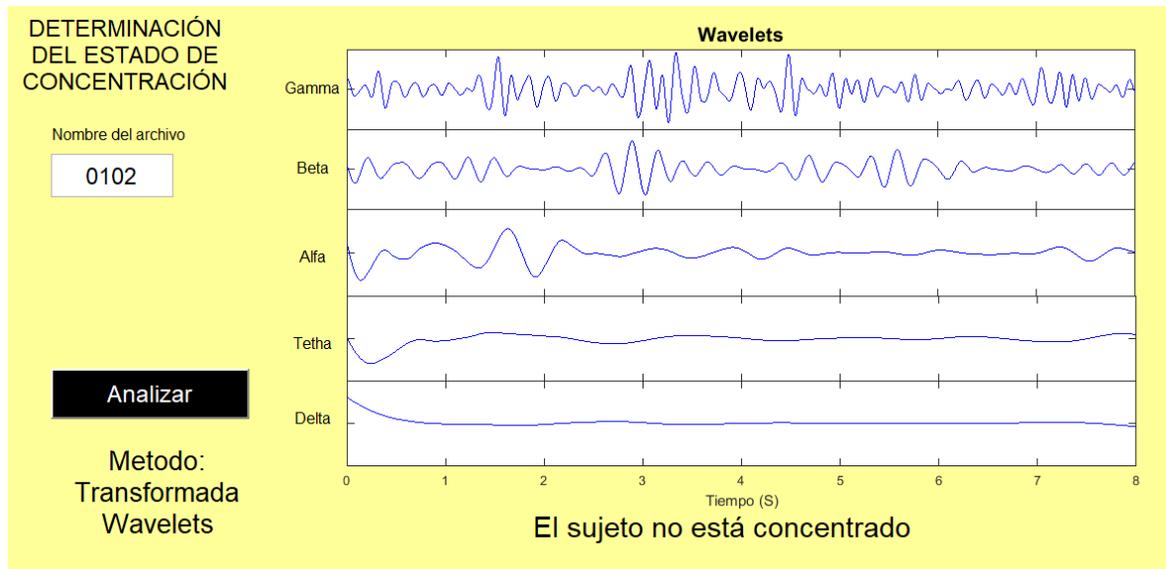
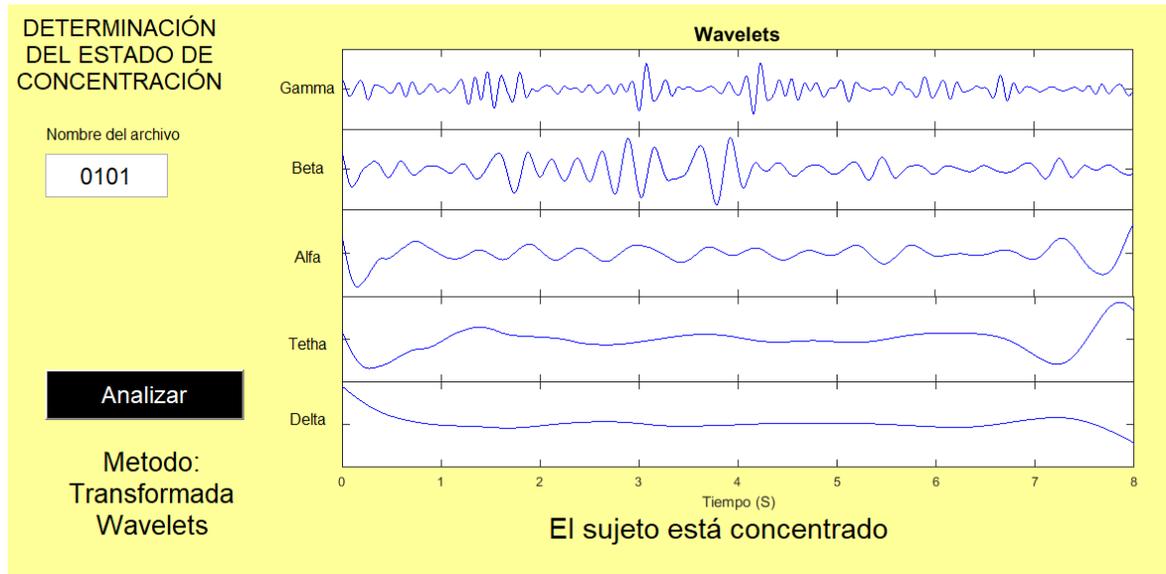
Metodo:
Common
Spatial
Pattern

Señales de entrada

Los sujetos están concentrados



Paciente 1 Método 4.





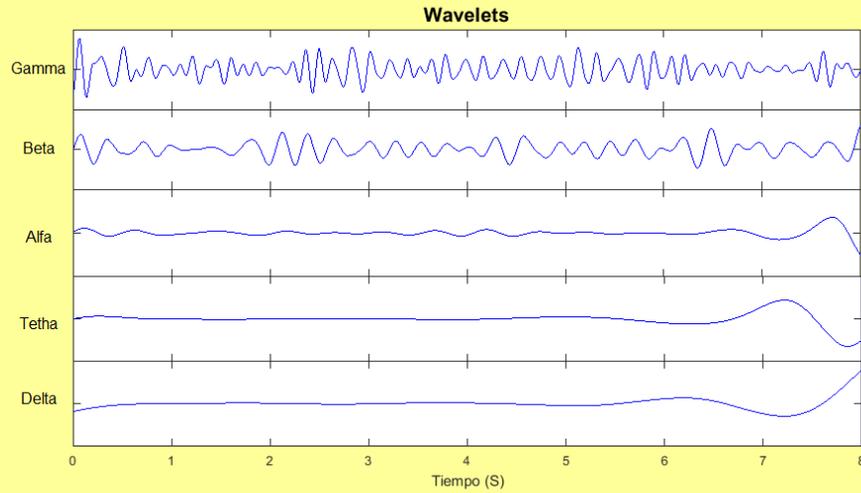
DETERMINACIÓN
DEL ESTADO DE
CONCENTRACIÓN

Nombre del archivo

0103

Analizar

Metodo:
Transformada
Wavelets



El sujeto está concentrado

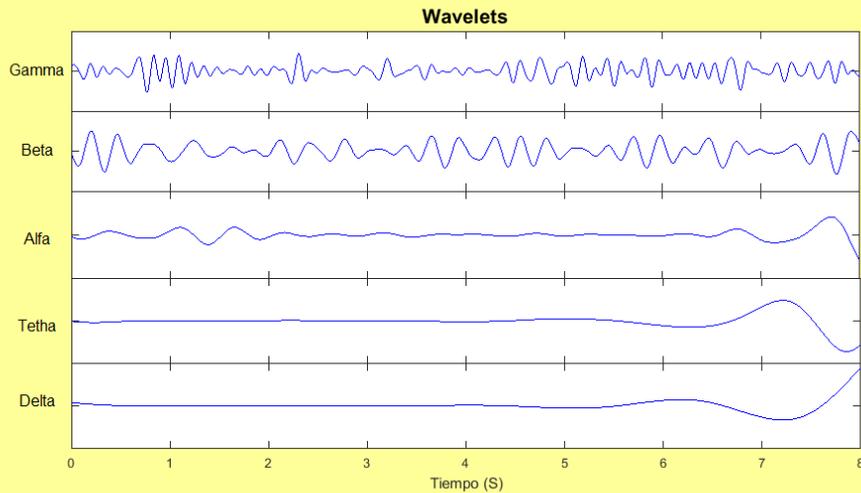
DETERMINACIÓN
DEL ESTADO DE
CONCENTRACIÓN

Nombre del archivo

0104

Analizar

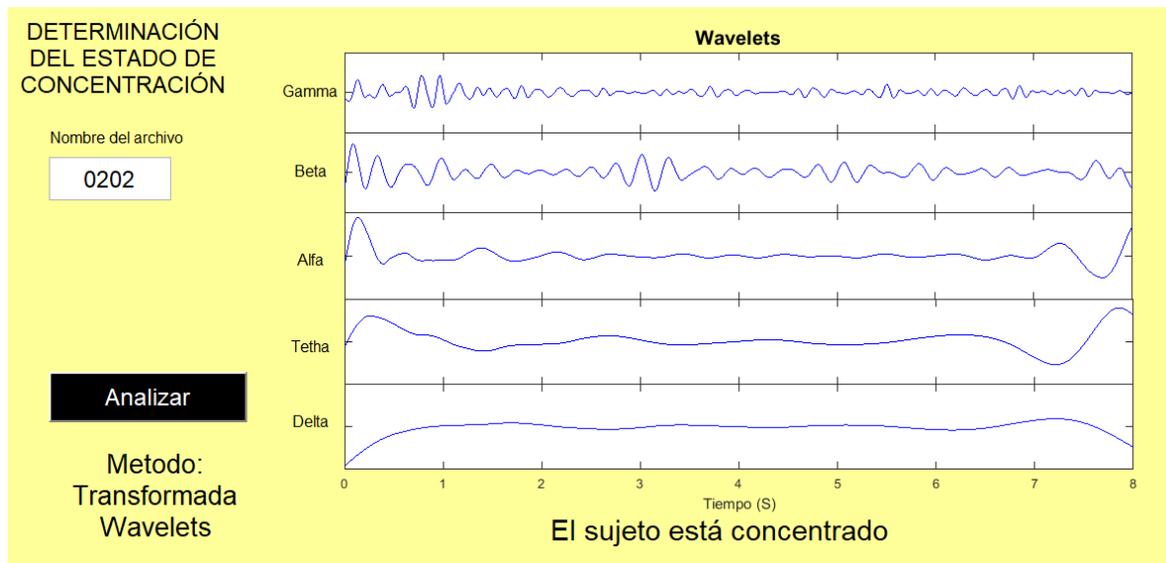
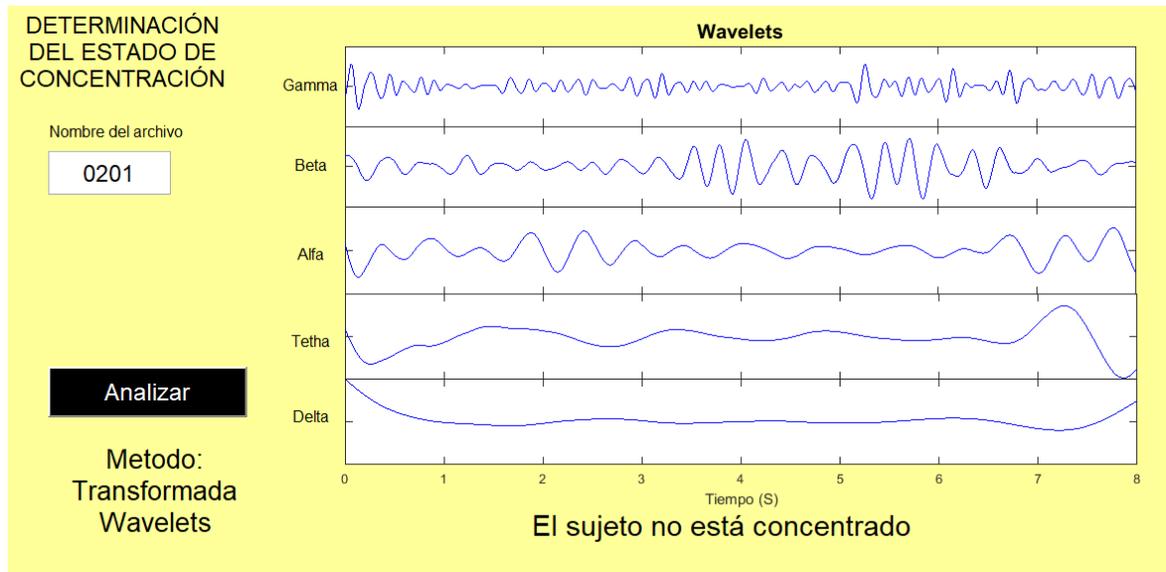
Metodo:
Transformada
Wavelets



El sujeto está concentrado



Paciente 2 Método 4.





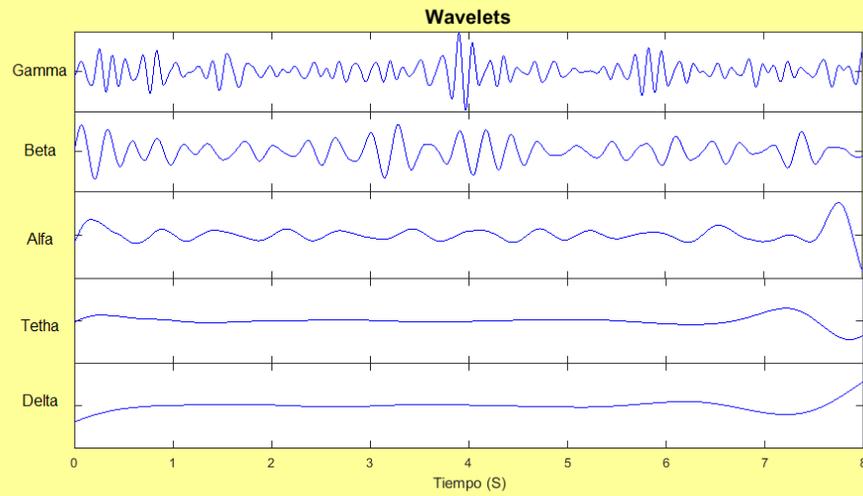
DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombre del archivo

0203

Analizar

Metodo:
Transformada
Wavelets



El sujeto está concentrado

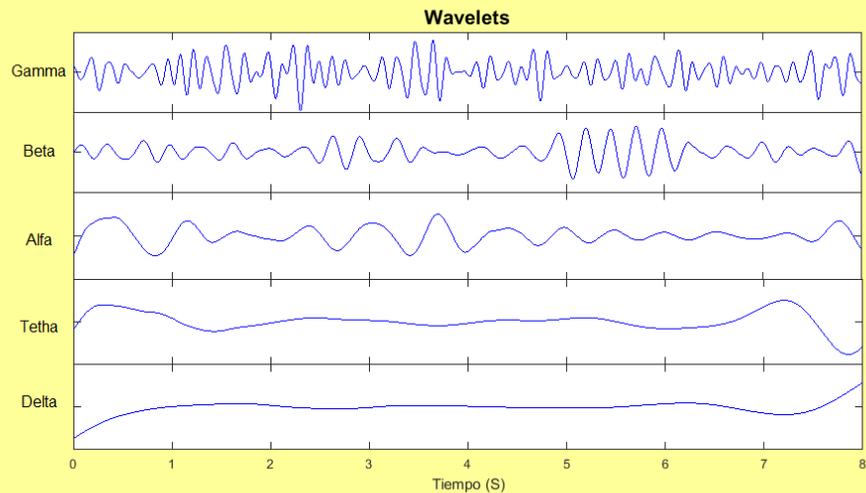
DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombre del archivo

0204

Analizar

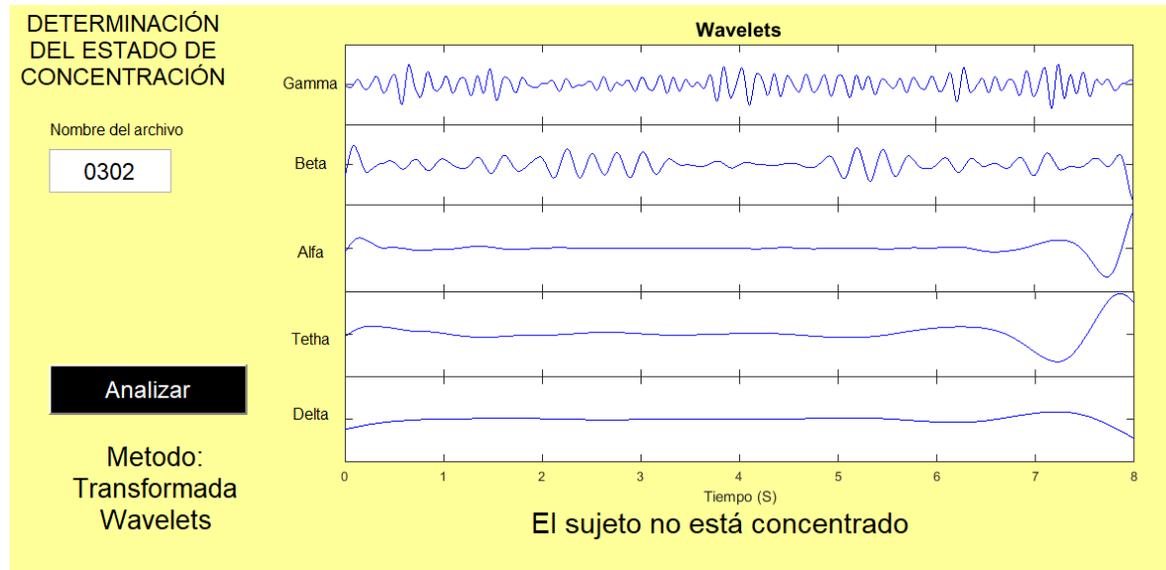
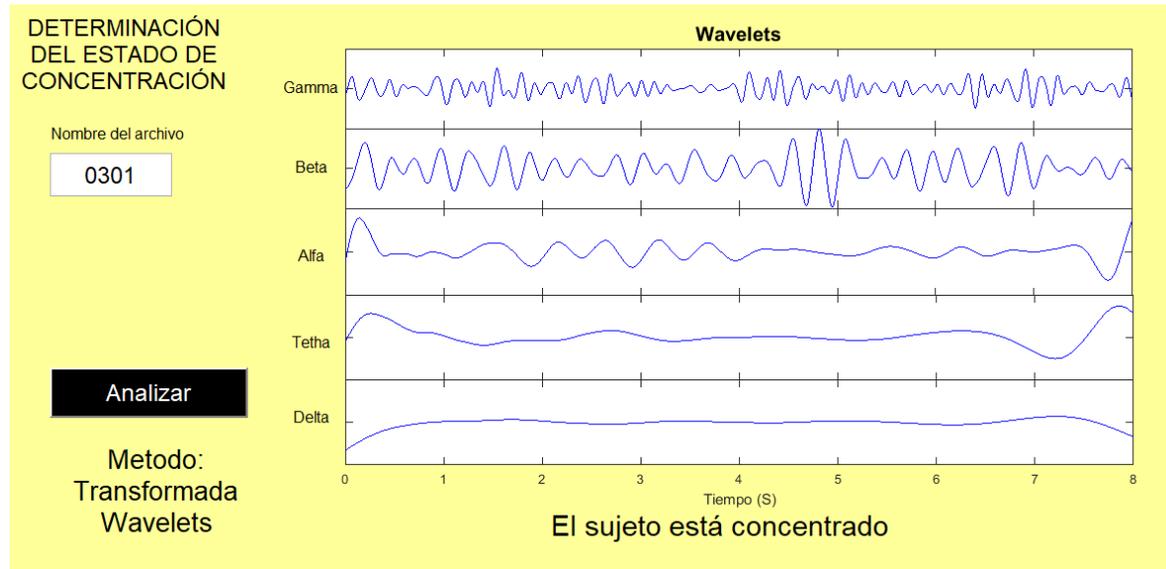
Metodo:
Transformada
Wavelets



El sujeto no está concentrado



Paciente 3 Método 4.





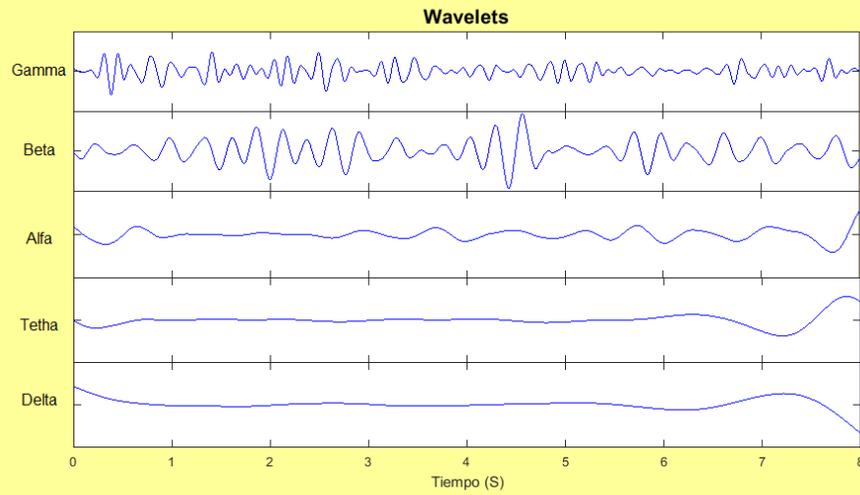
DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombre del archivo

0303

Analizar

Metodo:
Transformada
Wavelets



El sujeto está concentrado

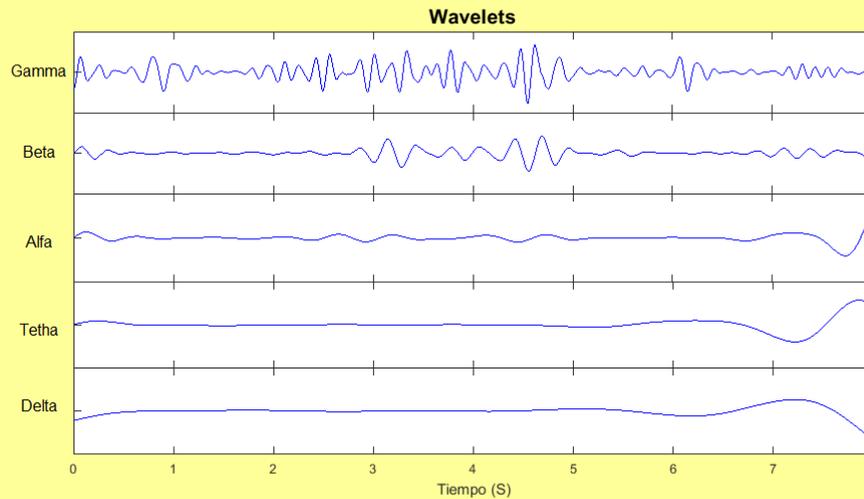
DETERMINACIÓN DEL ESTADO DE CONCENTRACIÓN

Nombre del archivo

0304

Analizar

Metodo:
Transformada
Wavelets



El sujeto está concentrado



Anexo C. Manual básico para instalación y uso de ADS1299EEGFE-PDK

Manual básico para instalación y uso de ADS1299EEGFE-PDK

Para usar la tarjeta ADS1299EEGFE-PDK en un ordenador con sistema operativo Windows 10 deberá ejecutar los controladores instalados. Los siguientes pasos listan el proceso para instalarlos.

Clic en Inicio.



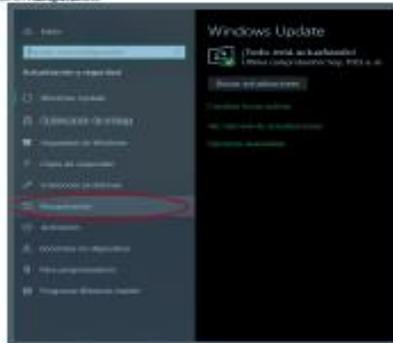
Clic en Configuración.



Clic en Actualización y seguridad.



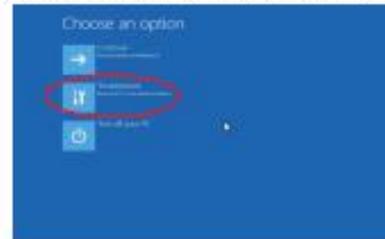
Clic en Recuperación.



Clic en Reiniciar ahora.



Cuando se reinicie el computador y aparezca el menú, seleccione solucionar problemas.



Para una mejor visualización del manual revisar archivo adjunto.



Anexo D. Códigos de MATLAB utilizados en los métodos para determinar estado de concentración.

Código Método 1

```
Fs=250;
Ts=1/Fs;
nombreSinExt=get(handles.edit1,'String');
nombre=strcat(nombreSinExt,'.txt');
Vin=cargaDato(nombre);
% _____ TRANSFORMADA RAPIDA DE
FOURIER _____
%tt=Ts:Ts:length(Vin)*Ts;
tt=0:0.004:2;
VF=fft(Vin);
Vfft=abs(VF);
f=linspace(0,Fs,length(VF));
% _____ DENSIDAD ESPECTRAL DE
POTENCIA _____
PDS=Vfft.*conj(Vfft);
% _____ GRAFICOS _____
axes(handles.axes1);
plot(tt,Vin(1250:1750),'k'),xlabel('Tiempo (S)');
title('\fontsize{15}Señal de entrada'),set(gca,'yticklabel',[]);
axes(handles.axes2);
plot(f,PDS,'r'),xlim([0 30]),xlabel('Frecuencia (Hz)');
title('\fontsize{15}Densidad Espectral de Potencia'),set(gca,
'yticklabel',[]);
red = get(handles.checkbox1,'value');
% _____ CLASIFICACION SEGUN RED
NEURONAL _____
if (red==1)
    load('RedFourier.mat');
    PDSRED=PDS(1:246);
    SalidaRed=sim(Red1,PDSRED);
    if (SalidaRed<0.6)
        resultado=' no ';
    else
        resultado=' ';
    end
% _____ CLASIFICACION SEGUN RELACION
ALFA/BETA _____
else
    alfaIni=fix(length(Vin)*8/Fs);
    alfaFin=fix(length(Vin)*15/Fs);
    betaIni=alfaFin+1;
    betaFin=fix(length(Vin)*30/250)+1;
    alfa=PDS(alfaIni:alfaFin);
    alfaT=sum(alfa);
```



```
beta=PDS(betaIni:betaFin);
betaT=sum(beta);
relacion=alfaT/betaT;
if (relacion>1.23)
    resultado=' no ';
else
    resultado=' ';
end
end
s1='El sujeto';
s2='está concentrado';
textM = [s1 resultado s2];
set(handles.text2,'string',textM);
```

Código Método 2

```
Fs=250;
Ts=1/Fs;
nombreSinExt=get(handles.edit1,'String');
nombre=strcat(nombreSinExt,'.txt');
Vin = cargaDato(nombre);
% _____ SE OBTIENE EL
HHT
imf = emd(Vin);
for k = 1:length(imf)
    b(k) = sum(imf{k}.*imf{k});
    th = angle(hilbert(imf{k}));
    d{k} = diff(th)/Ts/(2*pi);
end
[u,v] = sort(-b);
b = 1-b/max(b);
% _____ RELACION TIEMPO-FRECUENCIA _____
N = length(Vin);
c = linspace(0,(N-2)*Ts,N-1);
k=v(1);
    tt=0:0.004:2;
% _____ GRAFICOS _____
axes(handles.axes1);
plot(tt,Vin(1250:1750),'r'),xlabel('Tiempo (S)');
title('\fontsize{15}Señal de entrada'),set(gca,'yticklabel', []);
axes(handles.axes2);
plot(c,d{k},'b*','MarkerSize',1),ylim([0 30]),xlim([0 8]);
xlabel('Tiempo (S)'),ylabel('Frecuencia (Hz)');
title('\fontsize{15}Relación Tiempo - Frecuencia');
% _____ --CLASIFICACION CON RED
NEURONAL
dk=d{k}.';
dk1=fix(dk);
load('RedN73.mat');
dkRed=dk1(1:500);
SalidaRed=sim(network1,dkRed);
```



```
if (SalidaRed<0.6)
    resultado=' no ';
else
    resultado=' ';
end
s1='El sujeto';
s2='está concentrado';
textM = [s1 resultado s2];
set(handles.text2,'string',textM);
```

Código Método 3

```
N=2048;
K=1;
fs=250;
Ts=1/fs;
% _____ CLASE 1 _____
nombre1='train1.txt';
    xt11=cargaDato(nombre1);
    xt1=xt11.';
nombre2='train2.txt';
    xt22=cargaDato(nombre2);
    xt2=xt22.';
% _____ CLASE 2 _____
nombre4='train3.txt';
    yt11=cargaDato(nombre4);
    yt1=yt11.';
nombre5='train4.txt';
    yt22=cargaDato(nombre5);
    yt2=yt22.';
% _____ ENTRENAMIENTO _____
t=Ts:Ts:length(xt11)*Ts;
Xt=[xt1; xt2];
classt1=Xt;
Yt=[yt1; yt2];
classt2=Yt;
[PTranspose] = CSP(classt1,classt2);
classtrain= horzcat(classt1,classt2);
train = spatFilt(classtrain,PTranspose,2);
N=2048;
K=1;
fs=250;
% _____ ENTRADA DE DATOS _____
nombreSinExt7=get(handles.edit1,'String');
nombre7=strcat(nombreSinExt7,'.txt');
nombreSinExt8=get(handles.edit2,'String');
nombre8=strcat(nombreSinExt8,'.txt');
nombreSinExt10=get(handles.edit3,'String');
nombre10=strcat(nombreSinExt10,'.txt');
nombreSinExt11=get(handles.edit4,'String');
nombre11=strcat(nombreSinExt11,'.txt');
```



```
    xd11=cargaDato(nombre7);
    xd1=xd11.';
    xd22=cargaDato(nombre8);
    xd2=xd22.';
    yd11=cargaDato(nombre10);
    yd1=yd11.';
    yd22=cargaDato(nombre11);
    yd2=yd22.';

%
tft=0:0.004:2;
axes(handles.axes1);
plot(tft,xd11(1250:1750),'k');
title('\fontsize{15}Señales de entrada');
set(gca, 'yticklabel', []),set(gca, 'xticklabel', []);
axes(handles.axes3);
plot(tft,xd22(1250:1750),'k');
set(gca, 'yticklabel', []),set(gca, 'xticklabel', []);
axes(handles.axes4);
plot(tft,yd11(1250:1750),'k');
set(gca, 'yticklabel', []),set(gca, 'xticklabel', []);
axes(handles.axes5);
plot(tft,yd22(1250:1750),'k'),xlabel('Tiempo (S)');
set(gca, 'yticklabel', []);

%
Xd=[xd1; xd2];
classd1=Xd;
Yd=[yd1; yd2];
classd2=Yd;
classtest= horzcat(classd1,classd2);
test = spatFilt(classtest,PTranspose,2);
group = horzcat(ones(1,2048),2*ones(1,2048));
class = classify(test',train',group','diaglinear');
c1=((length(find(class == 1)))*100)/4096;
c2=((length(find(class == 2)))*100)/4096;

if c1 > 50 , c2 < 50;
    resultado= ' no ';
else c1 < 50 , c2 > 50;
    resultado = ' ';

end

s1='Los sujetos';
s2='están concentrados';
textM = [s1 resultado s2];
set(handles.text2,'string',textM);
```

GRAFICOS

CLASIFICACION



Código Método 4

```
nombreSinExt=get(handles.edit1,'String');
nombre=strcat(nombreSinExt, '.txt');
eegdata=cargaDato(nombre);
%-----TRAIN DATA
nombre='train1.txt';
traindata1=cargaDato(nombre);

nombre='train2.txt';
traindata2=cargaDato(nombre);

%load eeg data
s=eegdata;
%-----
s1=traindata1;
s2=traindata2;
%figure;p=plot(s);
%title('EEG Signal')
fs = 250;
Ts=1/fs;
% Sampling frequency
N=length(s);

%Discrete Wavelet decomposition
waveletFunction = 'db8';
[C,L] = wavedec(s,8,waveletFunction); %La estructura de
descomposición de salida %contiene el vector
de descomposición wavelet %C y el vector de
%contabilidad L.
%-----
waveletFunction1 = 'db8';
[C1,L1] = wavedec(s1,8,waveletFunction1);
waveletFunction2 = 'db8';
[C2,L2] = wavedec(s2,8,waveletFunction2);
%-----
cd1 = detcoef(C,L,1);
cd2 = detcoef(C,L,2);
cd3 = detcoef(C,L,3);
cd4 = detcoef(C,L,4);
cd5 = detcoef(C,L,5); %GAMA
cd6 = detcoef(C,L,6); %BETA
cd7 = detcoef(C,L,7); %ALPHA
cd8 = detcoef(C,L,8); %THETA
ca8 = appcoef(C,L,waveletFunction,8); %DELTA

D1 = wrcoef('d',C,L,waveletFunction,1);
```



```
D2 = wrcoef('d',C,L,waveletFunction,2);
D3 = wrcoef('d',C,L,waveletFunction,3);
D4 = wrcoef('d',C,L,waveletFunction,4);
D5 = wrcoef('d',C,L,waveletFunction,5); %GAMMA
D6 = wrcoef('d',C,L,waveletFunction,6); %BETA
D7 = wrcoef('d',C,L,waveletFunction,7); %ALPHA
D8 = wrcoef('d',C,L,waveletFunction,8); %THETA
A8 = wrcoef('a',C,L,waveletFunction,8); %DELTA

%-----
cD11 = detcoef(C1,L1,1);
cD21 = detcoef(C1,L1,2);
cD31 = detcoef(C1,L1,3);
cD41 = detcoef(C1,L1,4);
cD51 = detcoef(C1,L1,5); %GAMA
cD61 = detcoef(C1,L1,6); %BETA
cD71 = detcoef(C1,L1,7); %ALPHA
cD81 = detcoef(C1,L1,8); %THETA
cA81 = appcoef(C1,L1,waveletFunction1,8); %DELTA

D11 = wrcoef('d',C1,L1,waveletFunction1,1);
D21 = wrcoef('d',C1,L1,waveletFunction1,2);
D31 = wrcoef('d',C1,L1,waveletFunction1,3);
D41 = wrcoef('d',C1,L1,waveletFunction1,4);
D51 = wrcoef('d',C1,L1,waveletFunction1,5); %GAMMA
D61 = wrcoef('d',C1,L1,waveletFunction1,6); %BETA
D71 = wrcoef('d',C1,L1,waveletFunction1,7); %ALPHA
D81 = wrcoef('d',C1,L1,waveletFunction1,8); %THETA
A81 = wrcoef('a',C1,L1,waveletFunction1,8); %DELTA

cD12 = detcoef(C2,L2,1);
cD22 = detcoef(C2,L2,2);
cD32 = detcoef(C2,L2,3);
cD42 = detcoef(C2,L2,4);
cD52 = detcoef(C2,L2,5); %GAMA
cD62 = detcoef(C2,L2,6); %BETA
cD72 = detcoef(C2,L2,7); %ALPHA
cD82 = detcoef(C2,L2,8); %THETA
cA82 = appcoef(C2,L2,waveletFunction2,8); %DELTA

D12 = wrcoef('d',C2,L2,waveletFunction2,1);
D22 = wrcoef('d',C2,L2,waveletFunction2,2);
D32 = wrcoef('d',C2,L2,waveletFunction2,3);
D42 = wrcoef('d',C2,L2,waveletFunction2,4);
D52 = wrcoef('d',C2,L2,waveletFunction2,5); %GAMMA
D62 = wrcoef('d',C2,L2,waveletFunction2,6); %BETA
D72 = wrcoef('d',C2,L2,waveletFunction2,7); %ALPHA
D82 = wrcoef('d',C2,L2,waveletFunction2,8); %THETA
A82 = wrcoef('a',C2,L2,waveletFunction2,8); %DELTA

%-----
GRAFICOS
```



```
tts=Ts:Ts:Ts*length(eegdata);
axes(handles.axes1);
    Gamma = D5;
    plot(tts, Gamma, 'b'), xlim([0 8]);
    title('\fontsize{15}Wavelets');
    set(gca, 'yticklabel', [], set(gca, 'xticklabel', []);
axes(handles.axes3);
    Beta = D6;
    plot(tts, Beta, 'b'), xlim([0 8]);
    set(gca, 'yticklabel', [], set(gca, 'xticklabel', []);
axes(handles.axes4);
    Alpha = D7;
    plot(tts, Alpha, 'b'), xlim([0 8]);
    set(gca, 'yticklabel', [], set(gca, 'xticklabel', []);
axes(handles.axes5);
    Theta = D8;
    plot(tts, Theta, 'b'), xlim([0 8]);
    set(gca, 'yticklabel', [], set(gca, 'xticklabel', []);
    D8 = detrend(D8, 0);
axes(handles.axes6);
    Delta = A8;
    %figure, plot(0:1/fs:1, Delta);
    plot(tts, Delta, 'b'), xlim([0 8]);
    xlabel('Tiempo (S)'), set(gca, 'yticklabel', []);
%-----
%-----
    Gamma1 = D51;
    Beta1 = D61;
    Alpha1 = D71;
    Theta1 = D81;
    D81 = detrend(D81, 0);
    Delta1 = A81;

    Gamma2 = D52;
    Beta2 = D62;
    Alpha2 = D72;
    Theta2 = D82;
    D82 = detrend(D82, 0);
    Delta2 = A82;

%-----
----

D5 = detrend(D5, 0);
xdft1 = fft(D5);
D5power=bandpower(Delta);

freq1 = 0:N/length(D5):N/2;
xdft1 = xdft1(1:length(D5)/2+1);
```



```
%figure;subplot(511);plot(freq1,abs(xdft1),'r');title('GAMMA-  
FREQUENCY');  
[~,I] = max(abs(xdft1));  
%fprintf('Gamma:Maximum occurs at %3.2f Hz.\n',freq1(I));  
  
D6 = detrend(D6,0);  
xdft2 = fft(D6);  
freq2 = 0:N/length(D6):N/2;  
xdft2 = xdft2(1:length(D6)/2+1);  
% figure;  
%subplot(512);plot(freq2,abs(xdft2));title('BETA');  
[~,I] = max(abs(xdft2));  
%fprintf('Beta:Maximum occurs at %3.2f Hz.\n',freq2(I));  
  
D7 = detrend(D7,0);  
xdft3 = fft(D7);  
freq3 = 0:N/length(D7):N/2;  
xdft3 = xdft3(1:length(D7)/2+1);  
% figure;  
%subplot(513);plot(freq3,abs(xdft3));title('ALPHA');  
[~,I] = max(abs(xdft3));  
%fprintf('Alpha:Maximum occurs at %f Hz.\n',freq3(I));  
  
    xdft4 = fft(D8);  
freq4 = 0:N/length(D8):N/2;  
xdft4 = xdft4(1:length(D8)/2+1);  
% figure;  
%subplot(514);plot(freq4,abs(xdft4));title('THETA');  
[~,I] = max(abs(xdft4));  
%fprintf('Theta:Maximum occurs at %f Hz.\n',freq4(I));  
  
A8 = detrend(A8,0);  
xdft5 = fft(A8);  
freq5 = 0:N/length(A8):N/2;  
xdft5 = xdft5(1:length(A8)/2+1);  
  
D5fpower=bandpower(xdft5);  
% figure;  
%subplot(515);plot(freq3,abs(xdft5));title('DELTA');  
[~,I] = max(abs(xdft5));  
%fprintf('Delta:Maximum occurs at %f Hz.\n',freq5(I));  
%-----  
  
%-----Train SVM  
training1=horzcat(D61,D71,D8);  
training2=horzcat(D62,D72,D8);  
training=vertcat(training1,training2);  
Asistencia de investigación. Ingeniería Electrónica, 2019
```



```
group=horzcat(ones(1,2048),2*ones(1,2048)).';  
  
SVMModel=fitcsvm(training,group,'KernelFunction','rbf');  
  
%-----New Data classification  
newX=horzcat(D6,D7,D8);  
vclas= predict(SVMModel,newX);  
  
c1=((length(find(vclas == 1)))*89)/2048;  
c2=((length(find(vclas == 2)))*114)/2048;  
  
if c1 > c2;  
    resultado= ' no ';  
else  
    resultado = ' ';  
  
end  
  
s1='El sujeto';  
s2='está concentrado';  
textM = [s1 resultado s2];  
set(handles.text2,'string',textM);
```



Anexo E. Tabla resultados de clasificación de estado de concentración con cada algoritmo para base de datos obtenida con AFE.

Los primeros 2 dígitos del nombre de la señal corresponden al paciente (de 01 a 30) y los últimos 2 hacen referencia a las actividades realizadas, siendo 01 y 02 durante estados de relajación y 03 y 04 durante estados de concentración.

BASE DE DATOS CON AFE					
Señal	DSP		HHT	CSP	DWT
	Sin red neuronal	Con red neuronal			
.0101	No concentrado	No concentrado	No concentrado	Concentrado	Concentrado
.0102	No concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.0103	No concentrado	No concentrado	Concentrado	Concentrado	Concentrado
.0104	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.0201	No concentrado	No concentrado	Concentrado	Concentrado	No concentrado
.0202	No concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.0203	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.0204	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.0301	No concentrado	No concentrado	No concentrado	Concentrado	Concentrado
.0302	Concentrado	No concentrado	Concentrado	No concentrado	No concentrado
.0303	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.0304	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.0401	No concentrado	No concentrado	No concentrado	Concentrado	No concentrado
.0402	No concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.0403	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.0404	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.0501	Concentrado	No concentrado	Concentrado	No concentrado	No concentrado
.0502	No concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.0503	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.0504	Concentrado	No concentrado	Concentrado	Concentrado	No concentrado
.0601	Concentrado	No concentrado	Concentrado	No concentrado	No concentrado
.0602	Concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.0603	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.0604	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.0701	Concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.0702	No concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.0703	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado



.0704	Concentrado	No concentrado	Concentrado	Concentrado	No concentrado
.0801	Concentrado	Concentrado	Concentrado	No concentrado	No concentrado
.0802	Concentrado	Concentrado	No concentrado	No concentrado	No concentrado
.0803	Concentrado	Concentrado	No concentrado	Concentrado	No concentrado
.0804	Concentrado	Concentrado	No concentrado	Concentrado	No concentrado
.0901	Concentrado	Concentrado	No concentrado	No concentrado	No concentrado
.0902	No concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.0903	Concentrado	Concentrado	No concentrado	No concentrado	Concentrado
.0904	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.1001	No concentrado				
.1002	No concentrado				
.1003	Concentrado	Concentrado	No concentrado	No concentrado	Concentrado
.1004	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.1101	Concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.1102	No concentrado				
.1103	Concentrado	Concentrado	Concentrado	No concentrado	Concentrado
.1104	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.1201	No concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.1202	Concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.1203	Concentrado	Concentrado	Concentrado	No concentrado	Concentrado
.1204	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.1301	No concentrado	No concentrado	Concentrado	No concentrado	Concentrado
.1302	No concentrado	No concentrado	Concentrado	No concentrado	Concentrado
.1303	Concentrado	No concentrado	Concentrado	Concentrado	Concentrado
.1304	Concentrado	No concentrado	Concentrado	Concentrado	No concentrado
.1401	No concentrado				
.1402	No concentrado				
.1403	Concentrado	No concentrado	Concentrado	Concentrado	No concentrado
.1404	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.1501	No concentrado	No concentrado	Concentrado	No concentrado	No concentrado
.1502	No concentrado				
.1503	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.1504	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.1601	No concentrado				
.1602	No concentrado				
.1603	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado



.1604	Concentrado	No concentrado	Concentrado	Concentrado	No concentrado
.1701	Concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.1702	Concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.1703	Concentrado	No concentrado	Concentrado	Concentrado	Concentrado
.1704	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.1801	No concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.1802	No concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.1803	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.1804	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.1901	No concentrado				
.1902	No concentrado				
.1903	No concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.1904	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.2001	No concentrado				
.2002	No concentrado				
.2003	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.2004	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.2101	No concentrado	No concentrado	No concentrado	Concentrado	No concentrado
.2102	No concentrado	No concentrado	No concentrado	Concentrado	No concentrado
.2103	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.2104	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.2201	No concentrado	No concentrado	No concentrado	Concentrado	Concentrado
.2202	No concentrado	No concentrado	No concentrado	Concentrado	Concentrado
.2203	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.2204	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.2301	No concentrado	No concentrado	No concentrado	Concentrado	No concentrado
.2302	No concentrado	No concentrado	No concentrado	Concentrado	No concentrado
.2303	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.2304	Concentrado	Concentrado	No concentrado	Concentrado	No concentrado
.2401	No concentrado	No concentrado	No concentrado	Concentrado	No concentrado
.2402	No concentrado	No concentrado	No concentrado	Concentrado	No concentrado
.2403	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.2404	Concentrado	Concentrado	No concentrado	Concentrado	No concentrado
.2501	No concentrado				
.2502	No concentrado				
.2503	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado



.2504	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.2601	No concentrado				
.2602	Concentrado	No concentrado	No concentrado	No concentrado	No concentrado
.2603	Concentrado	Concentrado	No concentrado	Concentrado	Concentrado
.2604	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.2701	No concentrado	Concentrado	No concentrado	No concentrado	No concentrado
.2702	No concentrado				
.2703	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.2704	No concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.2801	No concentrado				
.2802	Concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.2803	Concentrado	No concentrado	Concentrado	Concentrado	No concentrado
.2804	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.2901	No concentrado	No concentrado	No concentrado	No concentrado	Concentrado
.2902	No concentrado				
.2903	Concentrado	Concentrado	No concentrado	Concentrado	No concentrado
.2904	Concentrado	Concentrado	Concentrado	Concentrado	Concentrado
.3001	No concentrado				
.3002	No concentrado				
.3003	Concentrado	Concentrado	Concentrado	Concentrado	No concentrado
.3004	Concentrado	No concentrado	Concentrado	Concentrado	Concentrado



Anexo F. Tabla resultados de pruebas con base de datos de PhysioNet y base de datos de Powerlab.

El primer dígito corresponde al paciente (del 1 al 4) y los últimos 2 hacen referencia a las actividades realizadas, siendo del 01 al 06 durante estados de relajación y del 07 y 12 durante estados de concentración.

BASE DE DATOS POWERLAB			
Señal	Estado	Señal	Estado
p101	No concentrado	p301	No concentrado
p102	No concentrado	p302	No concentrado
p103	No concentrado	p303	No concentrado
p104	Concentrado	p304	Concentrado
p105	No concentrado	p305	Concentrado
p106	Concentrado	p306	Concentrado
p107	Concentrado	p307	Concentrado
p108	No concentrado	p308	No concentrado
p109	Concentrado	p309	Concentrado
p110	Concentrado	p310	Concentrado
p111	Concentrado	p311	Concentrado
p112	Concentrado	p312	No concentrado
p201	Concentrado	p401	No concentrado
p202	No concentrado	p402	Concentrado
p203	No concentrado	p403	No concentrado
p204	Concentrado	p404	No concentrado
p205	No concentrado	p405	Concentrado
p206	No concentrado	p406	No concentrado
p207	Concentrado	p407	Concentrado
p208	Concentrado	p408	Concentrado
p209	Concentrado	p409	Concentrado
p210	Concentrado	p410	Concentrado
p211	Concentrado	p411	Concentrado
p212	Concentrado	p412	Concentrado



BASE DE DATOS PHYSIONET			
Señal	Estado	Señal	Estado
Subject00	Concentrado	Subject18	Concentrado
Subject01	No concentrado	Subject19	Concentrado
Subject02	Concentrado	Subject20	Concentrado
Subject03	Concentrado	Subject21	Concentrado
Subject04	Concentrado	Subject22	Concentrado
Subject05	Concentrado	Subject23	Concentrado
Subject06	Concentrado	Subject24	Concentrado
Subject07	No concentrado	Subject25	No concentrado
Subject08	Concentrado	Subject26	Concentrado
Subject09	Concentrado	Subject27	Concentrado
Subject10	Concentrado	Subject28	Concentrado
Subject11	No concentrado	Subject29	Concentrado
Subject12	Concentrado	Subject30	Concentrado
Subject13	No concentrado	Subject31	Concentrado
Subject14	No concentrado	Subject32	Concentrado
Subject15	Concentrado	Subject33	Concentrado
Subject16	Concentrado	Subject34	Concentrado
Subject17	Concentrado	Subject35	No concentrado