

**UNIVERSIDAD DE LAS AMÉRICAS PUEBLA**

Escuela de Ingeniería

Departamento de Computación, Electrónica y Mecatrónica



**Comparación de métricas lineales y no lineales de las señales de EEG en la detección  
de situaciones de emergencia**

Tesis que, para completar los requisitos del Programa de Honores presenta la estudiante

Sofía García Peña

162807

Ingeniería Biomédica

Director de tesis: Dra. Rocío Salazar Varas

Hoja de firmas

Tesis que, para completar los requisitos del Programa de Honores presenta la estudiante

Sofía García Peña con ID 162807

**Director de Tesis**

---

Dra. Rocío Salazar Varas

**Presidente de Tesis**

---

Dr. Roberto Rosas Romero

**Secretario de Tesis**

---

Mtro. Eduardo Javier Jiménez López

## Índice

Resumen .....	4
Abstract .....	5
Introducción .....	6
Justificación.....	9
Objetivos de investigación (general y específicos) .....	10
Marco Teórico .....	10
Estado del arte .....	30
Metodología .....	35
Resultados obtenidos .....	44
Conclusiones y discusión de resultados .....	58
Referencias bibliográficas .....	61
Anexos.....	67

## **Resumen**

La extracción de métricas de señales EEG permiten indicar la preparación fisiológica ante una emergencia. Con las interfaces cerebro-computadora es posible traducir la alerta identificada en la percepción, hacia una señal de control que evite riesgos, presentando ventajas en aplicaciones para ejecución de rutinas de resguardo.

En la presente investigación, se muestra un algoritmo de clasificación de eventos de emergencia en señales EEG, identificados en potenciales asociados a eventos (ERP) de frenado de emergencia. Se compararon cinco métricas frecuenciales con ventanas de un segundo a partir de la aparición del estímulo. Las métricas de espectro de frecuencia y potencia relativa de señales ERP, presentaron mejores desempeños de clasificación, alcanzando una precisión de 80% para los mejores sujetos.

Se logran clasificar estados mentales asociados a situaciones de emergencia con modelos de red neuronal (NN) y máquina de soporte vectorial de base radial (SVM). Se destaca el desempeño de clasificación de métricas de densidad espectral y potencia relativa de las señales EEG en canales parietales y occipitales.

**Abstract**

The metrics extraction from EEG signals allows us to detect the physiological anticipation for an emergency. With brain-computer interfaces (BCIs), it is possible to translate the perception identified alert into a control signal to avoid risks, presenting advantages in applications for execution of system-protection routines.

In this research, an algorithm for the classification of emergency events in EEG signals is shown, with detection of event-related potentials (ERP) in emergency braking situations. Five frequency metrics with one-second windows from stimulus onset were compared. The frequency spectrum and relative power metrics of ERP signals presented better classification performances, reaching 80% accuracy values for the best subjects.

It is possible to classify mental states associated with emergency situations with neural network (NN) and radial base vector machine (SVM) models. The classification performance of spectral density metrics and relative power of EEG signals in parietal and occipital channels proved to be highly relevant.

## **Introducción**

El tema de estudio que será abarcado a lo largo de la presente tesis tiene relación con la predicción de eventos de emergencia, por medio de la extracción de características obtenidas de espacios frecuenciales y temporales de señales cerebrales adquiridas por electroencefalografía (EEG). El predecir la intención de reacción, reflejada en la actividad cerebral, con antelación a la respuesta física del cuerpo, puede presentar grandes ventajas en diversas aplicaciones, por ejemplo, ejecutar alguna rutina de resguardo para minimizar las consecuencias debidas a un fenómeno inesperado.

Evidentemente, la obtención de características presentes en señales EEG que indiquen la preparación fisiológica ante una emergencia es de utilidad para lograr traducir la alerta identificada en la percepción, hacia una señal de control que pueda minimizar o prevenir cualquier clase de riesgo.

La implementación de sistemas que identifiquen señales de alerta con el análisis en tiempo real de parámetros fisiológicos es de gran utilidad en aplicaciones de interés para el desarrollo de tecnologías de asistencia o rehabilitación. Actualmente se identifica mayor atención por parte de la comunidad científica enfocada en desarrollo de sistemas médicos de apoyo, esto se relaciona con la necesidad de incorporar algoritmos capaces de alertar con antelación al usuario de la detección de situaciones que puedan dañar al propio sistema o al mismo usuario.

Esta clase de procesamiento y aprovechamiento de la actividad cerebral que refleja la percepción de situaciones de alerta es de gran utilidad en aplicaciones como: sistemas de asistencia a pacientes con impedimentos motrices o sistemas de encendido de alarmas en

dispositivos de rehabilitación, por mencionar ejemplos prácticos y conocidos en el área de ingeniería biomédica (Fontanillo L., 2020).

Un estudio pionero presentado en 2011 en la revista científica “*Journal of Neural Engineering*”, se destacó por reportar un método de clasificación de potenciales relacionados con evento (ERP) asociados a la anticipación de frenado detectada en sujetos sanos.

El entorno preparado para llevar a cabo el experimento consistía en un simulador de manejo (volante, pedal de frenado y tres monitores para visualizar ambiente virtual de manejo) en el cual se presentaba un carro líder que era seguido por el carro del sujeto a una velocidad simulada de 100 km/h. Para evocar un ERP relacionado con una emergencia de frenado que fuera percibida por el sujeto, el estímulo detonante se presentaba mediante un parpadeo de luces de frenado del carro líder. El objetivo es detectar la intención de frenado de los sujetos basándose en la actividad cerebral que se presenta previo a una respuesta física ante una situación de emergencia.

Los autores lograron detectar la respuesta al estímulo basándose en la activación cerebral con 130 ms de antelación en comparación con un sistema basado únicamente en la respuesta de activación motora (registrada por electromiografía). Los autores del estudio reportan que la antelación a la respuesta física para el frenado del coche implicaría una reducción de la distancia de frenado en 3.66 m considerando una velocidad de manejo de 100 km/h. El máximo puntaje de desempeño de clasificación que reportaron fue de 0.954 para el canal EEG que utilizaron.

Tomando como referencia el trabajo descrito, los principales desafíos con los que cuenta la investigación planteada son:

- Mejorar las tasas de eficacia de clasificación de métricas de señales que se encuentran reportadas hasta ahora en otras investigaciones.
- Disminuir el tiempo de identificación de características de señales EEG asociadas con evento de emergencia, con una ocurrencia previa a la respuesta física ante la emergencia.

Así pues, se propone analizar ventanas de menor dimensión que las propuestas por los autores de la base de datos, con el objetivo de evaluar si la clasificación puede ser igual o superior a la reportada por los autores de la base de datos. Aunado a esto, se evalúan cinco características en espacios frecuenciales y temporales de las señales EEG, estas características son: entropía espectral, coherencia, lateralización, densidad espectral de potencia y potencia relativa de la señal.

Al probar la clasificación de eventos de emergencia relacionados con ERPs detectados en señales de EEG con 5 características que ya han sido utilizadas en otros trabajos; será posible reportar una comparación de clasificaciones con distintas características y definir la más exitosa para el caso de la simulación de manejo a la cual fueron sometidos los sujetos del experimento.

Para el desarrollo de este trabajo se implementaron algoritmos para procesamiento de señales EEG; extracción de características en los dominios de tiempo y frecuencia; cálculo de métricas estadísticas para comparar las diferentes características extraídas; reducción de dimensionalidad de espacios de características; implementación de modelos de clasificación; validación y evaluación de los modelos de clasificación; comparación de desempeño de clasificadores y validación final de resultados. Todos los códigos fueron implementados en MATLAB de MathWorks Inc, de igual manera se hace uso de funciones específicas con



algoritmos existentes que son propios de la herramienta de análisis de datos (MATLAB, 2022).

Con el fin de realizar una comparación de eficiencia de clasificación de las características analizadas, se utilizó una base de datos generada por los autores del trabajo ya descrito, “*Event-related potentials predict upcoming braking events*” (Haufe S., 2011). Dicha base de datos fue publicada en línea para el concurso BNCI2020, relativo a publicaciones y hallazgos enfocados en aplicaciones de interfaces cerebro-computadora (*Brain-Computer Interfaces* o BCIs) (BNCI Horizon, 2020).

Finalmente, en el presente trabajo se reportan como hallazgos relevantes, los algoritmos implementados para la predicción de eventos de emergencia por medio de características extraídas de señales cerebrales que contienen ERP (potenciales relacionados con evento) asociados con estímulos visuales que desencadenan una reacción fisiológica ante un evento de emergencia, así como señales cerebrales normales registradas al no recibir ningún estímulo.

## **Justificación**

El adquirir una señal de EEG y extraer información significativa que demuestre alerta e intención de reacción ante una emergencia y detectarla después de recibir un estímulo, dará antelación ante una respuesta física de reacción del cuerpo, que implicaría la capacidad de predecir una respuesta de emergencia a partir de la activación cerebral.

Si la señal es reconocida de manera adecuada y con antelación suficiente, sería posible utilizar la detección de señales de respuesta a un evento de emergencia para generar una señal

de control a un sistema de asistencia al paciente como puede ser un exoesqueleto, silla de ruedas, alerta de asistencia, prótesis, entre otras aplicaciones relacionadas con tecnología de rehabilitación o asistencia.

### **Objetivos de investigación (general y específicos)**

Identificar características adecuadas para lograr una clasificación aceptable de señales cerebrales que permitan reconocer con anticipación de milisegundos situaciones de emergencia. Para lograr este objetivo, se proponen los siguientes objetivos específicos:

- Hallar una red reducida de electrodos (menor a 20) que brinde información relevante en cuanto a la actividad cerebral detectada posterior al estímulo.
- Analizar una ventana de 1000 ms posteriores al estímulo asociado con la situación de emergencia.
- Implementar los algoritmos para extraer cinco diferentes características: coherencia, entropía espectral, lateralización, espectro en frecuencia y potencia relativa.
- Comparar del desempeño de clasificadores SVM y NN con las 5 características extraídas.

### **Marco Teórico**

En esta sección se exponen conceptos relevantes, considerados temas clave debido a la fundamentación teórica que brindan a la metodología utilizada para la creación del código de detección anticipada de situaciones de emergencia.

- Electroencefalografía (EEG)

La electroencefalografía o EEG es una herramienta de diagnóstico médico e investigación que ha captado mayor atención entre las diversas áreas de ingeniería biomédica. Esta herramienta permite el registro de la actividad eléctrica cerebral mediante una red de electrodos acomodados estratégicamente procurando abarcar proporcionalmente el cuero cabelludo, utilizando como referencia el sistema internacional 10-20 (Novo C., 2010), como se muestra en la Figura 1.

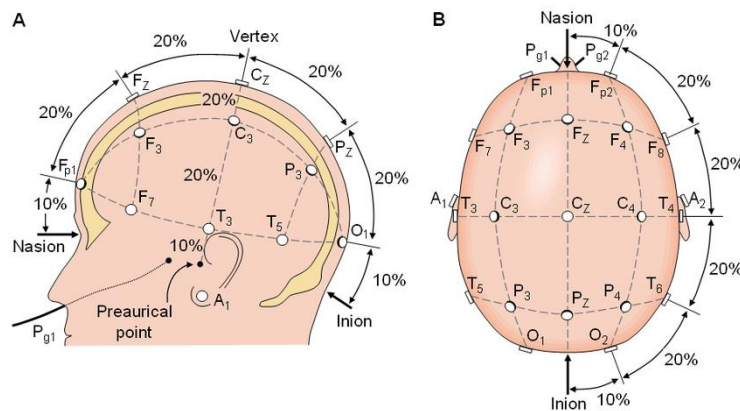


Figura 1. Diagrama de sistema internacional 10-20 para colocación de electrodos en EEG.

El electroencefalograma (EEG), brinda lecturas de las señales cerebrales con la principal característica de tener una resolución temporal muy buena, logrando brindar información de cambios en la actividad cerebral en periodos de milisegundos (Saikia A., 2019), con la desventaja de contar con una baja resolución espacial. Para hacer frente a esta baja resolución, se coloca estratégicamente una alta cantidad de electrodos con pocas separaciones entre ellos, utilizando como referencia las posiciones mostradas en la Figura 1.

El EEG inicialmente fue utilizado como herramienta de registro para diagnóstico y evaluación de pacientes con enfermedades cerebrales específicas como trastornos cognitivos o descompensaciones, como la epilepsia. Actualmente también es utilizado con fines investigativos para aplicaciones de interfaces cerebro-computadora o BCI por su abreviatura del inglés *Brain-Computer Interfaces* (Wolpaw J. R., 2002).

- Potenciales relacionados con evento (ERP)

Los potenciales relacionados con evento o ERP por la abreviatura del inglés *Event-related potentials*, representan la respuesta cerebral a un evento específico relacionado con un evento sensorial, motor o cognitivo. Para la evaluación de estos eventos únicamente se extraen de la señal EEG los cambios relacionados con el estímulo específico que disparó el potencial debido a que varios componentes del ERP observables en la señal están directamente relacionados con el estímulo (Baslar E., 1985).

Los ERP han demostrado ser buenos indicadores para el estudio de tareas de percepción y atención, debido a la excelente resolución temporal que permite observar cambios en la actividad cerebral con definición de milisegundos. Debido a la naturaleza de la actividad eléctrica cerebral, no se presenta ningún retraso detectable entre la generación del potencial en el cerebro y la detección del potencial como registro extraído afuera del cráneo (Woodman G. F., 2014).

Los ERP permiten observar una cadena de procesos cognitivos que toman lugar en el cerebro milisegundos antes de que se envíe información sensorial al sistema nervioso

periférico (SNP) hasta después de que ocurre una respuesta como consecuencia de la señal sensorial enviada al SNP (Woodman G. F., 2014).

La comprensión del proceso cognitivo que describe la señal de ERP visualizada por el registro EEG, permitirá relacionar correctamente la información del potencial con los grupos de neuronas que se esperan activar en la corteza cerebral. Para asegurar un análisis apropiado de los ERP registrados experimentalmente, en (Woodman G. F., 2014) se sugieren consideraciones fundamentales. A continuación se exponen las consideraciones más relevantes considerando los objetivos de la presente investigación:

- Los estímulos visuales deben ser los mismos para lograr amplitudes de voltaje similares en el registro de los potenciales. Esto evitará propagar diferencias en todo el sistema y mejorará la identificación de diferencias reales en cambios de comportamiento neuronal por experimento.
- Las señales previas al inicio del experimento pueden presentar diferencias como indicador de que la relación señal a ruido (SNR) de los ERP promediados es baja, indicando un tipo de alteración presente que pueda modificar la señal real para análisis.
- Las señales y los efectos inmediatos posteriores a un estímulo que involucre a un complejo ERP duran por lo menos un segundo hasta ser disipados por los siguientes procesos cognitivos.
- Al analizar la mayor cantidad de experimentos posibles por participante, se evitarán artefactos que tengan amplitudes similares a los potenciales de interés. Promediar las señales extraídas en numerosas ventanas de tiempo que contengan al ERP permitirá la omisión de cambios que corrompan la señal en el rango de tiempo deseado.

- Para cuantificar características específicas de los componentes ERP, es mejor enfocarse en el resto del segmento de tiempo seleccionado y no enfocarse en los picos iniciales de voltaje ya que suelen estar altamente influenciados por ruido de alta frecuencia.
- La interpretación de los componentes se puede facilitar al seleccionar componentes ERP específicos únicamente por el conocimiento de sus distribuciones en el cráneo.
- Para definir el tamaño de la ventana, la misma tendrá que abarcar el tiempo necesario para incluir el potencial de interés completo, esto requiere conocer la secuencia temporal establecida por el paradigma de los experimentos.
- La variabilidad entre sujetos es otro aspecto relevante que implica tomar una muestra considerable de sujetos de acuerdo con el tipo de ERP que se vaya a analizar, así como un número mínimo de experimentos a probar por sujeto de acuerdo con el tipo de estímulo y respuesta que se espera obtener. La variabilidad entre sujetos existe debido a las diferencias de plegamiento cortical, todas las personas tienen de manera fundamental componentes y procesos cognitivos iguales, pero los patrones de voltaje distribuidos en la corteza cerebral variarán de acuerdo con los patrones de plegamiento del tejido cortical ya que cambia la distribución de la materia gris. De igual manera, el grosor del cráneo y la conductividad de los tejidos podrá variar entre sujetos logrando cambios en las amplitudes de los ERP (Nunez P., 2006).

- Interfaces cerebro-computadora, Brain-computer interfaces (BCIs)

Las señales registradas por EEG permiten el control de dispositivos de rehabilitación por medio de una técnica no invasiva, dicha tecnología representa una herramienta de mucha

utilidad para personas con discapacidad. El control de prótesis por medio de interfaces cerebro-computadora permite establecer un puente de comunicación entre el paciente y un dispositivo que lo apoye y le permita llevar un estilo de vida con más comodidades (Abiri R., 2019).

Los sistemas de BCI trabajan con las señales cerebrales adquiridas por EEG, posteriormente estas señales son procesadas y utilizadas como señales de control para ser enviadas a microcontroladores y establecer el control de dispositivos. En la Figura 2 se presenta un diagrama de bloques que describe el funcionamiento principal de un sistema de interfaz cerebro-computadora (Abiri R., 2019).

Una gran variedad de tecnologías de rehabilitación de pacientes ha sido desarrollada con base en sistemas BCI, los sistemas que se desarrollan suelen utilizarse para el control y regulación de movimiento. Algunos ejemplos de sus principales aplicaciones son: el control de sillas de ruedas, prótesis de miembros superiores o inferiores, control de dispositivos del hogar (iluminación, televisión o temperatura), control de apertura de cuartos, control de dispositivos robóticos, control de elementos en realidad virtual, control del cursor en una pantalla de computadora, deletreo de palabras, escritura de mensajes, entre muchas otras aplicaciones.

Los algoritmos de extracción de características de señales EEG juegan un papel muy importante para que el sistema BCI logre identificar correctamente las intenciones del usuario, pues permite extraer información de la señal asociada con alguna tarea mental específica.

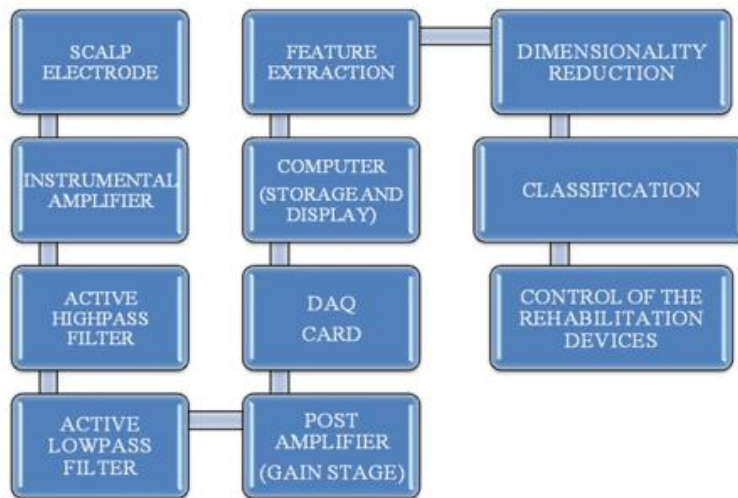


Figura 2. Diagrama de bloques de un sistema BCI.

Los bloques de extracción de características (*Feature extraction*), clasificación (*Classification*) y reducción de dimensiones (*Dimensionality reduction*) serán los bloques más relevantes en los cuales se encuentra enfocada la presente investigación, ya que se implementarán diversos algoritmos de extracción de características y se hará una comparativa para analizar las características que puedan ser más distinguibles por distintos modelos de clasificación. Los modelos de clasificación que sean utilizados requieren representación reducida de las características que se utilizan como entradas, por lo que también será necesaria una reducción de dimensiones de las matrices de datos que sean ingresadas a los clasificadores.

#### - Procesamiento de señales

El registro por EEG de las señales cerebrales está caracterizado por mostrar potenciales eléctricos de baja amplitud con rangos de frecuencia bajos de entre 4 y 60 Hz, estas frecuencias pueden permitir que señales no relacionadas con la actividad cerebral sean



mezcladas y contaminen los registros con información no deseada conocida como artefactos (Islam M. K., 2016).

En la Figura 3 se muestran los distintos rangos de frecuencia que han sido identificados para las ondas cerebrales y las ubicaciones que suelen tener en las distintas zonas cerebrales (Islam M. K., 2016).

Type	Frequency	Activity	Location
<b>Gamma</b>	20 – 60Hz	Visual attention	Occipital
<b>Beta</b>	14 - 20 Hz	Mental activity	Parietal and frontal
<b>Alpha</b>	8 - 13 Hz	Sensory stimulation	Occipital and parietal
<b>Theta</b>	4- 8 Hz	Emotional Stress	Temporal and parietal
<b>Delta</b>	Less than 4 Hz	Occur during sleep, coma	Everywhere

Figura 3. Tipos de ritmos cerebrales y sus respectivos rangos característicos de frecuencias.

Para la etapa de preprocesamiento de las señales EEG, el identificar correctamente los artefactos es de gran importancia. Los artefactos más comunes que se pueden encontrar en los registros con EEG están relacionados con otros biopotenciales como: cardiacos, musculares, oculares, aunque también pueden ser generados por dispositivos externos o ruido debido a alteraciones en una colocación incorrecta de electrodos en el cuero cabelludo.

Existen diversas técnicas de preprocesamiento de señales EEG, pero entre la más conocidas y utilizadas se encuentran las siguientes: Filtros adaptativos, Análisis de componentes independientes (ICA), filtros Wiener multicanal, método de diagonalización aproximada conjunta de Eigen-matrices (JADE), transformación wavelet, algoritmo de mínimo cuadrado medio (LMS), transformada discreta de Fourier (DFT), wavelet Haar.

Una consideración previa a la etapa de extracción de características de las señales EEG es la segmentación de las señales pre procesadas. A la segmentación de las señales en

el dominio del tiempo se le conoce como *ventaneo*, donde cada ventana corresponde a un rango de tiempo específico definido para facilitar el análisis de toda la señal.

La definición del tamaño de la ventana podrá variar los resultados de extracción de características de las señales de interés. Si la ventana se eligiera con un rango de tiempo muy amplia, podría provocar una superposición de la información analizada de la señal provocando que la característica extraída sea combinada con el resto de la información. En otro caso, si la ventana se ve muy reducida en el tiempo que extraerá de la señal, entonces podría estarse perdiendo información relevante que dará una extracción menos válida de las características.

- Extracción de características

La extracción de características es esencial para cualquier aplicación BCI, ya que ayuda a obtener información relevante para describir mejor la señal EEG y que sea de utilidad en nuevas etapas de procesado de la señal (Sarma P., 2016). Corresponde a una etapa esencial en el procesamiento de señales EEG para lograr resultados óptimos de clasificación (F. Shiman, 2012).

Para intentar describir los procesos cognitivos que pueden reflejarse por medio del análisis de EEG, se han desarrollado algoritmos basados en sistemas no-lineales y sus métodos matemáticos. La descripción de la dinámica no lineal para señales EEG definen al proceso de generación de las señales registradas como un sistema no determinista, debido a la imposibilidad de predecir el futuro comportamiento de la señal con valores a pesar de tener todos los valores anteriores conocidos, por la misma razón también es posible aplicar otros

conceptos no lineales o de teoría del caos por la imprevisibilidad del sistema (Prabhu, S., 2019).

La comprensión de la información que brindan las señales EEG considerándolas como producto de un sistema dinámico no lineal, permite el análisis de este sistema desde los dominios del tiempo y de la frecuencia. Ambos dominios permiten analizar la duración de las señales y la rapidez o lentitud de estas.

Entre los métodos más comunes de extracción de características de señales EEG correspondientes a imaginación motora, se encuentran los algoritmos de patrón espacial común (CSP), densidad espectral de potencia (PSD), modelo autorregresivo (AR) y transformada discreta de wavelets (DWT) (L. Dezhi, 2020).

Resultados experimentales de investigaciones recientes (L. Dezhi, 2020), han demostrado que los métodos de extracción múltiple de características son superiores a métodos de extracción que utilizan una sola característica (Xu J., 2020).

A continuación, se describen algunas técnicas empleadas para la extracción de características.

- Entropía espectral de potencia

La entropía espectral de potencia (PSE) ha demostrado buenos resultados de clasificación al aplicarse para análisis de señales cerebrales de tareas que involucran imaginación motora (A. Zhang, 2008).

La teoría que soporta el algoritmo de PSE está basada en la teoría de información de Shannon en la cual es definida la entropía de una fuente de información (Shannon C. E.,

1948) como la probabilidad de ocurrencia de distintos eventos como combinaciones en un sistema desconocido.

Esta característica describe un índice de complejidad como parte del cambio de estados dinámicos no lineales, además es un algoritmo que requiere de poca información por lo que es bastante adecuado para el análisis de señales EEG extraídas de tareas de imaginación motora.

En investigaciones relacionadas con el análisis de características de señales EEG por medio de la extracción de PSE, se han reportado resultados prometedores respecto a la correcta clasificación de estados mentales presentes en el monitoreo de etapas del sueño (Liu H., 2005), también en estudio de extensión de lesiones isquémicas cerebrales (Wu H., 2003) y en clasificación de tareas de imaginación motora (D. Xiao, 2009).

El espectro de potencia de una señal  $x(n)$  es expresado como  $S(m) = |X(m)|^2$ , donde  $X(m)$  es la transformada de Fourier de la señal original. Una vez realizada la transformación de la señal al dominio de la frecuencia, es posible expresar la distribución de probabilidad  $P(m)$  con la ecuación 1.

$$P(m) = \frac{S(m)}{\sum_i S(i)} \quad [1]$$

La entropía espectral representada por  $H$ , utiliza la distribución de probabilidad con la expresión de la ecuación 2.

$$- \sum_{m=1}^N P(m) \log_2 P(m) \quad [2]$$

Normalizando la ecuación 2 donde  $N$  corresponde al número total de valores de frecuencia, se obtiene la expresión de la ecuación 3. En la normalización, el denominador

$\log_2 N$  representa la entropía espectral máxima de ruido con distribución Gaussiana (ruido blanco), distribuido uniformemente en el dominio de la frecuencia.

$$H = -\frac{\sum_{m=1}^N P(m) \log_2 P(m)}{\log_2 N} \quad [3]$$

Para obtener la entropía espectral instantánea dado un espectrograma de potencia conocido  $S(t, f)$ , la distribución de probabilidad se expresa con la ecuación 4.

$$P(m) = \frac{\sum_t S(t, m)}{\sum_f \sum_t S(t, f)} \quad [4]$$

De esta manera, es posible obtener la entropía espectral instantánea dado un espectrograma de potencia  $P(t, m)$ , al basarse en los instantes especificados con ayuda del espectrograma. la distribución de probabilidad en un tiempo  $t$ , es descrita por la ecuación 5.

$$H(t) = -\sum_{m=1}^N P(t, m) \log_2 P(t, m) \quad [5]$$

#### - Conectividad

La conectividad cerebral corresponde a una herramienta que permite analizar cómo interactúan distintas regiones cerebrales, para las aplicaciones BCI existen dos tipos principales de evaluación de conectividad cerebral; donde es posible evaluar la relación entre regiones de acuerdo con su funcionalidad o la relación efectiva relacionando la funcionalidad y estructura cerebral (Alonso-Valerdi, L. M., 2019).

En la última década, se han llevado a cabo diversos estudios en los cuales se busca analizar al cerebro como un sistema complejo (Davidson R. J., 2004). Por lo cual la conectividad cerebral ha sido ampliamente investigada como un método de búsqueda de

relación entre zonas cerebrales para comprender mejor la interacción e intervención de redes de neuronas que se activan durante distintas tareas mentales (He, B., Yang, L., 2011).

Con el análisis de conectividad se ha examinado cómo es que las regiones cerebrales son coactivadas para comunicarse entre ellas y permitir sincronía que resulte en activaciones cerebrales específicas relacionadas con distintas tareas mentales (Bhattacharya, J., 2005).

Se ha comprobado que el proceso de estímulos complejos involucra la integración de distintas zonas cerebrales (Billinger M., 2013). También se han logrado identificar exitosamente patrones de conectividad útiles en el reconocimiento de estados neurales y respuestas cerebrales complejas (Kaminski M., 2001).

#### - Coherencia

La comunicación cerebral por coherencia es un modelo establecido por el autor Fries (Fries P., 2015), en el cual establece la existencia de una sincronía oscilatoria entre distintos grupos de neuronas para lograr comunicación y transferencia de información entre distintas regiones del cerebro.

La teoría de comunicación por medio de coherencia (CTC) establece que cuando un grupo de neuronas entra a un estado de sincronización rítmica, se producen secuencias excitatorias e inhibitorias que modifican la sensibilidad de las entradas sinápticas por periodos de tiempo muy cortos. El cambio en la sensibilidad de las entradas produce una coherencia selectiva cuando las neuronas comienzan a tener respuestas que convergen más con el área presináptica que posea una sincronización rítmica similar, lo cual indica una mayor coherencia postsináptica (Prabhu, S., 2019).

La coherencia presenta un concepto de utilidad para poder comprender la dinámica de las señales EEG; la dinámica de estas señales puede apreciarse como una coherencia espontánea que ocurre entre distintas regiones cerebrales a distintas frecuencias, la cual ocurre debido a un proceso oculto. Otra apreciación de la dinámica de señales EEG corresponde a una secuencia de cambios oscilatorios que ocurren debido a estímulos sensoriales (potenciales sensoriales evocados) o a estímulos relacionados con cognición (potenciales relacionados con evento o ERPs) (Prabhu, S., 2019).

La coherencia es una función que se obtiene con los valores de las densidades espectrales de potencia  $P_{xx}(f)$  y  $P_{yy}(f)$  de las señales, así como con la densidad de potencia espectral  $P_{xy}(f)$  de dos señales  $x$  y  $y$ . LA expresión de coherencia para un sistema de entradas únicas se define con la ecuación 6.

$$C_{xy}(f) = \frac{|P_{xy}(f)|^2}{P_{xx}(f)P_{yy}(f)} \quad [6]$$

En el caso de buscar obtener los valores de coherencia de arreglos de valores correspondientes a sistemas de múltiples entradas que requieran de múltiples salidas, la función de coherencia múltiple sería la expresada en la ecuación 7.

$$C_{Xy_i}(f) = \frac{P_{Xy_i}^{\dagger}(f)P_{XX}^{-1}(f)P_{Xy_i}(f)}{P_{y_iy_i}(f)} \quad [7]$$

En la ecuación 7, para una señal de salida con orden  $i$ ;  $X$  corresponde a un arreglo de  $m$  valores de entrada;  $P_{Xy_i}$  corresponde a un vector de dimensión  $m$  de densidades de potencia espectral cruzada entre los valores de entrada y  $y_i$ ;  $P_{XX}$  corresponde a las densidades espectrales de potencia y las densidades espectrales de potencia cruzadas de las entradas en

una matriz de dimensiones  $m \times m$ ;  $P_{Y_i Y_i}$  es la densidad espectral de potencia de la salida; finalmente, el exponente  $t$  corresponde a la transpuesta compleja conjugada.

El valor de la coherencia se encuentra entre 0 y 1; el resultado definirá qué tanto corresponde la señal  $x$  a la señal  $y$  en el dominio de la frecuencia. Un valor de coherencia igual a uno indica la máxima correspondencia entre señales y 0 indica la mínima correspondencia.

- Espectro en frecuencia

Otro método de análisis matemático que ayuda para el desarrollo de algoritmos de procesamiento de señales EEG es la transformada rápida de Fourier, que describe a la señal EEG como una señal compuesta por una gran suma de señales senoidales. Estudiando las frecuencias que componen a la señal al extraer su correspondiente espectro en frecuencias, es posible extraer información relevante (Prabhu, S., 2019).

Para comprender los procesos que ocurren en el cerebro en la cognición, existen diversas herramientas matemáticas y métodos de análisis. En la Tabla 1 se presentan algunos de los métodos más utilizados por presentar eficiencia en la veracidad y predictibilidad de sus resultados (Prabhu, S., 2019).



Tabla 1. Métodos de análisis para señales EEG.

Technique	Description	Usefulness
<b>Power spectral density</b>	Describes the power present in the signal as a function of frequency, per unit frequency	Marker of strength of activity of group of neurons
<b>Evoked spectra</b>	FFT analysis of the sensory-evoked potential elicited by simple light, tone signal, etc.	Documents early processing of sensory information
<b>Event-related spectra</b>	FFT analysis of an event-related potential (ERP), e.g. target or non-target signal during an oddball paradigm	Documents early response to target words and images which represent cognition
<b>Phase-locking, phase synchrony</b>	Used to investigate task-induced changes in long-range synchronization of neural activity	Indicates changes in system by a specific task
<b>Cross-correlation</b>	<i>Cross-correlation</i> measures the similarity between two discrete time series, say X and Y. Here X and shifted (lagged) copies of Y are studied as a function of the lag	Indicates evolution of cognitive processing as time passes in different brain regions
<b>EEG coherence</b>	Quantifies the association between pairs of signals as a function of frequency	Useful for measuring changes in EEG topography related to cognitive tasks
<b>Inter-electrode correlation</b>	Quantifies the association between pairs of signals as a function of frequency between different electrodes located on the scalp	Indicates how different brain regions 'cross-talk' to make a holistic cognition

- Clasificadores de características

Los estudios de clasificación de EEG son cada vez más comunes debido a la necesidad de encontrar características útiles que puedan ayudar a convertir las señales cerebrales, de una respuesta cerebral derivada de un estímulo, a señales de control lo suficientemente certeras para poder ser replicadas por otros sujetos en experimentos con tareas mentales estandarizadas que logren el manejo de sistemas para dispositivos de asistencia, dispositivos de rehabilitación o incluso sistemas de uso cotidiano como los automóviles.

Entre los modelos de clasificadores más populares utilizados con fines de investigación, se encuentran; análisis lineal discriminante (LDA), K-vecino más cercano (k-NN), redes neuronales (NN) artificiales (ANN) y máquina de soporte vectorial (SVM) (Saikia A., 2019).

Para propósitos del presente trabajo, serán definidas dos técnicas de clasificación aplicadas a señales EEG, por ser referentes a los modelos NN y SVM, los cuales son ampliamente utilizados para identificación de estados cerebrales.

- Redes neuronales artificiales (ANN)

Las redes neuronales son modelos de clasificación creados con la idea de asemejarse a la manera de procesamiento de información que tienen las neuronas en el cerebro humano. Las unidades de procesamiento básicas de estos modelos son llamadas neuronas o perceptrones y se organizan en capas.

La configuración más básica que puede tener una red neuronal consiste en tres partes principales; una capa de entrada en donde se representan las características de entrada; una o varias (multicapa) capas ocultas que analizan los valores de la capa previa para modificarse y mejorar el modelo; y una capa de salida que entrega la unidad o unidades de salida referentes a la salida resultante del modelo (IBM, 2021). En la Figura 5 se muestra el modelo de un ejemplo hipotético de una red multicapa de perceptrones, la cual es equivalente a la definición de una red neuronal con más de una capa oculta (Hassan H., 2015).




Figura 5. Esquema descriptivo de una Red neuronal artificial (ANN).

Las neuronas de las redes son conectadas con pesos sinápticos o ponderaciones correspondientes a los valores propagados por cada neurona de la capa anterior con dirección hacia la capa de salida. El funcionamiento básico de una red neuronal consiste en ir examinando valores individuales mientras va creando predicciones y ajustando los valores de los pesos sinápticos de entrada a las siguientes neuronas si se tuvo una predicción errónea. El proceso debe realizarse con varias repeticiones para que la red tenga una mejora continua hasta alcanzar los valores de predicción deseados.

- Máquina de soporte vectorial

Los clasificadores de máquina de soporte vectorial o SVM por las siglas en inglés, están basados en la teoría del aprendizaje estadístico. Los clasificadores SVM discriminan información mediante la búsqueda de hiperplanos óptimos que logren separar puntos de información correspondientes a una clase repartida en un espacio que puede alcanzar un tamaño infinito de dimensiones (hiperespacio). El modelo busca separar una clase de otro grupo de características correspondientes a otra clase  $n$  (Saikia A., 2019). Una vez que el hiperplano ha sido definido se le nombra plano de decisión, el propósito de este plano es separar un conjunto de características pertenecientes a distintas clases y agruparlas definiendo límites de decisión. Los clasificadores SVM buscan el hiperplano más apto de manera que el margen de separación entre clases sea el máximo posible (I. El-Naqa, 2002).

Para la mencionada técnica de clasificación, se presenta una variable de holgura o *slack* variable como técnica de compensación de puntos de error (Hsu CW., 2003). El algoritmo de clasificación con SVM es el más popular ya que presenta altos puntajes

generalizados de desempeño sin necesidad del conocimiento a priori incluso para espacios dimensionales muy altos (Vapnik V. N., 2022).

Para el mapeo de una característica existente en un espacio de menor dimensión, la misma debe ser transformada para lograr su acomodo dentro de un nuevo espacio de características. Para lograr lo anterior, se hace uso de distintos *kernels* (conjunto de funciones matemáticas que permiten la manipulación de los datos) que pueden ser de base lineal o no lineal y que son aplicados para cambiar las características de un espacio complejo a uno más simple o menor en dimensionalidad. En la Figura 6, se muestra un ejemplo gráfico del modelo teórico de la transformación de características y de su separación mediante vectores de soporte para lograr alcanzar la probabilidad más baja de aparición de un error de clasificación (Weston J., 1999).

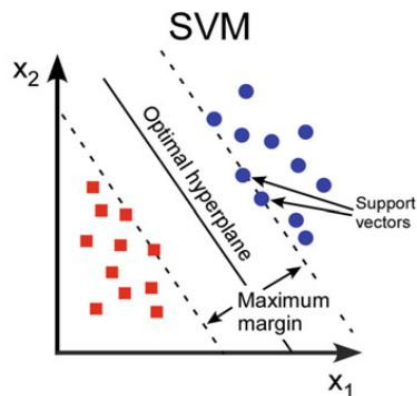


Figura 6. Clasificador SVM basado en modelo discriminativo de aprendizaje.

- Evaluación de resultados de clasificación

Después de la clasificación, el siguiente paso corresponde a la evaluación del desempeño general del clasificador para evaluar si el modelo creado será capaz de predecir

exitosamente las clases correctas de características provenientes de información nueva y desconocida.

La métrica que ofrece una medida directa de la evaluación de desempeño de un clasificador, es la precisión o *accuracy*. Este parámetro evalúa la porción de predicciones correctas entre el total de predicciones realizadas, es decir, el porcentaje de características que fueron correctamente clasificadas (Tu Y.,2019).

Por la propia simplicidad en la obtención de la medida de precisión, es necesario resaltar que dicho cálculo de desempeño no sería adecuado si es aplicado para sets de información no balanceados; los cuales corresponderían a aquellos en los que el número de observaciones pertenecientes a una clase sea mucho menor que la cantidad de observaciones pertenecientes a la clase contraria.

También se requiere contar con otras medidas de evaluación de desempeño para la clasificación binaria (dos posibles clases). Estos resultados pueden desglosarse para una mejor evaluación de desempeño como: verdadero positivo (TP) que implica una característica clasificada en una clase y que sea perteneciente a la misma clase, falso positivo (FP) como una característica erróneamente clasificada y acomodada en la clase contraria, verdadero negativo (TN) como una característica correctamente clasificada en la clase contraria y falso negativo (FN) como una característica incorrectamente clasificada en la clase contraria (Tu Y.,2019).

La sensibilidad o *sensitivity* de clasificación obtiene la proporción de positivos correctamente identificados como tales;  $Sensitivity = \frac{TP}{TP+FN}$ . La especificidad obtiene la

proporción de los negativos que son debidamente clasificados como tal; *Specificity* =

$$\frac{TN}{TN+FP}$$

### Estado del arte

Como parte de la investigación necesaria para decidir las técnicas que se aplicarán en el presente trabajo mediante algoritmos de procesamiento, análisis, clasificación y validación de resultados; se considera relevante la revisión de investigaciones publicadas que hayan realizado experimentos con objetivos similares al de la investigación base de la cual se obtuvo la base de datos para la implementación de técnicas de clasificación de eventos de emergencia.

Por lo que, en la Tabla 2, se identificarán a modo de comparación los aspectos más relevantes considerados para el fin de este trabajo. El destacar los datos presentados en la columna de “Técnica” ayudará a decidir sobre un método de resolución más adecuado para poder cumplir con los objetivos de la investigación.

Tabla 2. Técnicas extraídas de investigaciones relacionadas con detección de ERPs asociados con situaciones de emergencia en conducción simulada.

Artículo	Técnica	Descripción
A novel method of emergency situation detection for a brain-	Análisis	Propuesta de un método de detección de situaciones de emergencia combinando señales EEG con información del

<p>controlled vehicle by combining EEG signals with surrounding information (Bi, L., Wang, H., 2018)</p>		<p>entorno para un vehículo controlado con señales cerebrales.</p> <p>Modelo de detección basado en EEG para detectar intención de frenado de emergencia del conductor.</p> <p>Propuesta del sistema de detección de situaciones de emergencia realizado en código C, se propuso la eficacia del método propuesto utilizando experimentos de retroalimentación al conductor por la computadora en un simulador de manejo.</p>
	Número de sujetos	N =12
	Canales utilizados	16 electrodos (F3, Fz, F4, C3, Cz, C4, T7, T8, P7, P3, Pz, P4, P8, O1, Oz y O2)
	Banda de paso de filtro	0.53-60 Hz
	Tiempo de ventana	1000 ms
	Características	Características de espectro en frecuencia, calculadas aplicando la transformada rápida de Fourier (FFT)

	Clasificadores	<p>Primero obtuvieron una matriz de proyección del patrón espacial común (CSP), así como las etiquetas de la característica extraída.</p> <p>El clasificador utilizado fue el de parámetros de regularización por análisis lineal discriminante (RLDA).</p>
	Resultados de clasificación (mayor porcentaje de accuracy)	96.94% $\pm$ 2.62%
	Implementación	Pseudo-online y online con simulador de manejo
Detection of driver braking intention using EEG signals during simulated driving (Nguyen T.-H., 2019)	Análisis	Mejorar el desempeño y confianza de un sistema para detección de intención de frenado de emergencia.
	Número de sujetos	N = 10
	Canales utilizados	8 electrodos (F3, F4, C3, C4, P3, P4, O1 y O2)



	Banda de paso de filtro	1-60 Hz
	Tiempo de ventana	1000 ms
	Características	Densidad espectral de frecuencia aplicando FFT → espectro de potencia relativa.  Modelo autorregresivo (AR)
	Clasificadores	Red neuronal de perceptrones multicapa
	Resultados de clasificación (mayor porcentaje de accuracy)	90.8%
	Implementación	Online con simulador de manejo
EEG-based detection of braking intention under different car driving	Análisis	Detección de intención de frenado de emergencia utilizando señales EEG del sujeto en un ambiente simulado de

conditions (Hernández L. G., 2018)		conducción. Incluyen la presencia de estrés, sobrecarga mental y fatiga.
	Número de sujetos	N = 7
	Canales utilizados	7 electrodos (F3, F4, C3, C4, Cz, P3, P4)
	Banda de paso de filtro	0-45 Hz
	Tiempo de ventana	1500 ms
	Características	Características espaciotemporales (no especificadas)
	Clasificadores	Máquina de soporte vectorial (SVM) y red neuronal convolucional (CNN)
	Resultados de clasificación (mayor porcentaje de accuracy)	71.1 % → SVM 71.8% → CNN 80.1% → SVM mejor sujeto 88.1% → CNN mejor sujeto
	Implementación	Online con simulador de manejo

## Metodología

En esta sección se describe la base de datos utilizada y el procedimiento que se siguió para realizar el procesamiento y extracción de características de las señales de EEG para diferenciar eventos de frenado de emergencia y conducción normal. Todo el procesamiento fue hecho en el software MATLAB de Mathworks Inc. (MATLAB, 2022), en uso conjunto de la herramienta EEGLab (Delorme A., 2004).

### -Base de datos

Las señales EEG que se utilizaron, fueron obtenidas del set número 24 de la base de datos de acceso abierto publicada en la página oficial del proyecto *BCNI Horizon 2020*. La información fue descargada de manera libre y se ha utilizado bajo los principios que plantea el proyecto *BCNI*.

En el estudio *EEG potentials predict upcoming emergency braking during simulated driving* (Haufe S., 2011), se realizó un monitoreo de procesos cognitivos durante tareas de conducción simulada de un automóvil. Este estudio fue el primero en investigar la correlación entre el registro EEG y la intención de frenado de emergencia.

Para el desarrollo del experimento, el usuario se sentó frente a un simulador de manejo, compuesto por tres pantallas de 19". En la simulación se definió un coche líder, con el cual el participante debía mantener una distancia máxima de 20 m durante la conducción simulada, manteniendo una velocidad de 100km/h. A lo largo del experimento se indujeron situaciones de frenado de emergencia al provocar que el coche líder frenara y redujera su velocidad de manera inesperada, esta información constituye la clase *Target*, los segmentos

de conducción normal forman la clase *Non Target*. El registro por sujeto fue de aproximadamente 135 minutos en los cuales se registró la actividad cerebral de manera continua con un arreglo de 64 electrodos. La señal EEG adquirida fue sub muestreada a 200 Hz y filtrada con un pasa-bajas con una frecuencia de corte de 45 Hz, además de aplicar un filtro Notch a 50 Hz para eliminar el ruido inducido por la línea de corriente.

#### -Selección de canales

Los canales más relevantes fueron definidos con base en las descripciones de las curvas ERP características identificadas por los autores de la base de datos, mostradas en la Figura 7. Los canales fueron considerados relevantes si las curvas ERP promedio de los experimentos presentaban deflexiones similares a las expuestas por los autores. Con la primera etapa de análisis se identificaron patrones similares entre sujetos y se analizaron los electrodos con mejor contribución a la respuesta posterior al estímulo indicador de la situación de emergencia. Se seleccionaron aquellos canales en los que la distribución del potencial, con las señales previamente filtradas, presentaran una diferencia clara entre señales de situación normal y situación de emergencia.




Figura 7. Curvas ERP características del promedio general extraído de los 18 sujetos.

Cabe mencionar que no fueron analizados los 64 canales registrados, sino solo los 20 reportados en el artículo de los autores del *data set*, mostrados en la Figura 8.




Figura 8. Mapas de localización de 20 canales por nombre y número.

Para analizar la distribución del potencial, ésta se visualizó en distintas latencias (cada 100ms), lo que ayudó a observar cuáles eran los canales que daban una mejor contribución para la detección del potencial de cada sujeto. En la Tabla 4 mostrada en el Anexo I, se muestran las gráficas obtenidas.

#### -Selección de ventana de tiempo

Como se mencionó anteriormente, los autores trabajaron con ventanas de tiempo de 1500ms, considerando 300 ms previos a la aparición del estímulo (frenado del coche líder) para la clase *Target*. En el presente trabajo se propone estudiar ventanas de 1 s, a partir de la aparición del estímulo. Este análisis visual fue realizado con las gráficas de distribuciones de

potencial de todos los sujetos. Para la clase *Non Target*, las ventanas fueron tomadas 3.5 s posteriores a la aparición del estímulo. El código correspondiente se muestra en la Figura 25 del Anexo II.

Ya que la variabilidad intersujeto tiene gran influencia en el análisis de los datos, en este trabajo se decidió trabajar con sólo cinco sujetos, a prueba de concepto. Esto tomando en cuenta los análisis visuales de mapas de distribución de potenciales que mostraron un cambio en la zona parietal al incrementar el potencial con la aparición del estímulo, también se confirmó la selección de los sujetos al analizar las señales de cuatro canales de la zona parietal.

#### - Extracción de características

Como se mencionó anteriormente, las características de la señal que se utilizaron para extraer la información de la señal que sería ingresada al clasificador fueron; entropía espectral, coherencia, lateralización, espectro de frecuencia de la señal y potencia relativa extraída de la banda de frecuencias en la que se observaba una mejor separación de las señales. A continuación, se describirá de manera general el algoritmo para el análisis de las señales.

Una vez segmentada la señal en ventanas de 1000s para la clase *Target* y *Non target*, se obtienen dos arreglos tridimensionales (normal y emergencia) de dimensiones  $M \times N \times T$  para cada sujeto.  $M$  corresponde al número de canales,  $N$  es el número de muestras en el tiempo y  $T$  el número de eventos encontrados al segmentar el registro completo para cada usuario.

Como parte del preprocesamiento se aplicó un filtro pasa banda con una frecuencia de corte inferior de 0.5 y frecuencia de corte superior de 15 Hz, debido a que los potenciales ERP se encontraron a frecuencias bajas. A continuación, se describe cómo fueron obtenidas las diferentes características, a fin de generar los vectores de características y:

- *Entropía espectral.* Para obtener los valores de entropía espectral de la señal ERP en la ventana completa analizada, se utilizó la función *pentropy* de MATLAB (MATLAB, 2018). Esta función corresponde a una medida de la distribución del espectro en frecuencia de la señal. La expresión que define al algoritmo que permitió extraer los datos para el espacio de características definido para una señal, se presentó en la ecuación 5.

- *Coherencia.* Para la extracción de la correspondiente matriz de características, se extrajo la estimación de la coherencia de magnitud cuadrada calculada entre diferencias de potencial de pares de canales de los cuales se obtuvo la señal EEG, utilizando la función *mscohere* de MATLAB (MATLAB, 2018). La función obtiene la estimación de la coherencia entre dos pares de canales y se calcula en términos de la frecuencia de muestreo de la señal, la expresión que describe dicha estimación es definida por la ecuación 7.

- *Lateralización.* Para la extracción de esta característica, la señal por canal fue inicialmente filtrada en las bandas de frecuencia alfa y beta. El filtrado de las frecuencias alfa fue definido para la banda de 8-12 Hz y para beta se consideró la banda de 12-15 Hz. Este procesamiento de las señales se realiza basándose en preferencias por frecuencias espaciales bajas y altas como parte de la asociación con el principio de asimetría funcional que ocurre en los hemisferios cerebrales al procesar las percepciones y el comportamiento,

esto es explicado con la teoría de lateralización hemisférica funcional asociada con el aprendizaje perceptivo que posee el cerebro humano (Felisatti A., 2020).

Posteriormente se obtuvieron los valores RMS de cada banda extraída, el cálculo de dichos valores se expresa con la ecuación 8.

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N |x_n|^2} \quad [8]$$

El cociente resultante de la división del valor RMS de la banda beta entre el valor RMS de la banda alfa, como se expresa en la ecuación 9, se utilizó como característica para cada canal. Los datos resultantes para las matrices de características se consideraron relevantes por corresponder a valores eficaces de la señal como indicadores que permiten distinguir numéricamente los eventos ERP posteriores a la emisión de un estímulo, contra las señales obtenidas en situaciones sin estímulo.

$$Y = \frac{x_{\beta RMS}}{x_{\alpha RMS}} \quad [9]$$

La matriz resultante de las características para este caso es igual al número de eventos por el número de canales en los cuales se extrajo la lateralización.

- *Densidad espectral de potencia.* Para extraer la información de la distribución del espectro en frecuencia de la señal, se aplicó la transformada rápida de Fourier a las mediciones bipolares obtenidas de dos pares de los electrodos parietales no centrales.

La transformada rápida de Fourier o transformada discreta de Fourier, se define con la ecuación 10 para una señal  $X$ .

$$Y(k) = \sum_{j=1}^n X(j) W_n^{(j-1)(k-1)} \quad [10]$$



La medición bipolar se realizó entre los electrodos CP3-CP4 y P9-P10, y se obtiene como la diferencia de voltajes de las señales. Esta operación se implementa de manera previa a la obtención de los espectros de frecuencia. Este procedimiento es de utilidad para obtener el voltaje que relaciona a dos áreas cerebrales distintas.

- *Potencia relativa.* La potencia relativa se obtiene al calcular el promedio de la potencia espectral de una banda específica de frecuencias contra la potencia total de la señal.

Para obtener el valor de potencia relativa se ocupó la función de estimación de densidad espectral de potencia *pwelch* de MATLAB (MATLAB, 2018), ya que permite el análisis de un rango personalizado de frecuencias. El método es conocido como “Estimación del espectro de promediado de segmentos superpuestos de Welch” y utiliza un periodograma modificado para cada segmento, para luego promediar las estimaciones obtenidas y generar estimaciones de densidad espectral de frecuencia.

#### - Comparación estadística

Para conocer si las características extraídas son relevantes y útiles, es necesario evaluar si su diferencia es estadísticamente significativa. Mediante la visualización de gráficas, es posible realizar una comparación visual de los datos obtenidos y los valores en que tienden a dispersarse más los datos. Sin embargo, es necesaria una comparación cuantitativa para definir con mayor certeza cuáles características son las más relevantes y útiles en cuanto a la capacidad de clasificar la información que se otorga en las matrices.

Para realizar esta comparación, se hace uso de un método de estadística conocido como prueba de hipótesis. La prueba de hipótesis fue aplicada a las características del

espectro en frecuencia y de entropía espectral. Esta prueba fue útil para conservar únicamente las frecuencias en las que sí existe una diferencia significativa entre clases. La prueba de hipótesis se realizó con la función *ttest* de Matlab, empleando un nivel de significancia de 0.05.

#### - Análisis de componentes principales

A fin de reducir la dimensionalidad del vector de características, se aplicó el método de Análisis de Componentes Principales (PCA). PCA es utilizado para reducir la dimensionalidad de matrices de características y proyectar una nueva matriz en un espacio con nuevas dimensiones, la relevancia de las variables transformadas al nuevo subespacio será determinada por la varianza de la información obtenida. Comúnmente con este tipo de análisis las dimensiones pueden ser reducidas con alta eficacia ya que se pueden tomar unas cuantas dimensiones que puedan representar hasta el 90% de la variabilidad de los datos.

El método PCA es utilizado con frecuencia para el reconocimiento de patrones para clasificación de datos y también para la reducción de la cantidad de datos que se analizan para poder disminuir el costo computacional (Kong X., 2017).

#### - Creación de clasificadores

Para la etapa de clasificación, se utilizaron las funciones de MATLAB: *fitcsvm* y *fitcnet*. *fitcsvm*, que corresponde a la inicialización de un modelo de clasificación SVM para un conjunto de características de baja a moderada dimensionalidad (MATLAB, 2018). Se

hicieron pruebas de clasificación entrenando modelos lineales y también de base radial de clasificadores SVM.

También se generó un modelo de clasificación de red neuronal, mediante la función *fitcnet* (MATLAB, 2018), que inicializa una red de tipo *feed-forward*.

Para asegurar el correcto entrenamiento de los modelos de clasificadores implementados, se realizó una validación cruzada. Para validar los 3 modelos de clasificación utilizados (SVM lineal, SVM radial y NN) se implementó la función *crossval* con 30 iteraciones.

Para realizar la evaluación de desempeño de los modelos por medio del método de validación cruzada con K-fold de 30, únicamente se iba modificando el porcentaje de datos aislados que debía considerar el modelo para el entrenamiento. Los porcentajes de datos aislados fueron variados en un 5%, 10% y 15% de las observaciones ingresadas para la creación de los modelos SVM, para el modelo de red neuronal este parámetro no fue incluido. Con la obtención de valores de precisión o *accuracy* fue posible definir numéricamente si las predicciones realizadas por los clasificadores eran correctas y en qué porcentaje, lo cual fue considerado como el principal indicador para definir si los métodos de extracción de características fueron exitosos.

En la siguiente sección, se describen los resultados obtenidos al aplicar la metodología descrita, se incluyen tablas comparativas que con el nivel de *accuracy*, así como gráficas de espacios de características antes y después de implementar el método de análisis de componentes principales.

## Resultados obtenidos

En la Figura 9, se muestra la distribución del potencial para el sujeto 4 para ambas condiciones, conducción normal y frenado de emergencia, respectivamente. Las distribuciones para el resto de los sujetos se muestran en la Tabla 4 del Anexo I. Para cada figura mostrada, las primeras 3 distribuciones corresponden a 300 ms previos al estímulo, el estímulo es posteriormente presentado entre los tiempos 400 y 500 ms indicados por las gráficas correspondientes en las señales objetivo.

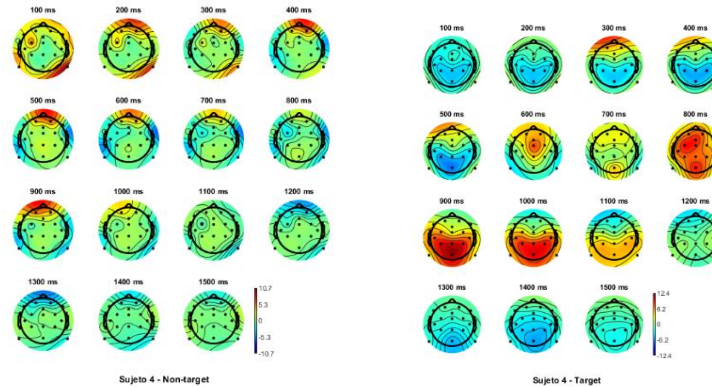


Figura 9. Distribución de potencial en ambas condiciones de manejo

Con base en las observaciones de las gráficas de distribuciones de potencial, se identificaron las zonas parietales-centrales y las frontales como las que presentan una mayor contribución al potencial identificado. También las zonas cerebrales mencionadas presentaron una mayor distinción en la aparición de potencial al comparar los eventos normales contra los eventos de emergencia en cada sujeto. Por esta razón, se seleccionaron seis canales correspondientes a los que abarcan la zona centro-parietal del cerebro; CP3, CP4, CPz, P9, P10 y POz. En la Figura 10 se muestran los canales seleccionados.




Figura 10. Mapas de localización de 20 canales con 6 canales seleccionados.

La selección de las ventanas de tiempo para lograr un correcto análisis de las señales ERP, se realizó tomando 200 muestras equivalentes a 1 segundo comenzando en el número de muestra en que ocurrió el estímulo. En la Figura 11, se muestra un ejemplo de segmentación del evento ERP en el intervalo seleccionado, así como un segmento de conducción normal donde no se presenta ningún estímulo.




Figura 11. Señal ERP con límites de ventana temporal de 1 segundo y señal de situación normal.

A continuación, se presentarán diagramas de flujo de los algoritmos implementados en MATLAB para el preprocesamiento de la señal y selección de sujetos, de acuerdo con la metodología descrita en la sección anterior. En el Anexo II se presentan los códigos creados siguiendo el proceso de cada diagrama.

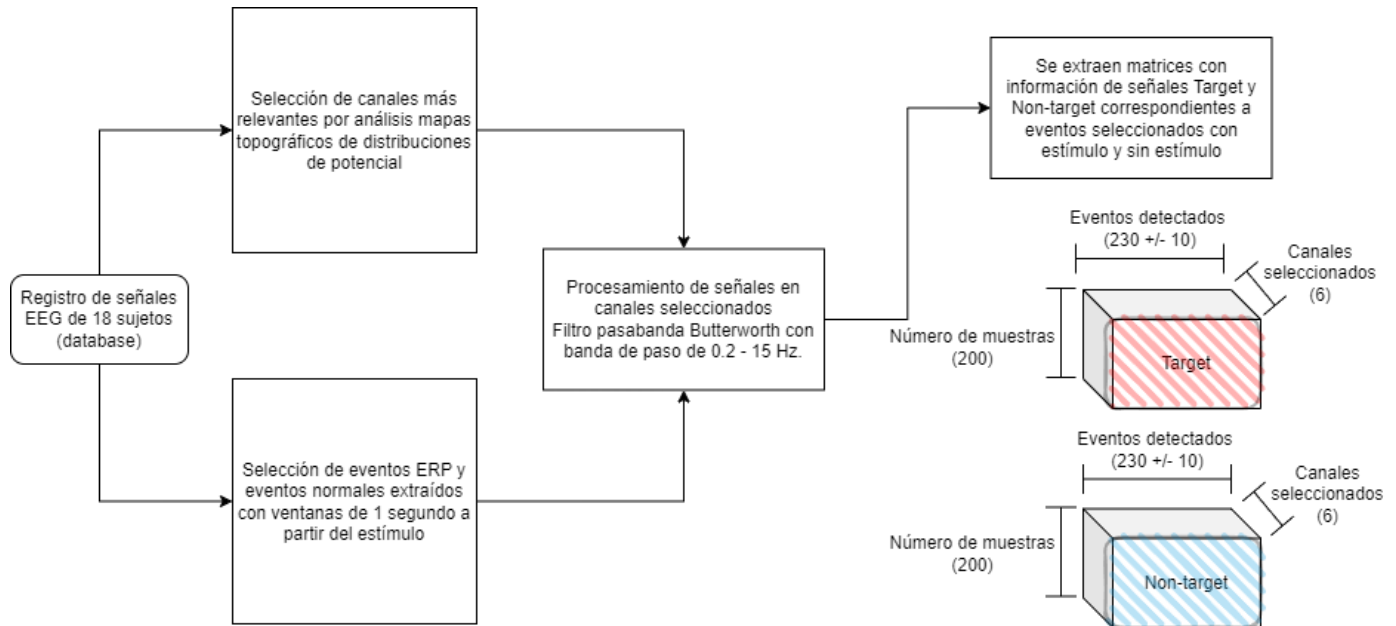


Figura 12. Diagrama de extracción de datos eventos por sujeto.

En la Figura 13, se muestra una gráfica de la distribución espaciotemporal de la señal con la ventana de tiempo de 1 segundo, además de las gráficas con mapeos de los potenciales que ocurren cada 100 ms. Se muestra con la señal promedio del sujeto 1 en la situación de emergencia, para poder relacionar visualmente cada componente del complejo ERP con la distribución de potenciales en los 20 canales.

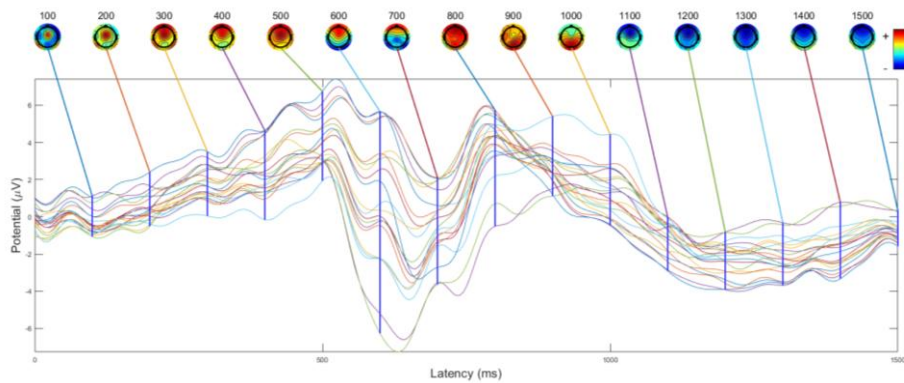


Figura 13. Distribución espaciotemporal de señal ERP Target del sujeto 1, con mapeos topográficos de potenciales cada 100 ms.

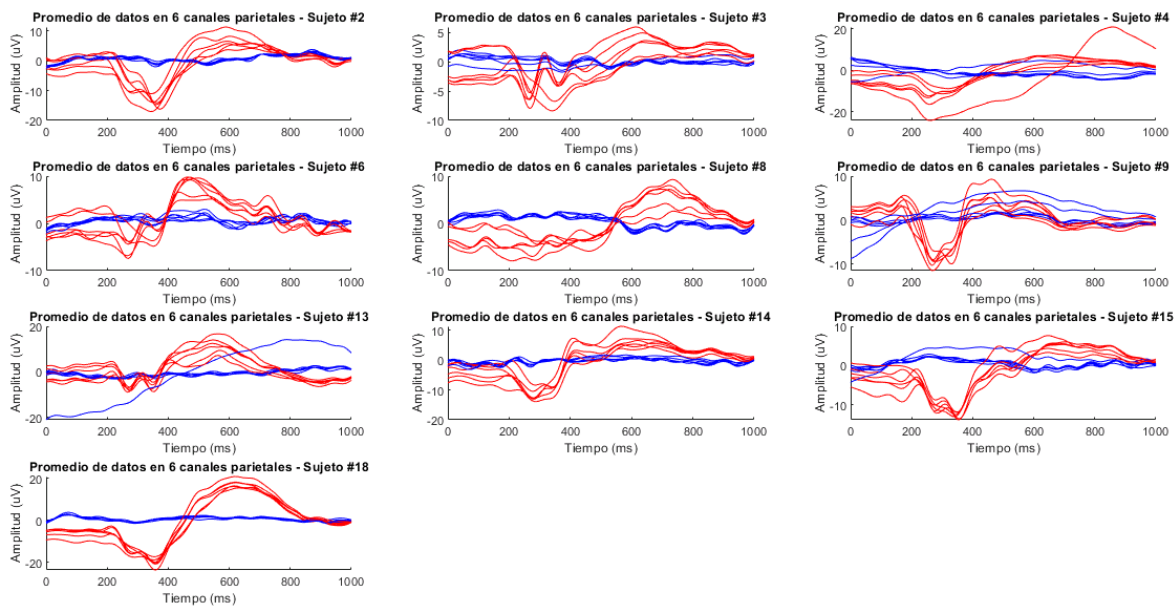


Figura 14. Señales de eventos normales y de emergencia en ventanas de 1 segundo para 10 sujetos.

La Figura 14, corresponde a los espectros de las señales de eventos normales y eventos relacionados con el estímulo indicador de emergencia, aquí se analizaron los promedios de datos de los eventos para los canales CP3, CP4, P9 y P10 con los respectivos

canales centrales incluidos (CPz y POz). En la Figura 15, se observan las gráficas promedio de eventos para 4 canales (CP3, CP4, P9 y P10) de los sujetos seleccionados. En las señales de ambas figuras se identifica el evento ERP asociado con emergencia representado con rojo, los eventos asociados con situaciones sin emergencia se presentan con azul.

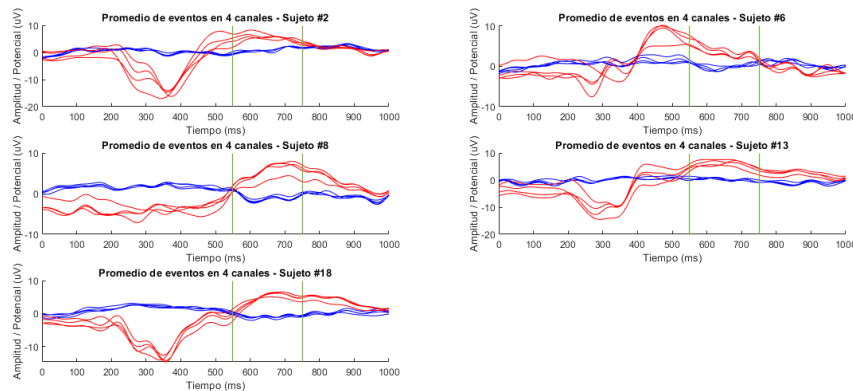


Figura 15. Señales de promedios de eventos en 4 canales, con ventana resaltada en la cual se nota mayor distinción entre datos.

El segmento en el que mejor se identificó una separación entre potenciales fue en el rango de tiempo de 550 ms (110 muestras) a 750 ms (150 muestras), este intervalo se indica con las líneas verdes. El potencial visual evocado P300 se distingue por comenzar a una latencia de 300 ms posteriores al estímulo visual presentado que, en este caso, son las luces de frenado. Esto coincide exactamente con el tiempo de inicio de los picos de los ERPs que están siendo analizados. En las gráficas se visualiza cómo incrementa el potencial a partir del número de muestra 60 que es el equivalente a 300 ms.

En la Figura 16 se muestran las gráficas de los promedios de eventos para los 5 sujetos seleccionados para el canal CP3. Como se puede observar, al colocar los límites entre la



latencia de 550 ms y 750 ms, todavía se encuentra información separable que será útil para la extracción de características para su posterior clasificación.

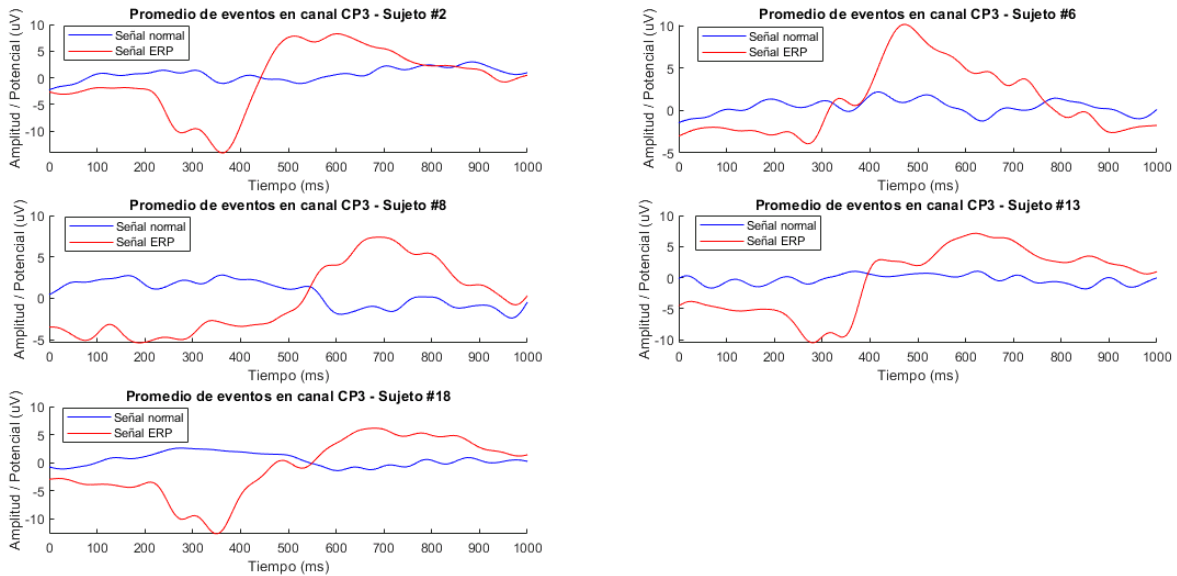


Figura 16. Señales de eventos con promedios de eventos en el canal CP3 para 5 sujetos.

Una vez obtenidas las matrices con las muestras de las señales ERP extraídas para todos los sujetos, la siguiente etapa correspondió a la implementación de algoritmos para extraer las características ya mencionadas. En el diagrama de la Figura 17, se muestra el procedimiento general que se siguió para extraer las características con el propósito de crear matrices de datos que fueran ingresadas como observaciones a los modelos de clasificación NN y SVM.

Las matrices resultantes de todas las características excepto las correspondientes a lateralización, tenían altas dimensionalidades, por lo que sólo ciertos vectores de observaciones fueron tomados en cuenta, el análisis estadístico de los valores fue realizado con la prueba de hipótesis para descartar vectores cuyas distribuciones fueran muy similares entre observaciones de eventos normales contra eventos de emergencia.

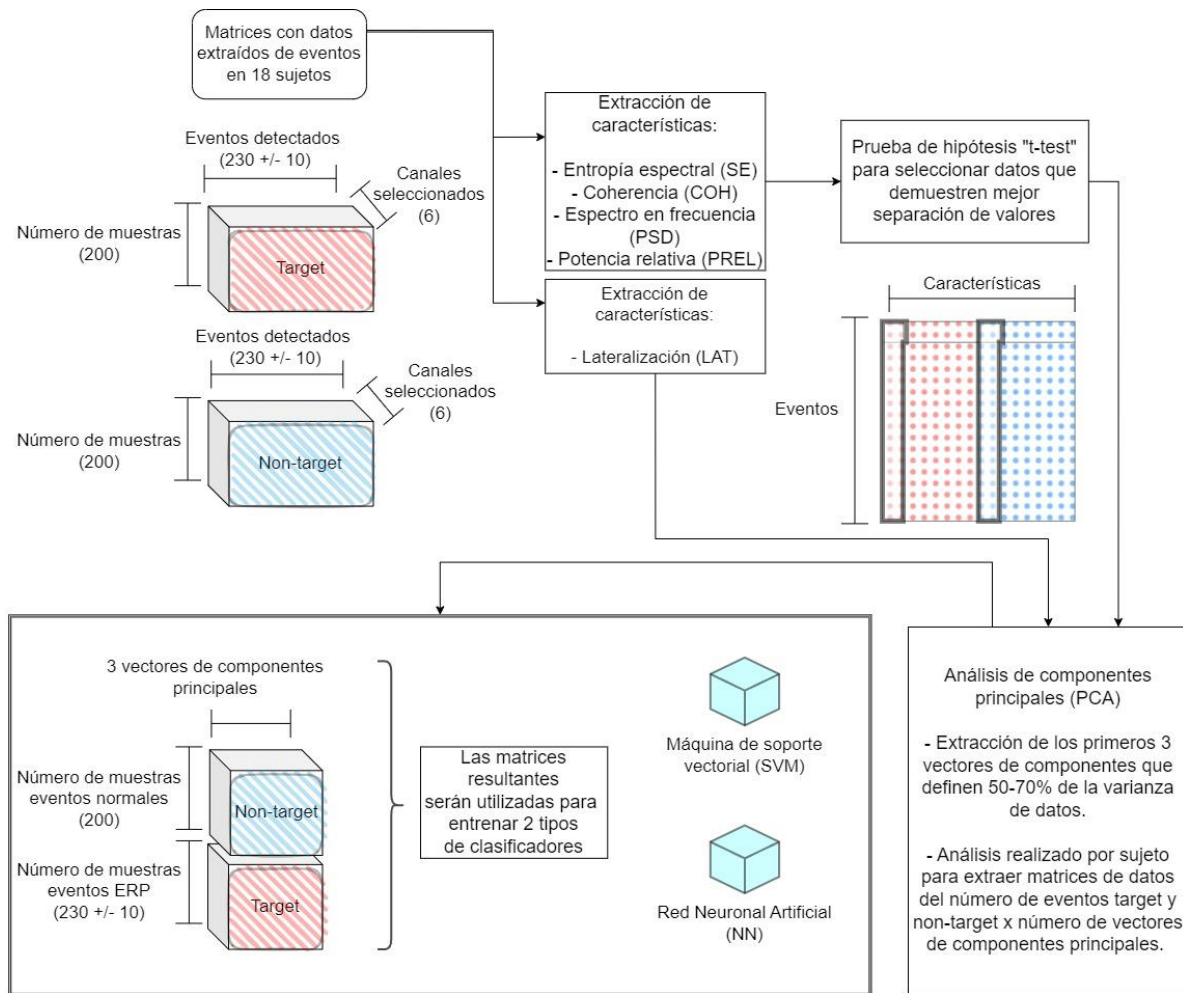


Figura 17. Diagrama de obtención de características y acomodo de datos.

## ■ Entropía espectral

Para la extracción de valores de entropía en puntos de frecuencia establecidos por la función *pentropy*, se utilizó la herramienta de estimación del periodograma de la señal con una resolución temporal de 100 ms. Las matrices resultantes se obtuvieron por cada sujeto y las dimensiones de las matrices están determinadas por  $M \times N$ , donde  $M$  corresponde al número de eventos detectados en situaciones normales para la primera mitad de filas y el número de

eventos detectados en situaciones de emergencia para la segunda mitad ( $M_{Nontarget} + M_{Target} = M$ ). La dimensión  $N$  está determinada por el número de frecuencias establecidas por la propia función, las frecuencias consideradas fueron 38. Por lo tanto, la dimensión de las matrices por sujeto,  $M \times N$ , varía en el número de filas  $M$  de acuerdo con el número de eventos detectados por sujeto ( $M_{Nontarget} = 230 \pm 10$  y  $M_{Target} = 230 \pm 10$ ) y los puntos de muestras de las frecuencias establecidos por la función de entropía utilizada ( $N = 38$ ).

Los valores de las matrices resultantes para cada sujeto se encontraban dentro de un rango de 0 a 1. Donde el valor mínimo de entropía indica variaciones menores entre las distribuciones de potencia de la señal y el valor máximo indica variaciones mayores.

#### ■ Coherencia

La obtención de valores de coherencia se realizó entre los pares de canales CP3-CP4 y P9-P10 para los eventos normales y para los eventos de emergencia.

Los resultados obtenidos indican qué tanta relación guarda las frecuencias de los pares de canales al presentarse eventos normales contra la aparición de los potenciales relacionados con la emergencia. Los valores más cercanos a 1 indican que las frecuencias de los canales se presentan con mayor similitud y, en este caso, corresponden a los eventos de emergencia.

#### ■ Espectro en frecuencia

La siguiente característica calculada fue el espectro en frecuencia de las mediciones bipolares entre los pares de electrodos CP3-CP4 y P9-P10. Mediante el análisis de los espectros mostrados en la Figura 18, fue posible observar la banda de frecuencias más

adecuada de la cual se podrían obtener características como valores de potencia relativa de la banda seleccionada.

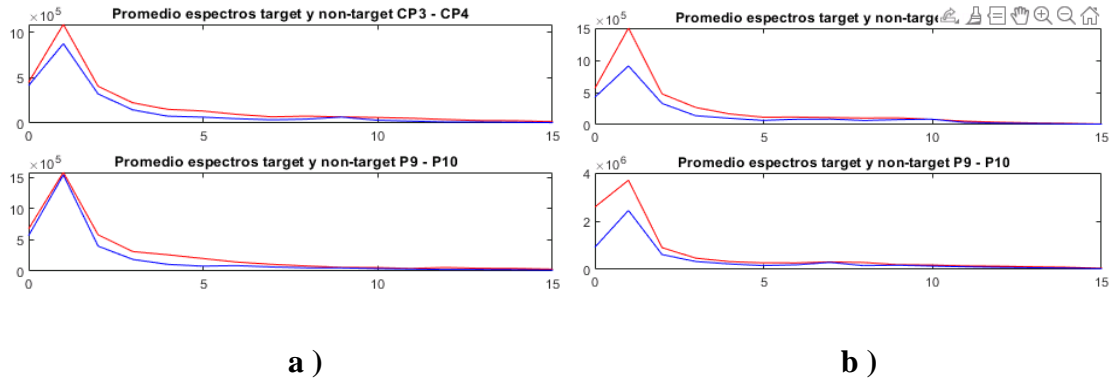


Figura 18. Espectros en frecuencia promediados para Sujetos a) 2 y b) 6.

En las gráficas mostradas en la Figura 18, se pueden observar los espectros en frecuencia promedio para los 240 eventos de las señales *Target* y los *Non-target* para los sujetos 2 y 6.

Es posible observar que entre las frecuencias 0 y 2.5 Hz aproximadamente, se muestran unos picos con densidad espectral de valores muy elevados, este fenómeno se presentó para los 6 canales en los 5 sujetos seleccionados. Esto podría corresponder a artefactos de la señal, como la respiración. Debido a esto, se decidió analizar la banda de frecuencias de 5-15 Hz para la obtención de potencia relativa de la señal.

#### ■ Potencia relativa

Con base en las observaciones del espectro en frecuencia, descritas previamente, el cálculo de la potencia relativa se realizó considerando la banda de frecuencias de 5-15Hz.

Se graficaron los datos correspondientes a los resultados de potencia relativa para la medición bipolar CP3-CP4, tal como se muestra en la Figura 19. Es posible observar que los promedios obtenidos de los datos muestran una tendencia de mayor dispersión al diferir en al menos 30 valores de unidades de potencia del espectro en frecuencia. la potencia relativa también fue calculada para el par de electrodos correspondiente a P9-P10




Figura 19. Distribuciones de frecuencias totales y promediadas en datos *Target* y *Non-target* de características de potencia relativa.

## ■ Lateralización

Para la extracción de valores de lateralización, se obtuvo un vector por cada canal correspondiente a los valores resultantes de la obtención del cociente de los valores RMS calculados para las bandas alfa y beta filtradas. Las matrices resultantes se obtuvieron por cada sujeto y las dimensiones de las matrices corresponden al número de eventos detectados en situaciones normales para la primera mitad de filas y el número de eventos detectados en situaciones de emergencia para la segunda mitad ( $M_{Non\textit{target}} + M_{\textit{Target}} = M$ ). La dimensión  $N$  quedó determinada por el número de canales, por lo que se obtuvieron 6

vectores. Los valores de las matrices resultantes para cada sujeto se encontraban dentro de un rango de 0 a 1.5.

En la figura 20 se muestran las gráficas resultantes de los datos de lateralización calculados para el sujeto 2, se observa la distribución de 240 datos para los eventos subsecuentes al estímulo (puntos rojos), así como 240 datos correspondientes a ventanas de eventos sin presencia de estímulo (puntos azules). Se puede observar que los datos no logran una separación visual muy clara para la clasificación de observaciones, por lo tanto, también se implementó la prueba de hipótesis para lograr extraer los datos que presentaran mayor significancia estadística para la clasificación. La extracción de los pares de datos que presentaran mayor significancia para la clasificación presentó una reducción de dimensiones de los vectores de datos, por medio del análisis de componentes principales se transformaron los valores de las observaciones hacia un nuevo subespacio en el cual se implementaría la clasificación, la nueva distribución de los datos se muestra en la Figura 24




Figura 20. Distribución de características de lateralización para el Sujeto 2.

### Análisis de componentes principales (PCA)

Con la implementación de la función *pca* se obtuvieron los nuevos valores definidos en un espacio de características con valores más adecuados para obtener matrices de dimensiones más reducidas y con parámetros transformados a un espacio que brinda una mejor distribución de los datos. Este método fue aplicado a las matrices de características. En el Anexo III se muestran los códigos implementados.

Como comprobación visual de la separación de los datos, las Figuras 21-25 se muestran las gráficas con las mejores separaciones obtenidas para cada matriz de características. En estos espacios 3D de características, los datos coloreados en rojo corresponden a datos *Target* y los datos coloreados en azul corresponden a los datos *Non-target*.




Figura 21. Distribución de características de entropía espectral transformadas a subespacio por análisis de componentes principales (PCA)




Figura 22. Distribución de características de densidad espectral de potencia transformadas a subespacio por análisis de componentes principales (PCA)




Figura 23. Distribución de características de potencia relativa transformadas a subespacio por análisis de componentes principales (PCA)




Figura 24. Distribución de características de lateralización transformadas a subespacio por análisis de componentes principales (PCA)






Figura 25. Distribución de características de coherencia transformadas a subespacio por análisis de componentes principales (PCA)

### Resultados de la clasificación

Finalmente, para evaluar el nivel de discriminación para las diferentes características extraídas, se realizó la clasificación tal como se describe en la Sección de Metodología, los bloques de código se presentan en el Anexo III.

Se muestran en el Anexo IV, las tablas resultantes de datos de *accuracy* al ir modificando información de la fracción de datos utilizada para la partición de información en entrenamiento y prueba para la máquina de soporte vectorial. También se presentan tablas con datos de *accuracy* obtenidos de una red neuronal con arquitectura de 3 capas de neuronas, la cual fue entrenada con validación cruzada *K-Fold* de 30 particiones.

Para la máquina de soporte vectorial también fue establecido un porcentaje de valores que son considerados por el modelo como datos que se encuentran más dispersos que la mayoría de las observaciones, el porcentaje fue definido como el 5% de los datos que se ingresan para el entrenamiento del modelo.

En las mismas tablas del Anexo IV, se resaltan en tono verde los resultados que superaron un valor mayor al 0.6 de precisión de clasificación.

#### ■ SVM de base radial

Al utilizar este clasificador, la característica que logró la mejor clasificación fue la potencia relativa, alcanzando una precisión máxima de 83.93 %.

La siguiente característica que tuvo mejor precisión de clasificación fue la densidad espectral de potencia con un máximo de 78.99 %.

#### ■ Red neuronal de 3 capas

En este caso, la característica que mejor logró distinguir también fue nuevamente la densidad espectral de potencia, alcanzando una precisión máxima de 88.98 %.

#### ■ SVM de base lineal

El algoritmo de base lineal no fue el óptimo para aplicar a los problemas de clasificación que se presentaron, los resultados de precisión no superaron 56 % para ninguna característica extraída. Por esta razón, las tablas de resultados de clasificación no son presentadas al ser resultados que no aportan información que apoye a alcanzar los objetivos del trabajo.

### **Conclusiones y discusión de resultados**

En el trabajo desarrollado se implementaron los algoritmos necesarios para la extracción de cinco características: entropía espectral, coherencia, lateralización, densidad espectral de

potencia y potencia relativa de la señal y los clasificadores SVM y ANN, a fin de evaluar y comparar el desempeño de las diferentes características en la tarea de detección de una situación de emergencia.

Con base en los resultados obtenidos, es posible decir que las métricas de coherencia, densidad espectral y potencia relativa de la señal mostraron una buena capacidad para distinguir entre estados de situaciones de emergencia y situaciones normales. Es relevante mencionar que todos los resultados obtenidos de accuracy se encuentran basados en parámetros específicos para las métricas calculadas.

Las métricas que mostraron ser menos relevantes en cuanto a los datos extraídos fueron lateralización y entropía espectral. El análisis de la distribución espacial de la actividad cerebral asociada al proceso cognitivo estudiado es de alta relevancia ya que de esta manera es posible dar una idea inicial de los canales que resultan ser de mayor relevancia.

Al comparar las métricas obtenidas es necesario considerar la selección de parámetros que afectarán a la distribución de valores de características en un subespacio, para posteriormente analizar las implicaciones que tienen los datos en los algoritmos de clasificación. Además, es necesario tomar en cuenta los parámetros de clasificación relativos al tiempo computacional que se invierte para el procesamiento e implementación de los modelos de clasificadores, así como los requisitos del acomodo de información de las señales o muestras de vectores que sean ingresados para entrenamiento y posterior validación.

A pesar de que el tiempo de la ventana para segmentar la señal fue reducido, fue útil para discriminar entre clases, utilizando características extraídas en el dominio frecuencial

de las señales. Este tiempo pudo reducirse a menos de 400 ms posteriores a la presentación del estímulo, por lo cual se motiva a buscar otra dimensión más relevante y sensible al tiempo de análisis de los datos.

En cuanto a la etapa de clasificación, se observó que la máquina de soporte vectorial de base radial es el clasificador que genera mejores resultados y la SVM de base lineal presenta el desempeño más bajo.

A pesar de lograrse obtener resultados adecuados de clasificación, sería necesario considerar evaluar más redes de electrodos entre los 64 posibles canales de EEG que presenta la base de datos, pues hay más de una zona de activación de electrodos con la aparición del potencial relacionado con evento, por ejemplo, también hay aparición de potencial en el lóbulo frontal. Si se evaluaran más redes de electrodos siguiendo el principio de conectividad cerebral, al aplicar análisis de coherencia entre las redes sería posible encontrar electrodos que puedan brindar la misma o una mayor cantidad de información relevante de los ERP evocados con el estímulo de emergencia.

En resumen, el método propuesto puede utilizarse como alternativa de extracción de características con el propósito de mantener únicamente las observaciones que presenten mayor significancia estadística y obtener subespacios de características reducidos para lograr clasificaciones más rápidas y de menor complejidad. Es posible lograr la extracción de métricas relevantes de la señal trabajando con ventanas de 1000 ms. La extracción de características separables por modelos de clasificación de baja complejidad es de utilidad para la detección de situaciones de emergencia. Los resultados indican la viabilidad y practicidad de buscar características relacionadas con densidad espectral de la señal y cálculo

de potencia relativa de la señal en aquellas bandas de frecuencias en que se observe una mejor separación de las señales.

Es importante remarcar que el análisis offline no es suficiente si se desea llevar la metodología a aplicaciones reales de BCI, pues las señales cerebrales del usuario pueden verse alteradas por diversos factores intrínsecos al sujeto, como estrés por el experimento, y extrínsecos, como ruido del entorno.

### **Referencias bibliográficas**

- A. Zhang, B. Yang and L. Huang, "Feature Extraction of EEG Signals Using Power Spectral Entropy," 2008 International Conference on BioMedical Engineering and Informatics, 2008, pp. 435-439, doi: 10.1109/BMEI.2008.254.
- Alonso-Valerdi, L. M., Arreola-Villarruel, M. A., & Argüello-García, J.. (2019). Interfaces Cerebro-Computadora: Conceptualización, Retos de Rediseño e Impacto Social. *Revista mexicana de ingeniería biomédica*, 40(3), e201912EE3. Epub 21 de septiembre de 2020. <https://doi.org/10.17488/rmib.40.3.8>
- Bhattacharya, J., & Petsche, H. (2005). Phase synchrony analysis of EEG during music perception reveals changes in functional connectivity due to musical expertise. *Signal Processing*, 85, 2161e2177.
- Bi, L., Wang, H., Teng, T., & Guan, C. (2018). A Novel Method of Emergency Situation Detection for a Brain-Controlled Vehicle by Combining EEG Signals With Surrounding Information. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(10), 1926–1934. <https://doi.org/10.1109/tnsre.2018.2868486>

- BNCI Horizon 2020. (2020). Retrieved October 27, 2022, from Bnci-horizon-2020.eu website: <http://bnci-horizon-2020.eu/> Copyright © 2022 Institute of Neural Engineering, Graz University of Technology.
- D. Xiao, Z. Mu and J. Hu, "Classification of Motor Imagery EEG Signals Based on Energy Entropy," 2009 International Symposium on Intelligent Ubiquitous Computing and Education, 2009, pp. 61-64, doi: 10.1109/IUCE.2009.57.
- Delorme A & Makeig S (2004) EEGLAB: an open-source toolbox for analysis of single-trial EEG dynamics, *Journal of Neuroscience Methods* 134:9-21. PDF.
- F. Shiman, S. H. Safavi, F. M. Vaneghi, M. Oladazimi, M. J. Safari and F. Ibrahim, "EEG feature extraction using parametric and non-parametric models," *Proceedings of 2012 IEEE-EMBS International Conference on Biomedical and Health Informatics*, 2012, pp. 66-70, doi: 10.1109/BHI.2012.6211507.
- Felisatti, A., Aagten-Murphy, D., Laubrock, J., Shaki, S., & Fischer, M. H. (2020). The Brain's Asymmetric Frequency Tuning: Asymmetric Behavior Originates from Asymmetric Perception. *Symmetry*, 12(12), 2083. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/sym12122083>
- Fontanillo Lopez, C. A., Li, G., & Zhang, D. (2020). Beyond Technologies of Electroencephalography-Based Brain-Computer Interfaces: A Systematic Review From Commercial and Ethical Aspects. *Frontiers in Neuroscience*, 14. <https://doi.org/10.3389/fnins.2020.611130>
- Fries, P. (2015). Rhythms for Cognition: Communication through Coherence. *Neuron*, 88(1), 220–235. <https://doi.org/10.1016/j.neuron.2015.09.034>

- Hassan, Hassan & Negm, Abdelazim & Zahran, Mohamed & Saavedra, Oliver. (2015). Assessment of artificial neural network for bathymetry estimation using high resolution satellite imagery in shallow lakes: case study El Burullus Lake. *International Water Technology Journal*. 5.
- Haufe, S., Treder, M. S., Gugler, M. F., Sagebaum, M., Curio, G., & Blankertz, B. (2011). EEG potentials predict upcoming emergency brakings during simulated driving. *Journal of Neural Engineering*, 8(5), 056001. <https://doi.org/10.1088/1741-2560/8/5/056001>
- He, B., Yang, L., Wilke, C., & Yuan, H. (2011). Electrophysiological imaging of brain activity and connectivity-challenges and opportunities. *Biomedical Engineering, IEEE Transactions on*, 58, 1918e1931.
- Hernández, L. G., Mozos, O. M., Ferrández, J. M., & Antelis, J. M. (2018). EEG-Based Detection of Braking Intention Under Different Car Driving Conditions. *Frontiers in Neuroinformatics*, 12. <https://doi.org/10.3389/fninf.2018.00029>
- Hsu, Chih-wei & Chang, Chih-chung & Lin, Chih-Jen. (2003). A Practical Guide to Support Vector Classification Chih-Wei Hsu, Chih-Chung Chang, and Chih-Jen Lin. University of National Taiwan, Taipei
- I. El-Naqa, Yongyi Yang, M. N. Wernick, N. P. Galatsanos and R. M. Nishikawa, "A support vector machine approach for detection of microcalcifications," in *IEEE Transactions on Medical Imaging*, vol. 21, no. 12, pp. 1552-1563, Dec. 2002, doi: 10.1109/TMI.2002.806569.
- IBM Documentation. (2021, August 17), from Ibm.com website: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>

- Islam M. K., Rastegarnia, A., & Yang, Z. (2016). Methods for artifact detection and removal from scalp EEG: A review. *Neurophysiologie Clinique/Clinical Neurophysiology*, 46(4-5), 287–305. <https://doi.org/10.1016/j.neucli.2016.07.002>
- Kaminski M., Ding, M., Truccolo, W. A., & Bressler, S. L. (2001). Evaluating causal relations in neural systems: Granger causality, directed transfer function and statistical assessment of significance. *Biological Cybernetics*, 85, 145e157.
- Kong, X., Hu, C., & Duan, Z. (2017). Principal Component Analysis Networks and Algorithms. *SpringerLink*. <https://doi.org/10.1007-978-981-10-2915-8>
- L. Dezhi, Z. Xintong and G. Xiaozhong, "Research on Multi-feature Extraction Method in EEG Signal of Motor Imagination," in 2020 International Conference on Virtual Reality and Intelligent Systems (ICVRIS), Zhangjiajie, China, 2020 pp. 462-465. doi: 10.1109/ICVRIS51417.2020.00116
- Liu H. & He, W.-X & Chen, X.-P. (2005). EEG time-series analysis using nonlinear dynamics method for sleep monitoring. 26. 174-177.
- MATLAB (2018). “fitcnet” Copyright 1988-2018 The MathWorks, Inc. <https://la.mathworks.com/help/stats/fitcnet.html>
- MATLAB (2018). “fitsvm” Copyright 1988-2018 The MathWorks, Inc. <https://la.mathworks.com/help/stats/fitsvm.html>
- MATLAB (2018). “mscohere” Copyright 1988-2018 The MathWorks, Inc. <https://la.mathworks.com/help/signal/ref/mscohere.html>
- MATLAB (2018). “pentropy” Copyright 1988-2018 The MathWorks, Inc. <https://la.mathworks.com/help/signal/ref/pentropy.html>



MATLAB (2018). “pwelch” Copyright 1988-2018 The MathWorks, Inc.  
<https://la.mathworks.com/help/signal/ref/pwelch.html>

MATLAB (2018). “ttest” Copyright 1988-2018 The MathWorks, Inc.  
<https://la.mathworks.com/help/stats/ttest.html>

MATLAB. (2022). R2022a. Natick, Massachusetts: The MathWorks Inc.

McFarland D. J., & Wolpaw, J. R. (2017). EEG-based brain–computer interfaces. *Current Opinion in Biomedical Engineering*, 4, 194–200.  
<https://doi.org/10.1016/j.cobme.2017.11.004>

Nguyen, T.-H., & Chung, W.-Y. (2019). Detection of Driver Braking Intention Using EEG Signals During Simulated Driving. *Sensors*, 19(13), 2863.  
<https://doi.org/10.3390/s19132863>

Novo C., Leticia Chacón Guitiérrez, & Barradas, A. (2010). Mapeo Electroencefalográfico y Neurofeedback.  
[https://www.researchgate.net/publication/282294960\\_Mapeo\\_Electroencefalografico\\_y\\_Neurofeedback](https://www.researchgate.net/publication/282294960_Mapeo_Electroencefalografico_y_Neurofeedback)

Nunez Paul L., and Ramesh Srinivasan, Electric Fields of the Brain: The neurophysics of EEG, 2nd edn (New York, 2006; online edn, Oxford Academic, 1 May 2009), <https://doi.org/10.1093/acprof:oso/9780195050387.001.0001>

Prabhu S. (2019). Electroencephalogram: Expanded Applications in Clinical and Nonclinical Settings. In: Paul, S. (eds) Application of Biomedical Engineering in Neuroscience. Springer, Singapore. [https://doi.org/10.1007/978-981-13-7142-4\\_11](https://doi.org/10.1007/978-981-13-7142-4_11)

- Saikia A., Paul, S. (2019). EEG Signal Processing and Its Classification for Rehabilitation Device Control. In: Paul, S. (eds) *Application of Biomedical Engineering in Neuroscience*. Springer, Singapore. [https://doi.org/10.1007/978-981-13-7142-4\\_9](https://doi.org/10.1007/978-981-13-7142-4_9)
- Sarma P., Tripathi, P., Sarma, M.P., & Sarma, K.K. (2016). Pre-processing and Feature Extraction Techniques for EEGBCI Applications- A Review of Recent Research. *ADBU Journal of Engineering Technology (AJET)*, 5.
- Shannon C. E. (1948). A Mathematical Theory of Communication. *Bell System Technical Journal*, 27(4), 623–656. <https://doi.org/10.1002/j.1538-7305.1948.tb00917>.
- Tu Y. (2019). Machine Learning. In: Hu, L., Zhang, Z. (eds) *EEG Signal Processing and Feature Extraction*. Springer, Singapore. [https://doi.org/10.1007/978-981-13-9113-2\\_15](https://doi.org/10.1007/978-981-13-9113-2_15)
- Vapnik V. N. (2022). The Nature of Statistical Learning Theory. *SpringerLink*. <https://doi.org/10.1007-978-1-4757-2440-0>
- Weston J., Watkins C et al (1999) Support vector machines for multi-class pattern recognition. ESANN proceedings - European Symposium on Artificial Neural Networks Bruges (Belgium), 21-23 April 1999, D-Facto public., ISBN 2-600049-9-X, pp. 219-22
- Wolpaw J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., & Vaughan, T. M. (2002). Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767–791. [https://doi.org/10.1016/s1388-2457\(02\)00057-3](https://doi.org/10.1016/s1388-2457(02)00057-3)
- Woodman G. F., (2014). A brief introduction to the use of event-related potentials in studies of perception and attention. *Attention, Perception & Psychophysics*, 72(8). <https://doi.org/10.3758/APP.72.8.2031>

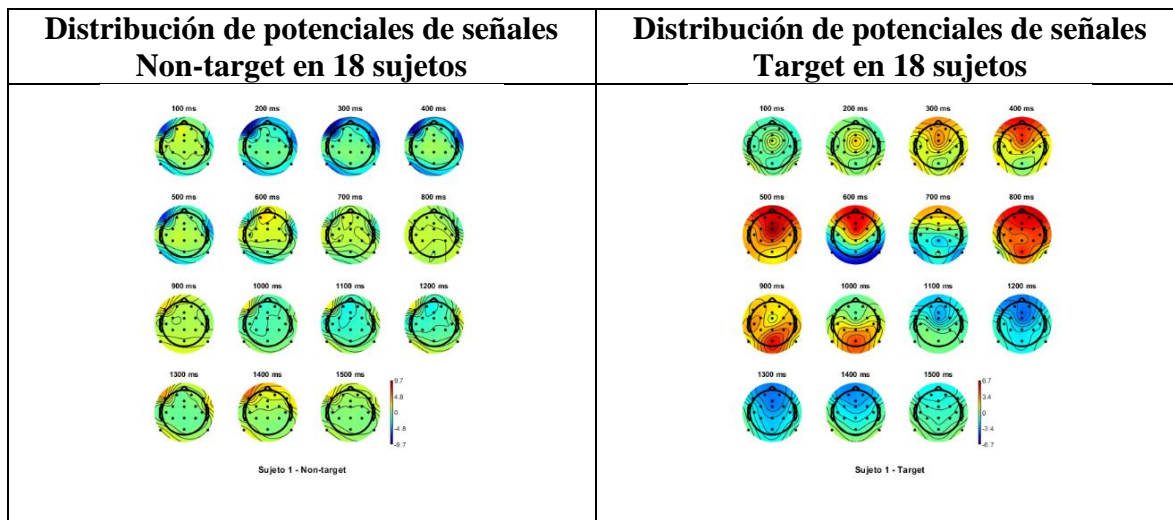
Wu H., Zhang H, Zheng C, Kong J. [Application of power spectral entropy to the noninvasive detection of focal ischemic cerebral injury]. *Sheng Wu Yi Xue Gong Cheng Xue Za Zhi*. 2003 Jun;20(2):229-32. Chinese. PMID: 12856585.

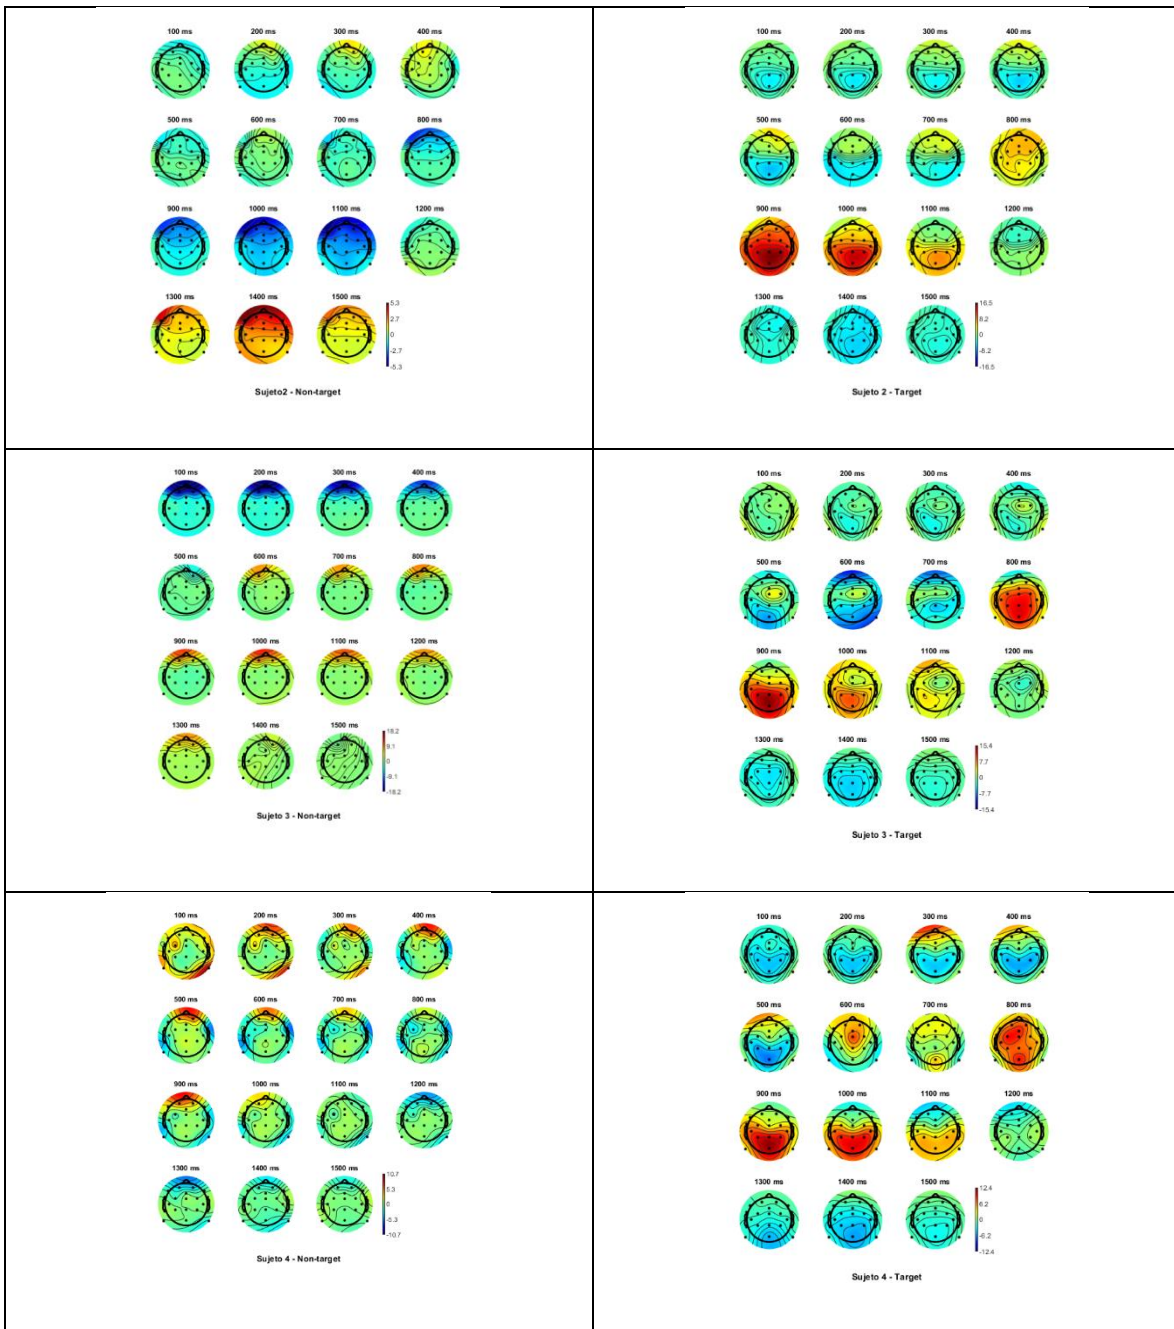
Xu J.; Zheng, H.; Wang, J.; Li, D.; Fang, X. Recognition of EEG Signal Motor Imagery Intention Based on Deep Multi-View Feature Learning. *Sensors* 2020, 20, 3496. <https://doi.org/10.3390/s20123496>

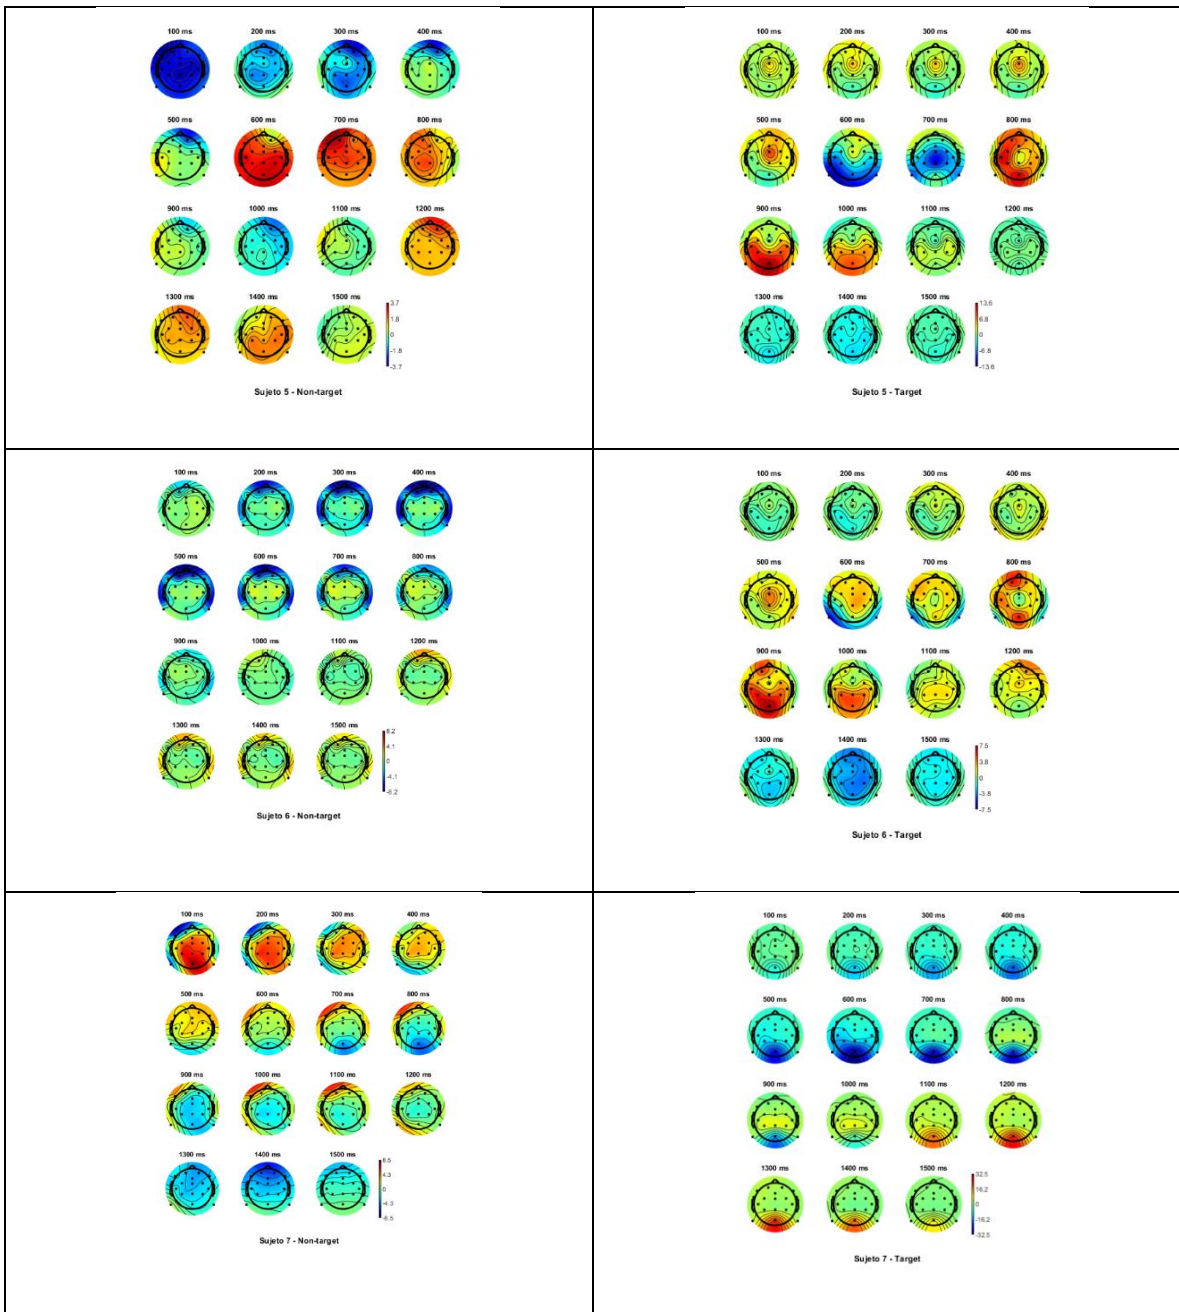
## Anexos

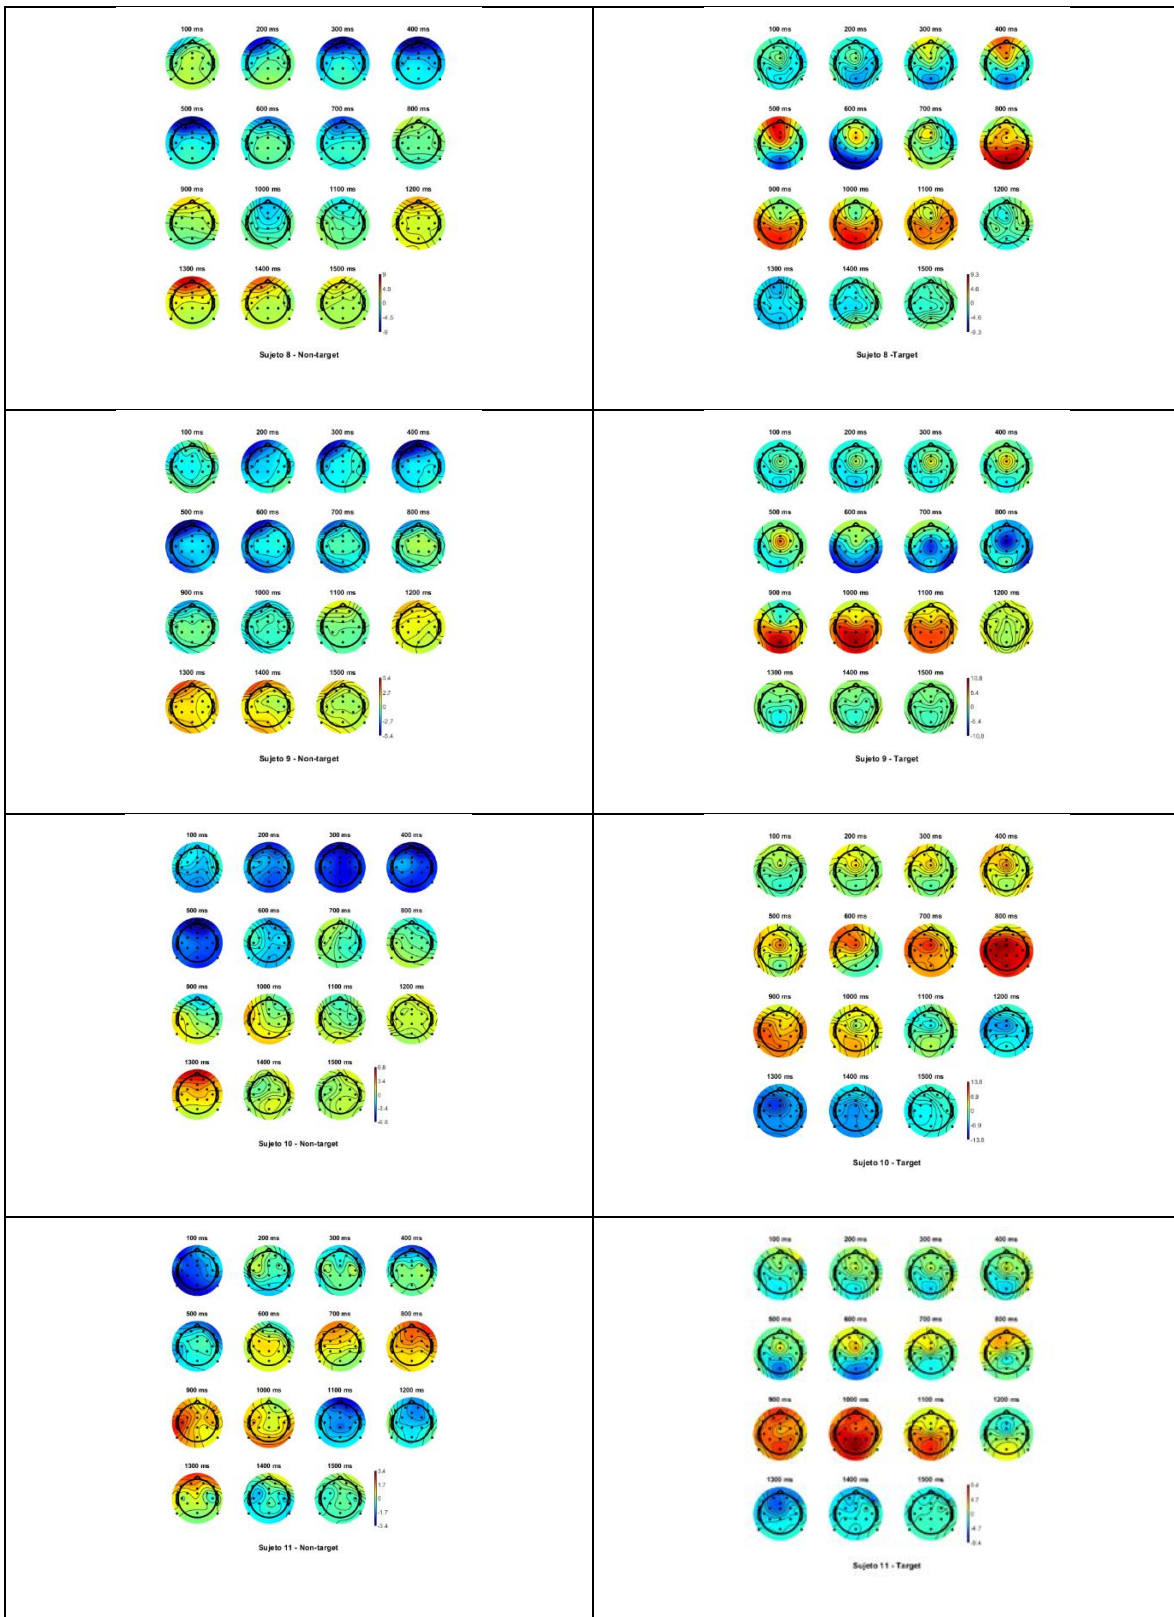
### Anexo I

Tabla 4. Figuras con gráficas de mapeos topográficos de potenciales presentados cada 100 ms.

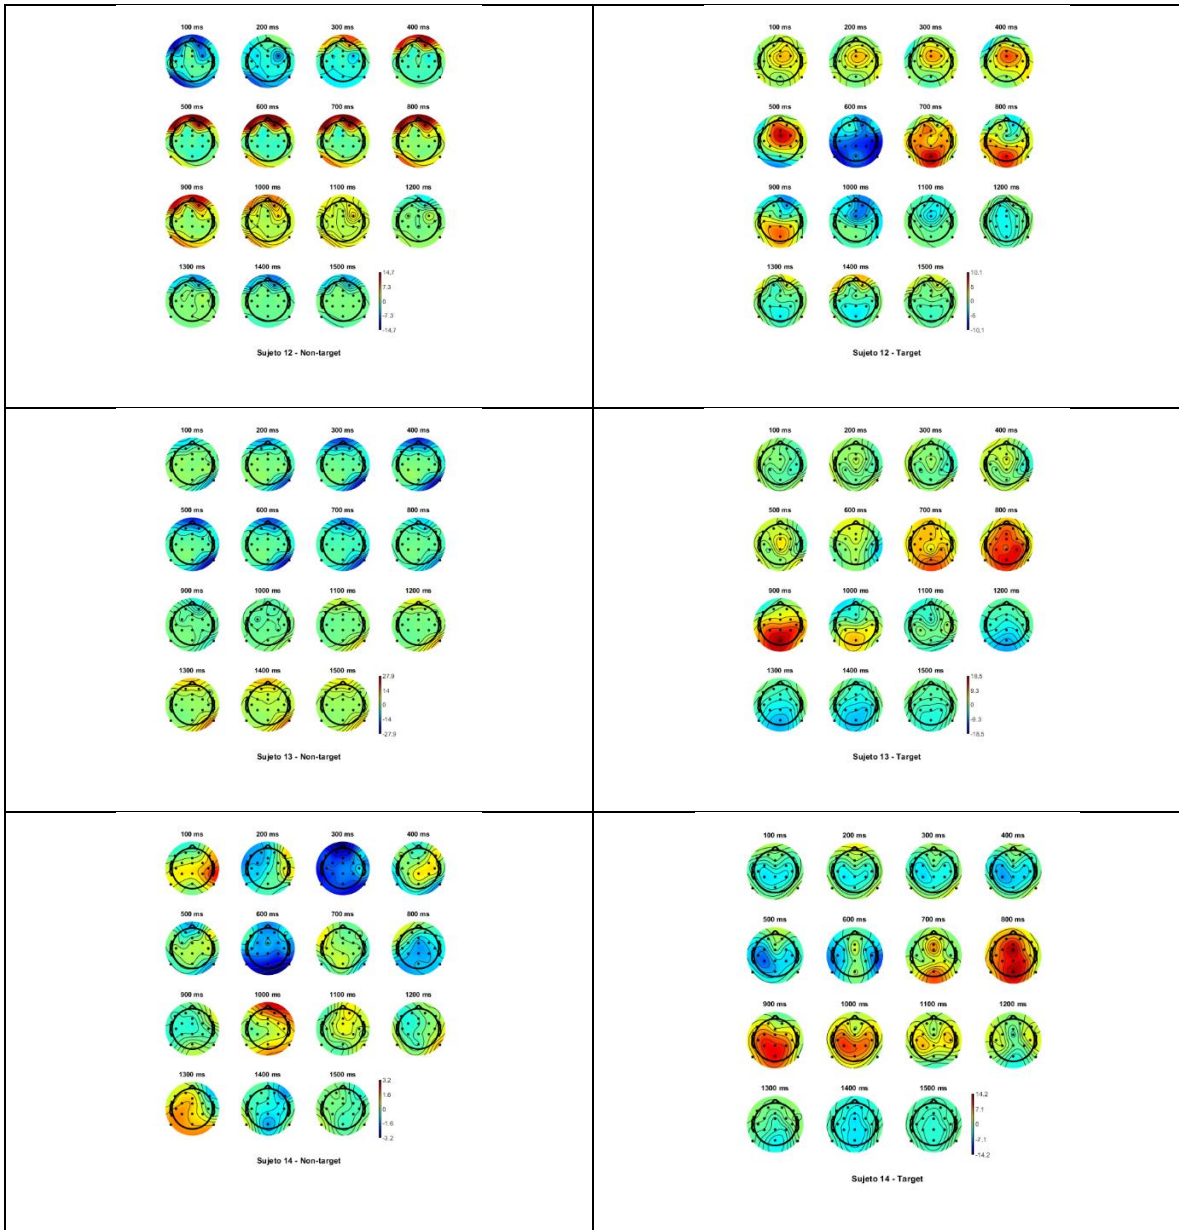


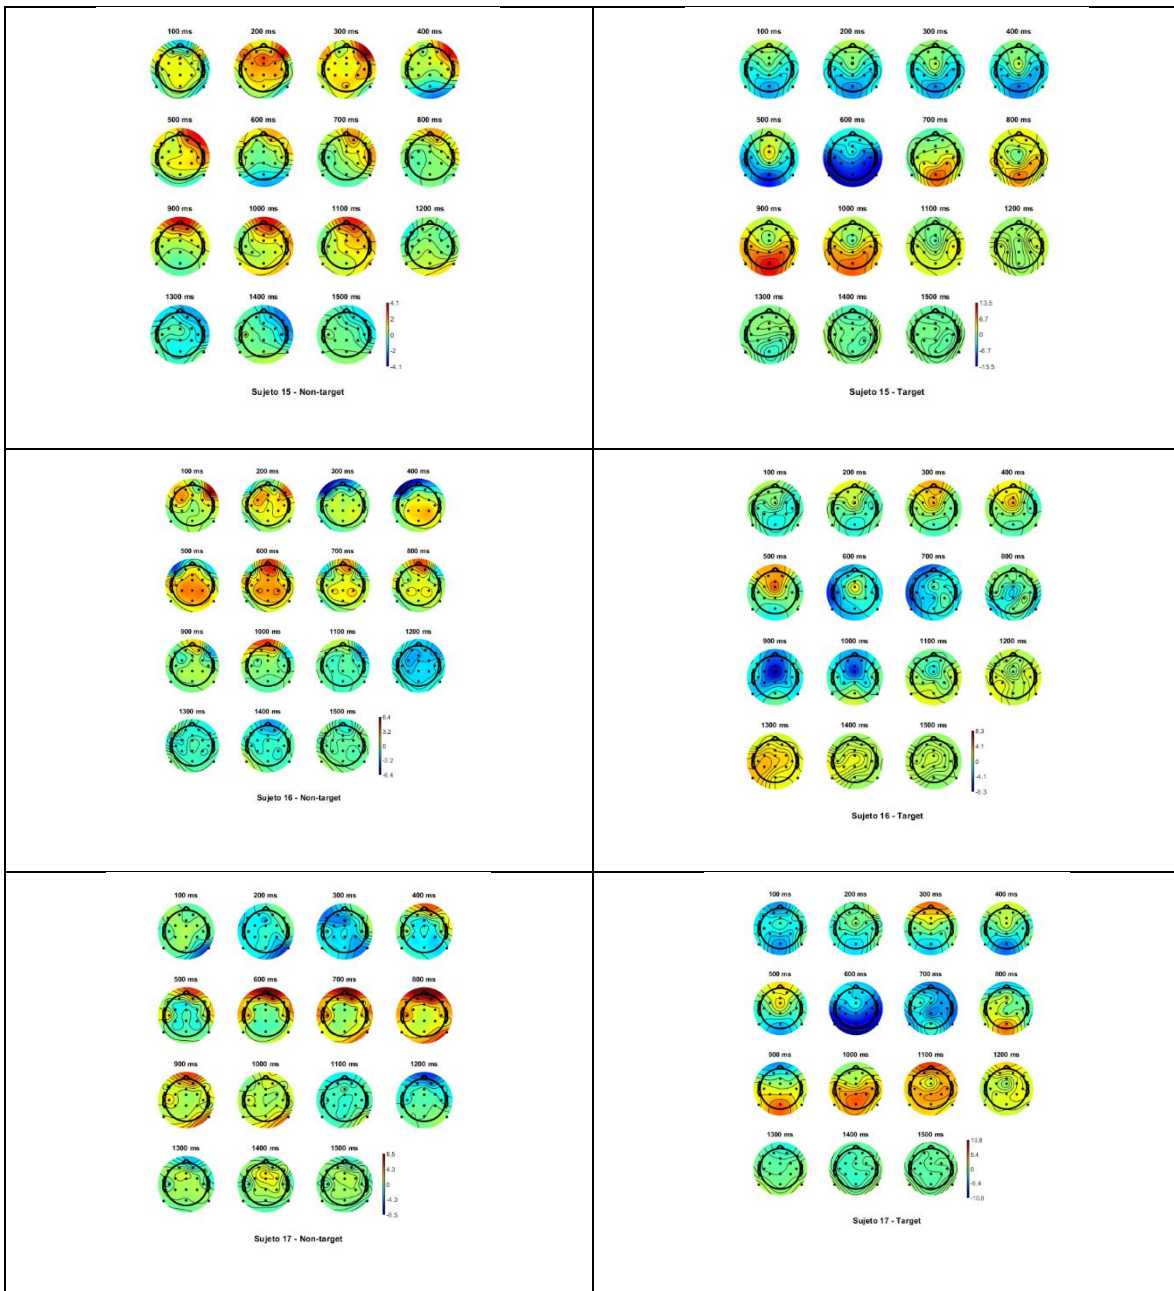




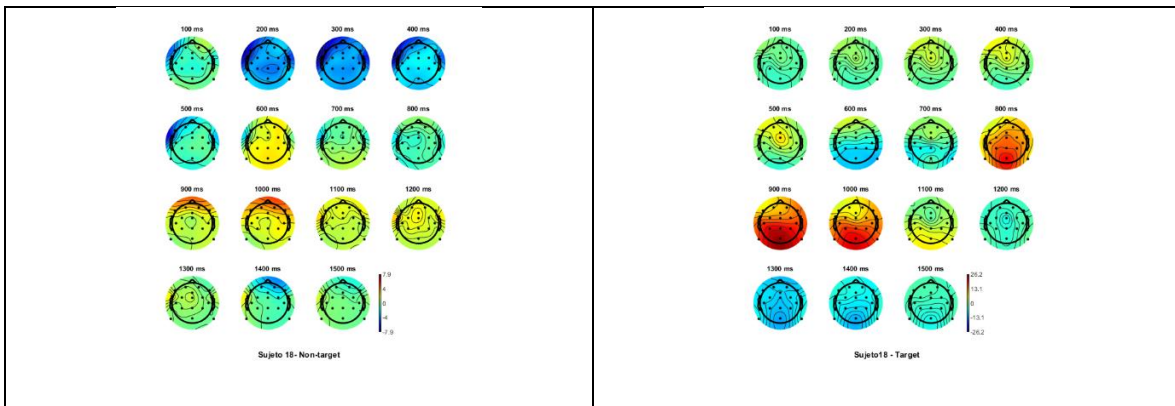












## Anexo II

```

1 % Para reconstruir toda la información en carpeta de 5 sujetos
2 files = dir('*.mat');
3 num = length(files);
4 EBD = cell(1,num);
5 figure
6
7 for k = 1:5
8     EBD{1,k} = importdata(files(k).name);
9     cnt = EBD{1,k}.cnt;
10    mnt = EBD{1,k}.mnt;
11    mrk = EBD{1,k}.mrk;
12
13    % Obtención de datos
14    res=mrk.y(2,:); % selección de datos
15
16    % se define frecuencia de muestreo y unidad de tiempo en milisegundos
17    fs=200;
18    ms=1e-3;
19
20    % se guardan los índices de las posiciones en que se encuentran los eventos
21    [-,index]=find(res==1);
22    index=index(1:end-1);
23
24    % se define vector con marcas de tiempo en milisegundos
25    ev=mrk.time; % mrk.time -- 1x704
26
27    % vector con marcas de tiempo en ms de eventos encontrados
28    event=ev(index); % event -- número de eventos encontrados
29
30    % Selección de canales de acuerdo con variables de cnt.clab
31    data=transpose(cnt.x);
32
33    data = data([36 38 40 43 53 56],:); % 6 canales parietales - CP3, CP2, PO2, CP4, P9, P10
34    % data == 6 canales X 1619967 muestras --> ~135 mins de registro a 200 Hz de fs
35
36    % Ventana de evento definida por número de muestras -- 1 segundo
37    w1_NT = 700; % 3500 ms después del estímulo (inicio de segmento NT)
38    w2_NT = 300; % 1000 ms después de inicio segmento NT
39
40    for i=1:length(index)
41        SJT_NT(:,i)=data(:,floor(event(i)*ms+w1_NT):floor(event(i)*ms+w1_NT+w2_NT));
42    end
43
44    % Ventana de evento definida por núm. de muestras -- 1.0 segundo
45    w1_T = 0; % 0 ms antes de estímulo
46    w2_T = 200; % 1000 ms después de estímulo
47
48    % s = 2 (car_brake); se seleccionarán segmentos Target
49    for i=1:length(index) % se obtienen datos para todos los eventos encontrados
50        SJT_T(:,i)=data(:,floor(event(i)*ms+w1_T):floor(event(i)*ms+w2_T));
51    end
52
53    [ch,m,tr]=size(SJT_NT); % ch=canal, m=muestras, tr=trial/evento
54
55    % Filtrado para Target y NonTarget (0.2-15 Hz)
56    for i=1:tr
57        for j=1:ch
58            [b,a]=butter(5,[0.2 15]/(fs/2));
59            SJT_T(j,:,i)=filtfilt(b,a,SJT_T(j,:,i));
60            SJT_NT(j,:,i)=filtfilt(b,a,SJT_NT(j,:,i));
61        end
62    end
63    data_SJT_T{1,k}=SJT_T;
64    data_SJT_NT{1,k}=SJT_NT;
65 end

```

Figura 26. Código de extracción de ventanas de muestras con eventos normales y ERPs de cada sujeto.

## Entropía espectral (SE)

```

sjt=5;

for k = 1:sjt

    % Se extraen dimensiones con datos Target
    [ch,m,tr]=size(data_SJT_T(1,k));
    fs=200;

    % Obtención de vectores de Entropía Espectral
    for i=1:ch
        for j=1:tr
            [pT,fr,tt]=pspectrum(data_SJT_T(1,k)(i,:,j),fs,'TimeResolution',0.1,'spectrogram');
            SE_T(i,:,j)=pentropy(pT,fr,tt);
            [pF,ff,tF]=pspectrum(data_SJT_NT(1,k)(i,:,j),fs,'TimeResolution',0.1,'spectrogram');
            SE_NT(i,:,j)=pentropy(pF,ff,tF);
        end
    end

    for i=1:ch
        SE.SE_T(k,i) = squeeze(SE_T(i,:,j));
        SE.SE_NT(k,i) = squeeze(SE_NT(i,:,j));
    end

end
end

```

Figura 27. Obtención de datos de entropía espectral para señales *Target* y *Non-target* de cada sujeto.

```

Espectro en frecuencia (PSD) y Potencia Relativa (PT)

1  sjt=5; PT_chars=cell(1,sjt);
2  for k=1:sjt
3      % Se extraen dimensiones con datos Target
4      [ch,m,tr]=size(data_SJT_T(1,k)); fs=200;
5      % Obtención de mediciones bipolares entre 4 canales para T y NT
6      dif1T = squeeze(data_SJT_T(1,k)(1,:,j)) - squeeze(data_SJT_T(1,k)(3,:,j)); % CP3 - CP4
7      dif1NT = squeeze(data_SJT_NT(1,k)(1,:,j)) - squeeze(data_SJT_NT(1,k)(3,:,j)); % CP3 - CP4
8      dif2T = squeeze(data_SJT_T(1,k)(4,:,j)) - squeeze(data_SJT_T(1,k)(5,:,j)); % P9 - P10
9      dif2NT = squeeze(data_SJT_NT(1,k)(4,:,j)) - squeeze(data_SJT_NT(1,k)(5,:,j)); % P9 - P10
10     cn1T = squeeze(data_SJT_T(1,k)(2,:,j));
11     cn1NT = squeeze(data_SJT_NT(1,k)(2,:,j));
12     cn2T = squeeze(data_SJT_T(1,k)(6,:,j));
13     cn2NT = squeeze(data_SJT_NT(1,k)(6,:,j));
14
15     for flg=1:tr
16         % Espectro en frecuencia para eventos de emergencia (f,v)
17         x = dif1T(:,flg);
18         nfft = length(x);
19         Y = fft(x,nfft);
20         Y = Y(1:floor(nfft/2));
21         V1(:,flg) = abs(Y).^2;
22         f = (0:nfft/2-1)*fs/nfft;
23         % Espectro en frecuencia para eventos de situación normal (f,F)
24         x=dif1NT(:,flg);
25         nfft=length(x);
26         Y=fft(x,nfft);
27         Y = Y(1:floor(nfft/2));
28         F1(:,flg) = abs(Y).^2;
29         f = (0:nfft/2-1)*fs/nfft;
30     end
31     for flg=1:tr
32         % Espectro en frecuencia para eventos de emergencia (f,v)
33         x = dif2T(:,flg);
34         nfft = length(x);
35         Y = fft(x,nfft);
36         Y = Y(1:floor(nfft/2));
37         V2(:,flg) = abs(Y).^2;
38         f = (0:nfft/2-1)*fs/nfft;
39         % Espectro en frecuencia para eventos de situación normal (f,F)
40         x = dif2NT(:,flg);
41         nfft=length(x);
42         Y=fft(x,nfft);
43         Y = Y(1:floor(nfft/2));
44         F2(:,flg) = abs(Y).^2;
45         f = (0:nfft/2-1)*fs/nfft;
46     end

```

Figura 28. Obtención de datos de espectro en frecuencia y potencia total para señales *Target* y *Non-target* de cada sujeto (Parte 1).

```

47     for flg=1:tr
48         % Espectro en frecuencia para eventos de emergencia (f,V)
49         X = cn1T(:,flg);
50         nfft = length(X);
51         Y = fft(X,nfft);
52         Y = Y(1:floor(nfft/2));
53         V3(:,flg) = abs(Y).^2;
54         f = (0:nfft/2-1)*fs/nfft;
55         % Espectro en frecuencia para eventos de situación normal (f,F)
56         X = cn1NT(:,flg);
57         nfft = length(X);
58         Y = fft(X,nfft);
59         Y = Y(1:floor(nfft/2));
60         F3(:,flg) = abs(Y).^2;
61         f = (0:nfft/2-1)*fs/nfft;
62     end
63     for flg=1:tr
64         % Espectro en frecuencia para eventos de emergencia (f,V)
65         X = cn2T(:,flg);
66         nfft = length(X);
67         Y = fft(X,nfft);
68         Y = Y(1:floor(nfft/2));
69         V4(:,flg) = abs(Y).^2;
70         f = (0:nfft/2-1)*fs/nfft;
71         % Espectro en frecuencia para eventos de situación normal (f,F)
72         X = cn2NT(:,flg);
73         nfft = length(X);
74         Y = fft(X,nfft);
75         Y = Y(1:floor(nfft/2));
76         F4(:,flg) = abs(Y).^2;
77         f = (0:nfft/2-1)*fs/nfft;
78     end
79     % Acomodar resultados Coherencia en matriz con datos Target y NonTarget
80     NT = [F2;F1;F3;F4];
81     T = [V2;V1;V3;V4];
82     PSD.PSD_T(1,k) = NT;
83     PSD.PSD_NT(1,k) = T;

```

Figura 29. Obtención de datos de espectro en frecuencia para señales *Target* y *Non-target* de cada sujeto (Parte 2).

```

96     % Potencia total de banda de frecuencia de 5 a 15 Hz
97
98     lg=size(NT,2);
99     for flg=1:lg
100
101         [pXXT1(:,flg),f] = pwelch(V1(:,flg),100,[],5:1:14,fs);
102         [pXXNT1(:,flg),f2] = pwelch(F1(:,flg),100,[],5:1:14,fs);
103         pt1_T(flgs,:) = 10*log10(mean(pXXT1(:,flg),2));
104         pt1_NT(flgs,:) = 10*log10(mean(pXXNT1(:,flg),2));
105         PT_chars(1,k)=[pt1_NT;pt1_T];
106
107         [pXXT2(:,flg),f] = pwelch(V2(:,flg),100,[],5:1:14,fs);
108         [pXXNT2(:,flg),f2] = pwelch(F2(:,flg),100,[],5:1:14,fs);
109         pt2_T(flgs,:) = 10*log10(mean(pXXT2(:,flg),2));
110         pt2_NT(flgs,:) = 10*log10(mean(pXXNT2(:,flg),2));
111         PT_chars(1,k)=[pt2_NT;pt2_T];
112
113         [pXXT3(:,flg),f] = pwelch(V3(:,flg),100,[],5:1:14,fs);
114         [pXXNT3(:,flg),f2] = pwelch(F3(:,flg),100,[],5:1:14,fs);
115         pt3_T(flgs,:) = 10*log10(mean(pXXT3(:,flg),2));
116         pt3_NT(flgs,:) = 10*log10(mean(pXXNT3(:,flg),2));
117         PT_chars(1,k)=[pt3_NT;pt3_T];
118
119         [pXXT4(:,flg),f] = pwelch(V4(:,flg),100,[],5:1:14,fs);
120         [pXXNT4(:,flg),f2] = pwelch(F4(:,flg),100,[],5:1:14,fs);
121         pt4_T(flgs,:) = 10*log10(mean(pXXT4(:,flg),2));
122         pt4_NT(flgs,:) = 10*log10(mean(pXXNT4(:,flg),2));
123         PT_chars(1,k)=[pt4_NT;pt4_T];
124
125     end
126
127     end
128
129
130     % Graficar características Potencia total en banda de 5-15 Hz
131     figure;plot(f,10*log10(pXXT1),'r');hold on;plot(f2,10*log10(pXXNT1),'b')
132     figure;plot(f,10*log10(mean(pXXT1,2)),'r');hold on;plot(f2,10*log10(mean(pXXNT1,2)),'b')

```

Figura 30. Obtención de datos de potencia total para señales *Target* y *Non-target* de cada sujeto (Parte 2).

```

Lateralización (LAT)
1  sjt=5;
2  ch=6;
3
4  lat.res(sjt,ch)=[];
5  for k = 1:sjt
6
7      % Se extraen dimensiones con datos Target
8      [ch,m,tr]=size(data_SJT_T{1,k});
9      fs=200;
10
11     for j=1:tr
12         for i=1:ch
13             [b,a]=butter(5,[8 12]/(fs/2));
14             T_a(i,:,j)=filtfilt(b,a,data_SJT_T{1,k}(i,:,j));
15             [d,c]=butter(5,[12 15]/(fs/2));
16             T_b(i,:,j)=filtfilt(d,c,data_SJT_T{1,k}(i,:,j));
17         end
18     end
19
20     for j=1:tr
21         for i=1:ch
22             [f,e]=butter(5,[8 12]/(fs/2));
23             NT_a(i,:,j)=filtfilt(f,e,data_SJT_NT{1,k}(i,:,j));
24             [h,g]=butter(5,[12 15]/(fs/2));
25             NT_b(i,:,j)=filtfilt(h,g,data_SJT_NT{1,k}(i,:,j));
26         end
27     end
28
29     for i=1:ch
30         T = squeeze(rms(T_b(i,:, :)))./squeeze(rms(T_a(i,:, :)));
31         NT = squeeze(rms(NT_b(i,:, :)))./squeeze(rms(NT_a(i,:, :)));
32         lat.res(k,i)=[lat.res(k,i);NT;T];
33     end
34
35 end

Creación de matrices de características para unir canales de sujetos
36 n_sjt=1:1:5; % selección de sujetos
37 n_SJT=size(n_sjt,2);
38 LAT_chars = cell(1,n_SJT);
39
40 for rep=1:n_SJT
41     for j=1:ch
42         LAT_chars{1,rep}=[LAT_chars{1,rep},lat.res{n_sjt(:),rep},j]];
43     end
44 end

```

Figura 31. Obtención de datos de lateralización.

```

Coherencia (COH)
1  sjt=5;
2  fs = 200;
3
4  COH_chars=cell(1,5);
5
6
7  for k=1:5
8
9      CP3_T = squeeze(data_SJT_T{1,k}(1,:, :)); % CP3 T
10     CP3_NT = squeeze(data_SJT_NT{1,k}(1,:, :)); % CP3 NT
11     CP4_T = squeeze(data_SJT_T{1,k}(3,:, :)); % CP4 T
12     CP4_NT = squeeze(data_SJT_NT{1,k}(3,:, :)); % CP4 NT
13
14     P9_T = squeeze(data_SJT_T{1,k}(4,:, :)); % P9 T
15     P9_NT = squeeze(data_SJT_NT{1,k}(4,:, :)); % P9 NT
16     P10_T = squeeze(data_SJT_T{1,k}(5,:, :)); % P10 T
17     P10_NT = squeeze(data_SJT_NT{1,k}(5,:, :)); % P10 NT
18
19     [C1_T,f] = mscohere(CP3_T,CP4_T,[],[],5:0.5:15,fs);
20     [C2_T,~] = mscohere(P9_T,P10_T,[],[],5:0.5:15,fs);
21     [C1_NT,~] = mscohere(CP3_NT,CP4_NT,[],[],5:0.5:15,fs);
22     [C2_NT,~] = mscohere(P9_NT,P10_NT,[],[],5:0.5:15,fs);
23
24     COH_chars{1,k}=[COH_chars{1,k};C1_NT',C2_NT';C1_T',C2_T'];
25
26     COH.CO_H_NT{1,k} = C1_NT;C2_NT;
27     COH.CO_H_T{1,k} = C1_T;C2_T;
28
29 end

```

Figura 32. Obtención de coherencia en pares de canales CP3-CP4 y P9-P10.

```

t-test para COH
30  sz=size(COH_COH_T(1,1),1);
31
32  for k=1:sjt
33
34      tbl=[];
35      for vls=1:sz
36          [h,p]=ttest(COH_COH_T(1,k)(vls,:),COH_COH_NT(1,k)(vls,:));
37          tbl = [tbl;h,p,COH_COH_NT(1,k)(vls,:),COH_COH_T(1,k)(vls,:)];
38      end
39
40      TBL_COH.chans(1,k) = tbl;
41      TBL_COH.chsort(1,k) = sortrows(TBL_COH.chans(1,k),2,'descend');
42      TBL_COH.find(1,k) = find(TBL_COH.chsort(1,k){:},1==1);
43
44      TBL_COH.res(1,1:sz)=[];
45
46      for fig = 1:size(TBL_COH.find(1,k),1)
47          new = TBL_COH.chans(1,k)(TBL_COH.find(1,k)(fig),:);
48          TBL_COH.res(1,k) = [TBL_COH.res(1,k);new(1,3:end)];
49      end
50  end
51
52  for k=1:sjt
53      TBL_COH.res(1,k)=transpose(TBL_COH.res(1,k));
54  end

```

Figura 33. T-test para selección de datos coherencia

```

t-test para SE
25  sjt=5;
26  ch=6;
27  sz=size(SE_SE_T(1,1),1);
28
29  for k=1:sjt
30
31      tbl=[];
32
33      for j=1:ch
34          for vls=1:sz
35              [h,p]=ttest(SE_SE_T(k,j)(vls,:),SE_SE_NT(k,j)(vls,:));
36              tbl = [tbl;h,p,SE_SE_NT(k,j)(vls,:),SE_SE_T(k,j)(vls,:)];
37          end
38      end
39
40      | i= [1:sz;sz+1:sz*2;sz*2+1:sz*3;sz*3+1:sz*4;sz*4+1:sz*5;sz*5+1:sz*6]; % para 6 canales
41
42      for j=1:ch
43          TBL_SE.chans(k,j) = tbl(i(j,:),:);
44          TBL_SE.chsort(k,j) = sortrows(TBL_SE.chans(k,j),2,'descend');
45          TBL_SE.find(k,j) = find(TBL_SE.chsort(k,j){:},1==1);
46          TBL_SE.res(sjt,ch)=[];
47
48          for fig = 1:size(TBL_SE.find(k,j),1)
49              new = TBL_SE.chans(k,j)(TBL_SE.find(k,j)(fig),:);
50              TBL_SE.res(k,j) = [TBL_SE.res(k,j);new(1,3:end)];
51          end
52      end
53      TBL_SE.res(k,j)=transpose(TBL_SE.res(k,j));
54  end
55

```

Figura 34. T-test para selección de datos entropía espectral

```

t-test para PSD
133  sjt=5;
134  sz=size(PSD_PSD_T(1,1),1);
135
136  for k=1:sjt
137
138      tbl=[];
139
140      for vls=1:sz
141          [h,p]=ttest(PSD_PSD_T(1,k)(vls,:),PSD_PSD_NT(1,k)(vls,:));
142          tbl = [tbl;h,p,PSD_PSD_NT(1,k)(vls,:),PSD_PSD_T(1,k)(vls,:)];
143      end
144
145      TBL_PSD.chans(1,k) = tbl;
146      TBL_PSD.chsort(1,k) = sortrows(TBL_PSD.chans(1,k),2,'descend');
147      TBL_PSD.find(1,k) = find(TBL_PSD.chsort(1,k){:},1==1);
148
149      TBL_PSD.res(1,1:sz)=[];
150
151      for fig = 1:size(TBL_PSD.find(1,k),1)
152          new = TBL_PSD.chans(1,k)(TBL_PSD.find(1,k)(fig),:);
153          TBL_PSD.res(1,k) = [TBL_PSD.res(1,k);new(1,3:end)];
154      end
155  end
156
157  for k=1:sjt
158      TBL_PSD.res(1,k)=transpose(TBL_PSD.res(1,k));
159  end

```

Figura 35. T-test para selección de datos de densidad espectral de potencia

## PCA para SE

```

67 scoresT=[]; scoresNT=[]; SE_chars_PCA=cell(1,n_SJT);
68
69 for k=1:n_SJT
70     [coeffSE_NT,scoreSE_NT,~,~,expNT]=pca(SE_chars{1,k}(1:240,:));
71     [coeffSE_T,scoreSE_T,~,~,expT]=pca(SE_chars{1,k}(241:480,:));
72     SE_chars_PCA{1,k}=[scoreSE_NT(:,1:3);scoreSE_T(:,1:3)];
73
74     figure
75     plot3(SE_chars_PCA{1,k}(1:240,1),SE_chars_PCA{1,k}(1:240,2),SE_chars_PCA{1,k}(1:240,3),'b');
76     hold on
77     plot3(SE_chars_PCA{1,k}(241:480,1),SE_chars_PCA{1,k}(241:480,2),SE_chars_PCA{1,k}(241:480,3),'r');
78 end

```

## PCA para PSD

```

167 PSD_chars_PCA=cell(1,sjt);
168
169 for k=1:sjt
170     [coeffPSD_NT,scorePSD_NT,~,~,expNT]=pca(PSD_chars{1,k}(1:240,:));
171     [coeffPSD_T,scorePSD_T,~,~,expT]=pca(PSD_chars{1,k}(241:480,:));
172     PSD_chars_PCA{1,k}=[scorePSD_NT(:,1:3);scorePSD_T(:,1:3)];
173
174     figure
175     plot3(PSD_chars_PCA{1,k}(1:240,1),PSD_chars_PCA{1,k}(1:240,2),PSD_chars_PCA{1,k}(1:240,3),'b');
176     hold on
177     plot3(PSD_chars_PCA{1,k}(241:480,1),PSD_chars_PCA{1,k}(241:480,2),PSD_chars_PCA{1,k}(241:480,3),'r');
178 end

```

## PCA para PT

```

179 PT_chars_PCA=cell(1,sjt);
180
181 for k=1:sjt
182     [coeffPT_NT,scorePT_NT,~,~,expNT]=pca(PT_chars{1,k}(1:240,:));
183     [coeffPT_T,scorePT_T,~,~,expT]=pca(PT_chars{1,k}(241:480,:));
184     PT_chars_PCA{1,k}=[scorePT_NT(:,1:3);scorePT_T(:,1:3)];
185
186     figure
187     plot3(PT_chars_PCA{1,k}(1:240,1),PT_chars_PCA{1,k}(1:240,2),PT_chars_PCA{1,k}(1:240,3),'b');
188     hold on
189     plot3(PT_chars_PCA{1,k}(241:480,1),PT_chars_PCA{1,k}(241:480,2),PT_chars_PCA{1,k}(241:480,3),'r');
190 end

```

## PCA para LAT

```

45 LAT_chars_PCA=cell(1,sjt);
46
47 for k=1:sjt
48     [coeffLAT_NT,scoreLAT_NT,~,~,expNT]=pca(LAT_chars{1,k}(1:240,:));
49     [coeffLAT_T,scoreLAT_T,~,~,expT]=pca(LAT_chars{1,k}(241:480,:));
50     LAT_chars_PCA{1,k}=[scoreLAT_NT(:,1:3);scoreLAT_T(:,1:3)];
51
52     figure
53     plot3(LAT_chars_PCA{1,k}(1:240,1),LAT_chars_PCA{1,k}(1:240,2),LAT_chars_PCA{1,k}(1:240,3),'b');
54     hold on
55     plot3(LAT_chars_PCA{1,k}(241:480,1),LAT_chars_PCA{1,k}(241:480,2),LAT_chars_PCA{1,k}(241:480,3),'r');
56 end

```

## PCA para COH

```

62 COH_chars_PCA=cell(1,sjt);
63
64 for k=1:sjt
65     [coeffCOH_NT,scoreCOH_NT,~,~,expNT]=pca(COH_chars{1,k}(1:240,:));
66     [coeffCOH_T,scoreCOH_T,~,~,expT]=pca(COH_chars{1,k}(241:480,:));
67     COH_chars_PCA{1,k}=[scoreCOH_NT(:,1:3);scoreCOH_T(:,1:3)];
68
69     figure
70     plot3(COH_chars_PCA{1,k}(1:240,1),COH_chars_PCA{1,k}(1:240,2),COH_chars_PCA{1,k}(1:240,3),'b');
71     hold on
72     plot3(COH_chars_PCA{1,k}(241:480,1),COH_chars_PCA{1,k}(241:480,2),COH_chars_PCA{1,k}(241:480,3),'r');
73 end

```

Figura 36. Bloques de código para obtención de matrices de características transformadas a un subespacio nuevo con método PCA.

## Anexo III

```

1      %% SVM %%
2
3      for k = 1:5
4
5          HOut = 0.1;
6          OutFrac = 0.05;
7
8          M = PT_chars{1,k}; % matriz con datos características
9
10
11         sz = size(M,1);
12         lbls = [zeros(size(M,1)/2,1);ones(size(M,1)/2,1)];
13         tbl = [M,lbls];
14         lim=size(tbl,2);
15
16         ind = randperm(sz);
17         tbl_rnd = [];
18
19         for i = 1:sz
20             rnd_data = M(ind(i),:);
21             rnd_lbls = lbls(ind(i),1);
22             tbl_rnd = [tbl_rnd;rnd_data,rnd_lbls];
23         end
24
25         X = tbl_rnd(:,1:lim-1);
26         Y = tbl_rnd(:,lim);
27
28         % separar datos para entrenamiento y reserva
29         rng('default') % For reproducibility
30         n = length(Y);
31         part = cvpartition(n,'Holdout',HOut); % Nonstratified partition
32         idx = training(part);
33         XTrain = X(idx,:);
34         YTrain = Y(idx);
35         idxNew = test(part);
36         XTest = X(idxNew,:);
37         YTest = Y(idxNew);
38
39         % Mdl = fitsvm(XTrain,YTrain,'Standardize',true);
40         Mdl = fitsvm(XTrain,YTrain,'Standardize',true,'KernelFunction','RBF','KernelScale','auto','OutlierFraction',OutFrac);
41
42         trainError = resubLoss(Mdl);
43         trainAccuracy = 1-trainError;
44
45         cvMdl = crossval(Mdl,'kFold',30); % Performs 30-fold cross-validation
46         cvtrainError = kfoldLoss(cvMdl);
47         ACCtSVMop = 1-cvtrainError;
48
49         error = loss(Mdl,XTest,YTest);
50         ACCSVMop = 1 - error;
51
52         [ACCSVM(:,k)]=ACCSVMop;
53
54     end

```

Figura 37. Código implementado para clasificadores SVM de base lineal y base radial.

```

55     %% NN %%
56
57     for k = 1:5
58
59         HOut = 0.5;
60         lay=[3 2 2];
61
62         M = PT_chars{1,k}; % matriz con datos características
63
64
65         sz = size(M,1);
66         lbls = [zeros(size(M,1)/2,1);ones(size(M,1)/2,1)];
67         tbl = [M, lbls];
68         lim=size(tbl,2);
69
70         ind = randperm(sz);
71         tbl_rnd = [];
72
73         for i = 1:sz
74             rnd_data = M(ind(i),:);
75             rnd_lbls = lbls(ind(i),1);
76             tbl_rnd = [tbl_rnd;rnd_data,rnd_lbls];
77         end
78
79         X = tbl_rnd(:,1:lim-1);
80         Y = tbl_rnd(:,lim);
81
82         % separar datos para entrenamiento y reserva
83         rng('default') % For reproducibility
84         n = length(Y);
85         part = cvpartition(n,'Holdout',HOut); % Nonstratified partition
86         idx = training(part);
87         XTrain = X(idx,:);
88         YTrain = Y(idx);
89         idxNew = test(part);
90         XTest = X(idxNew,:);
91         YTest = Y(idxNew);
92
93         Mdl = fitcnet(XTrain,YTrain,"LayerSizes",lay,'Standardize',true); % NN
94
95         trainError = resubLoss(Mdl);
96         trainAccuracy = 1-trainError;
97
98         cvMdl = crossval(Mdl,'kfold',30); % Performs 30-fold cross-validation
99         cvtrainError = kfoldLoss(cvMdl);
100        ACCtNNop = 1-cvtrainError;
101
102        error = loss(Mdl,XTest,YTest);
103        ACCNNop = 1 - error;
104
105        [ACCNN(:,k)]=ACCNNop;
106
107    end

```

Figura 38. Código implementado para clasificadores NN multicapa.



## Anexo IV. Resultados clasificación

SVM de base radial entrenada considerando 5% de datos aislados y K-fold = 30 para validación cruzada																		
Sujetos																		
Métrica utilizada	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16	S17	S18
LAT	0.51523	0.58395	0.44995	0.55738	0.5029	0.45833	0.5625	0.5	0.58333	0.5625	0.5625	0.54167	0.45833	0.45833	0.54167	0.45833	0.41667	0.5
SE	0.64754	0.64929	0.53267	0.67592	0.6063	0.54167	0.60417	0.5625	0.52083	0.54167	0.60417	0.5625	0.5	0.5	0.6875	0.58333	0.75	0.79167
COH	0.48696	0.67328	0.64599	0.55738	0.69559	0.5	0.375	0.66667	0.77083	0.5	0.54167	0.58333	0.79167	0.70833	0.6875	0.58333	0.75	0.79167
PSD	0.62586	0.56242	0.7899	0.50433	0.42579	0.70833	0.6875	0.5	0.625	0.77083	0.64583	0.64583	0.60417	0.75	0.70833	0.64583	0.625	0.625
PTREL	0.81993	0.81058	0.73201	0.47902	0.83494	0.83333	0.6875	0.64583	0.79167	0.79167	0.70833	0.6875	0.75	0.64583	0.54167	0.70833	0.64583	0.64583
MEDIA	0.6191	0.6559	0.6301	0.55481	0.6131	0.60833	0.58333	0.575	0.65833	0.63333	0.6125	0.60417	0.62083	0.6125	0.63333	0.59583	0.6375	0.67083
VAR	0.01736	0.00955	0.01953	0.00574	0.02582	0.02483	0.01649	0.00621	0.01402	0.01879	0.00447	0.00369	0.02179	0.01641	0.00707	0.00859	0.01858	0.01528

SVM de base radial entrenada considerando 10% de datos aislados y K-fold = 30 para validación cruzada																		
Sujetos																		
Métrica utilizada	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16	S17	S18
LAT	0.46911	0.43045	0.534	0.57605	0.48054	0.42991	0.6294	0.55662	0.46848	0.59563	0.52284	0.51655	0.55295	0.49296	0.452	0.52457	0.46196	0.54905
SE	0.56524	0.65923	0.54196	0.60184	0.53501	0.60147	0.65583	0.62378	0.51483	0.59129	0.59323	0.5328	0.50075	0.60364	0.64587	0.56291	0.67014	0.8393
COH	0.58583	0.7107	0.6519	0.47324	0.68728	0.57398	0.42774	0.75049	0.81092	0.52045	0.53603	0.62161	0.79901	0.5978	0.64587	0.56291	0.67014	0.8393
PSD	0.72302	0.62725	0.74672	0.571	0.59389	0.69328	0.6777	0.65105	0.61488	0.7427	0.66212	0.55489	0.63831	0.726	0.70413	0.78014	0.77258	0.73057
SSPTREL	0.80103	0.77667	0.77043	0.57234	0.67964	0.80463	0.7925	0.71649	0.77475	0.75026	0.65583	0.72233	0.69807	0.69223	0.67425	0.67598	0.72645	0.67231
MEDIA	0.62885	0.64086	0.649	0.55889	0.59527	0.62065	0.63664	0.65968	0.63677	0.64006	0.59401	0.58964	0.63782	0.62253	0.62443	0.6213	0.66025	0.7261
VAR	0.01399	0.01362	0.0098	0.00196	0.00648	0.01561	0.01401	0.00469	0.01861	0.00827	0.00338	0.00568	0.01112	0.00666	0.0079	0.00888	0.0113	0.01198

SVM de base radial entrenada considerando 15% de datos aislados y K-fold = 30 para validación cruzada																		
Sujetos																		
Métrica utilizada	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16	S17	S18
LAT	0.55695	0.54809	0.51896	0.55992	0.49527	0.48102	0.55549	0.48539	0.49228	0.63037	0.55883	0.48895	0.48435	0.47205	0.50041	0.5171	0.51481	0.55361
SE	0.52702	0.62008	0.56991	0.5508	0.59575	0.57843	0.62182	0.58552	0.58844	0.59115	0.53483	0.56591	0.56112	0.57864	0.50041	0.5171	0.51481	0.55361
COH	0.56869	0.69376	0.67338	0.54036	0.65634	0.59053	0.47518	0.65415	0.74593	0.51398	0.47538	0.62995	0.74343	0.62307	0.68877	0.56425	0.68544	0.80309
PSD	0.72964	0.63499	0.72669	0.5055	0.55642	0.61159	0.56466	0.59345	0.61202	0.7234	0.58031	0.63892	0.66771	0.69587	0.65457	0.71339	0.73446	0.66583
PTREL	0.77175	0.78665	0.77777	0.66495	0.72332	0.73613	0.81372	0.68273	0.74426	0.71652	0.70963	0.66416	0.68586	0.69587	0.65248	0.71297	0.70358	0.67563
MEDIA	0.63081	0.65671	0.65334	0.56431	0.60542	0.59954	0.60617	0.60025	0.63659	0.63508	0.5718	0.59758	0.62849	0.6131	0.59933	0.60496	0.63062	0.65035
VAR	0.01243	0.00797	0.01157	0.00359	0.00778	0.00834	0.01619	0.00579	0.01182	0.00776	0.00748	0.005	0.01084	0.00872	0.00836	0.01013	0.01148	0.01073

NN con arquitectura 3-2-2 entrenada con K-fold = 30 para validación cruzada																		
Sujetos																		
Métrica utilizada	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16	S17	S18
LAT	0.52606	0.52437	0.49707	0.48477	0.59915	0.68979	0.51643	0.48299	0.5402	0.55489	0.56707	0.4194	0.51063	0.4194	0.47526	0.51314	0.56262	0.59605
SE	0.54956	0.622	0.51176	0.60508	0.58333	0.49581	0.61188	0.61776	0.64778	0.49831	0.51345	0.56235	0.64612	0.61403	0.58311	0.6152	0.61251	0.77036
COH	0.60527	0.63619	0.6598	0.51292	0.58333	0.64315	0.394	0.6379	0.68618	0.41163	0.50757	0.56548	0.75797	0.61964	0.58311	0.48593	0.61251	0.77036
PSD	0.73386	0.64565	0.79834	0.45097	0.62302	0.79706	0.69752	0.66023	0.77909	0.76169	0.52281	0.52029	0.53498	0.59857	0.61848	0.67762	0.77522	0.73792
PT	0.77007	0.77953	0.75746	0.72307	0.70833	0.59362	0.76448	0.68555	0.69081	0.62427	0.78799	0.606	0.69731	0.82389	0.63014	0.66141	0.78149	0.72208
MEDIA	0.63696	0.64155	0.64489	0.55536	0.61943	0.64389	0.59686	0.61689	0.66881	0.57016	0.57978	0.53471	0.6294	0.61511	0.57802	0.59066	0.66887	0.71935
VAR	0.01201	0.0083	0.019	0.01207	0.00273	0.01251	0.02152	0.00624	0.00748	0.01753	0.01409	0.00507	0.01111	0.02055	0.00374	0.00754	0.01041	0.00519