



Estudio Comparativo de Métodos para el Reconocimiento de Potenciales Relacionados a Eventos P300 para una Interfaz Cerebro-Computador

Cristian Felipe Blanco Díaz

Facultad de Ingeniería Mecánica, Electrónica y Biomédica
Programa de Ingeniería Biomédica
Universidad Antonio Nariño
Bogotá, Colombia
2020

Estudio Comparativo de Métodos para el Reconocimiento de Potenciales Relacionados a Eventos P300 para una Interfaz Cerebro-Computador

Cristian Felipe Blanco Díaz

Trabajo Integral de Grado presentado como requisito para optar al título de:
Ingeniero Biomédico

Director:
Ing. Andrés F. Ruiz Olaya PhD

Universidad Antonio Nariño
Facultad de Ingeniería Mecánica, Electrónica y Biomédica
Programa de Ingeniería Biomédica
Bogotá, Colombia
2020

Nota de Aceptación

Firma del presidente del Jurado

Firma del Jurado 1

Firma del Jurado 2

Bogotá D.C. _____

A mi pasado, a ese niño que creció escuchando hablar de los más grandes: Newton, Einstein, Euler, Fourier, Tesla, Pasteur, Descartes y otros más que generaron en él, el sueño de seguir sus pasos, el sueño de dejar su huella en el mundo, el sueño de ser la inspiración de alguien más.

Puede que todavía me falte mucho para ser grande, pero jamás voy a dejar de intentar serlo.

Agradecimientos

Inicialmente a Dios, a la vida y al destino por permitirme estar donde estoy, por regalarme la oportunidad de iniciar y finalizar mi carrera de manera exitosa y por todas las bendiciones que he recibido durante mi vida.

A mi madre, por ser el motor de mi esfuerzo y brindarme su apoyo en todas las decisiones que he tomado a lo largo de mi vida. Porque a pesar de los contratiempos me ha enseñado a no rendirme en el primer golpe.

A mi abuela, por su cariño, sus bendiciones y sabios consejos que me han permitido ser constante en mi camino.

A Alexander, por representar la figura paterna que no logré tener y el apoyo incondicional en los últimos años.

A mi abuelo, porque después de 10 años en el cielo, sigue dándome lecciones de vida. A mis tíos, tías, padrinos, madrinas, primas y demás integrantes de mi familia por creer en mi.

A mi tutor, el Ing. Andrés Ruiz, quien estuvo ahí para afrontar las dificultades en el desarrollo de este y de otros proyectos, además del conocimiento transmitido para mi crecimiento personal y profesional.

Al Ing. Sebastián Jaramillo, por creer en mí desde un principio, por sus consejos que me han permitido potenciarme aun más. A los demás integrantes de la facultad, que contribuyeron en mis enseñanzas dentro y fuera del salón, para ser mejor persona y un buen ingeniero.

Por último, quiero agradecer a mis compañeros y colegas, aquellos que están, aquellos que se fueron, los que vendrán y los que nunca volvieron, por estar en momentos de risas, lágrimas, ira y porque de cada uno aprendí algo que me motivó a cada día ser mejor.

Resumen

En los últimos años, las Interfaces Cerebro-Computador(BCI) han sido altamente estudiadas, debido a que permiten interactuar con el entorno sin necesidad de usar el sistema nervioso periférico. Por lo que, su aplicación en el campo de la ingeniería de rehabilitación, ha sido muy útil.

Sin embargo, la traducción de la intención del usuario a través de Electroencefalografía todavía sigue siendo un reto para la comunidad científica, por lo que es necesario la estimulación que permita evocar respuestas en patrones que el sistema pueda reconocer.

Un experimento altamente usado corresponde al paradigma Oddball, que a través de estimulación visual, permite evocar una deflexión positiva en la corteza parieto-central a los 300 ms cuando al sujeto de pruebas le llama la atención un estímulo específico entre una estimulación aleatoria, conocido como potencial P300. El P300 tiene una problemática en su reconocimiento que consiste en la baja relación señal a ruido, por lo que las técnicas de extracción de esta señal son motivo de interés.

En el presente trabajo, se realiza un estudio comparativo entre cinco métodos de reconocimiento P300. dos métodos estándar reportados en la literatura: Mean-Amplitude-LDA(MA-LDA) y Stepwise-LDA(SWLDA), y tres nuevos basados en el análisis de correlación canónica(CCA): MA+CCA-LDA ,CCA con Regresión Logística Regularizada y CCA con Perceptrón Multicapa (CCA-MLP). Los métodos se validaron en una base de datos disponible, que consistió en un sistema BCI-P300 implementado en un deletreador o Speller. Usando como métricas de evaluación:el porcentaje de clasificación y el costo computacional.

También se elaboró un protocolo de medición en personas sanas para implementar el sistema BCI-P300 Speller en tiempo real, en el laboratorio de simulación de la Universidad Antonio Nariño, utilizando el dispositivo de adquisición de EEG g.Nautilus-32 PRO y el software público BCI2000.

Palabras clave: Interfaz Cerebro-Computador, Electroencefalografía, Potencial Relacionado a Eventos, P300, Análisis de Correlación Canónica.

Abstract

In recent years, the Brain Computer Interfaces(BCI) have been highly studied, due to they allow to interact with the environment without the requirement to use the peripheral nervous system. Consequently, The appliaction of this, has been very useful in the rehabilitation engineering.

However, the traslation of the user's intent through of Electroencephalography(EEG) is still a challenge for the scientific community, consequently, the stimulation that allow to evoke responses in patterns form, for that the system can recognizes them, is necessary.

An experiment highly used corresponding to the Oddball paradigm, that through of visual stimulus, allow to evoke a positive deflection in the parieto-central cortex to the 300 ms, when the subject is interested in a specific stimuli between aleatory stimulation, known as P300 potential. The P300 have a problematic in his recognition that consist in a low signal to noise ratio, this generate that the extraction techniques be reason of interest.

In the present work, a comparative study between five P300-recognition methods is performed: two standard methods reported in literature: Mean-Amplitude-LDA(MA-LDA) and Stepwise-LDA(SWLDA), and three novel methods based in the Canonical Correlation Analysis(CCA): MA+CCA-LDA, CCA with Regularizad Logistic Regression and CCA with Multilayer Perceptron(MLP). The methods were validated in a available dataset, that consisted in a BCI-P300 system implemented in a Speller. Using as evaluation metrics: the classification percentage and the computational cost.

Also a measurement protocol in healthy people was developed, to implement the BCI-P300 Speller in real time, at the simulation Lab of the Universidad Antonio Nariño, using the device of EEG acquisition g.Nautilus-32 PRO and the public software BCI 2000

Keywords: Brain-Computer Interface, Electroencephalography, Event-Related Potential, P300, Canonical Correlation Analysis.

Tabla de contenidos

Agradecimientos	9
Resumen	11
Abstract	13
Lista de Figuras	19
Lista de Tablas	19
1 Introducción	21
1.1 Planteamiento del Problema	24
1.2 Justificación	25
1.3 Objetivos	26
1.3.1 Objetivo general	26
1.3.2 Objetivos específicos	26
1.4 Estado del Arte	27
2 Marco Teórico	31
2.1 Interfaz Cerebro-Computador	31
2.1.1 Adquisición de señales	31
2.1.2 Análisis de la señal EEG para un sistema BCI	33
2.1.3 Paradigmas para usarse en BCI	34
2.2 Potencial Relacionado a Evento P300	35
2.2.1 Definición y características	35
2.2.2 Factores que afectan el ERP P300	37
2.3 Métodos de reconocimiento P300 Visual	38
2.3.1 Análisis de Discriminante Lineal (LDA)	38
2.3.2 Análisis de Discriminante Lineal Paso a Paso(SWLDA)	40
2.3.3 Análisis de Correlación Canónica(CCA)	40
2.3.4 Regresión Logística Regularizada	41
2.3.5 Redes Neuronales Artificiales (RNA)	41
3 Metodología	43
3.1 Definición del paradigma del sistema BCI-P300	43

3.2	Base de datos de señales EEG registradas con el paradigma Oddball	44
3.3	Preprocesamiento	44
3.4	Técnicas de reconocimiento	45
3.4.1	Amplitud Media con Análisis de Discriminante Lineal (MA-LDA)	45
3.4.2	Análisis Discriminante Lineal Paso a Paso(SWLDA)	46
3.4.3	Análisis de Correlación Canónica con Análisis de Discriminante Lineal(CCA-LDA)	46
3.4.4	Análisis de Correlación Canónica con Regresión Logística Regularizada	47
3.4.5	Análisis de Correlación Canónica con Perceptrón Multicapa (CCA-MLP)	49
3.5	Métricas de comparación	52
3.5.1	Porcentaje de clasificación	52
3.5.2	Costo computacional	53
3.6	Diseño Experimental para el registro P300	53
3.6.1	Sistema de adquisición EEG	53
3.6.2	Configuración del sistema de adquisición	54
3.6.3	Definición del protocolo de adquisición	55
4	Resultados y Discusión	61
4.1	Validación	61
4.2	Grand Averages(GA)	61
4.3	Análisis comparativo	63
5	Conclusiones	75
5.1	Conclusiones	75
5.2	Trabajos Futuros	76
5.3	Artículos obtenidos en el trabajo	77
	Bibliografía	78
	Referencias	78
	Anexos	83
5.4	Anexo A- Consentimiento Informado	83

Lista de Figuras

1-1	Ejemplos de sistemas BCI aplicados en prótesis.(A)Movimientos ejecutados por una neuroprótesis de miembro superior (Bright et al.,2016).(B) Control de interruptor de prótesis de miembro inferior (Bai et al.,2015).	27
1-2	(a) Speller de 6x6(b) Comportamiento de la señal P300 respecto al Speller(Elsawy et al.,2013).	28
2-1	Diagrama de bloques de un sistema BCI.	31
2-2	Ubicación de los electrodos para registros de EEG según estándar 10-5(Blanco), estándar 10-10(Gris) y estándar 10-20(Negro)(Seeck et al.,2017).	32
2-3	Componentes P3a, P3b y P2 en los canales F_z y P_z durante la respuesta ERP-P300(Bolduc-Teasdale et al.,2012).	36
2-4	Modelo de red neuronal artificial(Gámez Albán, Cabrera, Salas, y Bravo Bastidas, 2016)	41
2-5	Modelo general del Perceptrón Multicapa(Caicedo y López,2009).	42
3-1	Metodología	43
3-2	Diseño experimental para paradigma BCI-P300 basado en el Speller 6x6, implementado por (Lee et al.,2019).	44
3-3	Posición topográfica de los 8 canales usados, según estándar 10-20.	45
3-4	Respuesta P300 en el dominio del tiempo, con características discriminantes como el valor medio absoluto de la señal y la desviación estándar para objetivos y no objetivos.	46
3-5	Diagrama de flujo del método propuesto basado en CCA-Regresión Logística Regularizada para detectar el P300 utilizando los datos de prueba.	49
3-6	Diagrama de flujo del método propuesto basado en CCA-MLP para detectar el P300 utilizando los datos de prueba.	52
3-7	(a)Disposición de canales g.Nutilus-32-PRO (National Center for Adaptive Neurotechnologies,2018). (b)Imagen real del dispositivo.	53
3-8	Configuración del entorno con g.NeedAccess.	54
3-9	Entorno de adquisición con BCI2000 (National Center for Adaptive (Source) Neurotechnologies,2018)	57
3-10	Entorno de adquisición con BCI2000 (National Center for Adaptive (Application) Neurotechnologies,2018)	57

3-11 Deletreador mostrado en la pantalla durante la fase de calibración(National Center for Adaptative Neurotechnologies,2018).	58
3-12 Análisis offline usando el entorno de BCI2000(National Center for Adaptative Neurotechnologies,2018).	59
4-1 Comportamiento de las señales de referencia en los canales(a) \mathbf{F}_z y (b) \mathbf{C}_z . . .	61
4-2 Comportamiento de las señales de referencia en los canales(a) \mathbf{P}_3 y (b) \mathbf{P}_z . . .	62
4-3 Comportamiento de las señales de referencia en los canales(a) \mathbf{P}_4 y (b) \mathbf{PO}_3 . . .	62
4-4 Comportamiento de las señales de referencia en los canales(a) \mathbf{PO}_4 y (b) \mathbf{O}_z . . .	62
4-5 Topografía del comportamiento de las señales de referencia(objetivo y no-objetivo) en diferentes secciones de tiempo.	63
4-6 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 1.	65
4-7 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 2.	66
4-8 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 3.	66
4-9 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 4.	67
4-10 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 5.	67
4-11 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 6.	68
4-12 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 7.	68
4-13 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 8.	69
4-14 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 9.	69
4-15 Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 10.	70
4-16 Porcentaje de clasificación media de cada método para identificación de ERP-P300.	70
4-17 Aumento en el porcentaje de clasificación de cada método respecto al número de trials utilizados.	73
5-1 Dispositivo g.Nautilus	84
5-2 Deletreador	85

Lista de Tablas

2-1	Clasificación de las ondas EEG conforme a las bandas de frecuencia	33
2-2	Otros ERPs generados durante la estimulación con paradigma oddball	37
2-3	Técnicas de extracción y clasificación para reconocimiento de P300	39
3-1	Clasificación de impedancias por color	55
4-1	Porcentaje de clasificación por cada método, usando 1 trial.	63
4-2	Porcentaje de clasificación por cada método, usando 2 trials.	64
4-3	Porcentaje de clasificación por cada método, usando 3 trials.	64
4-4	Porcentaje de clasificación por cada método, usando 4 trials.	65
4-5	Costo computacional por cada método expresado en segundos(s), usando 4 trials	71
4-6	Técnicas para el reconocimiento de P300 según paradigma Oddball en Speller 6x6 reportadas en la literatura	72

1 Introducción

Según Emerson Pugh y Lyall Watson: "Si el cerebro fuera tan simple que pudiéramos entenderlo, seríamos tan simples que no lo entenderíamos" (Pugh, 1977). Esto, junto con el avance de la tecnología, ha motivado a profundizar los análisis del cerebro humano y aplicar sus capacidades en diferentes campos, entre ellos la ingeniería.

La ingeniería ha permitido el desarrollo de sistemas que permiten la interacción de las personas con el ambiente, usando señales eléctricas provenientes del cerebro, Electroencefalografía (EEG), sin necesidad de usar su sistema nervioso periférico o muscular, conocidos como Interfaces Cerebro-Computador o Brain Computer Interface (BCI) (McFarland y Wolpaw, 2011). Los sistemas BCI tienen una gama de aplicaciones en los campos de la medicina, educación, neuroergonomía, juegos, rehabilitación motora y de comunicación, robótica, entre otros (Rezeika et al., 2018; Patelia y Patel, 2019; Chaudary, Birbaumer, y Ramos, 2016; Abdulkader, Atia, Mostafa, y Mostafa, 2015).

No obstante, los sistemas BCI presentan una serie de limitaciones debido principalmente a que las señales EEG del cerebro son de amplitud baja, no son estacionarias, tienen alto contenido de ruido interno y externo y son variables respecto al tiempo y a la persona (Boelts, Cerquera, y Ruiz, 2015).

Con el objetivo que el sistema BCI pueda reconocer la intención del usuario para ejecutar alguna acción, es necesario encontrar patrones en las señales de EEG. Lo que los usuarios del BCI deben hacer es generar patrones específicos, los cuales están determinados por la estrategia mental o paradigmas. Entre los paradigmas más estudiados en la literatura se encuentran los basados en potenciales evocados (EP), los basados en potenciales relacionados a eventos (ERP) y los basados en la sincronización/desincronización relacionada a eventos (ERD/ERS) (McFarland y Wolpaw, 2011; Rezeika et al., 2018). En la literatura, el potencial relacionado a eventos (ERP) P300 visual es comúnmente estudiado e implementado en sistemas BCI. La señal P300, como lo indica su nombre (Picton, 1992), es una deflexión positiva de voltaje con una latencia entre la presentación del estímulo y la respuesta de aproximadamente 300 ms. Registrado en la parte parieto-central de la corteza cerebral, principalmente en los canales F_z , C_z y P_z (Karimi, Mijani, Talebian, y Mirzakuchaki, 2019) según el estándar 10-20 (Baura, 2011). Por otra parte, los electrodos correspondientes a la región occipital del cerebro, que es la encargada de la función visual, también experimentan

el fenómeno P300 cuando el estímulo es visual. La señal P300 es considerada como señal de baja frecuencia, cuyo contenido espectral se encuentra en la banda Delta, Theta y Alpha (Basar y A.Duzgun, 2015).

Para la adquisición de señal P300, el sujeto se concentra en un estímulo objetivo a lo largo de una serie de repeticiones. El método de promediación ha sido extensamente usado en la literatura para el reconocimiento de la señal P300, debido a su baja relación señal a ruido, que consiste en realizar un promedio de gran cantidad de trials o repeticiones; no obstante, esto aumenta el costo computacional del sistema, teniendo en cuenta que se requiere adquirir mayor número de señales y el proceso matemático es más extenso, de forma que la identificación de la intención del usuario tardaría mucho más tiempo. Diversos estudios en la literatura han establecido un compromiso entre el número de trials y exactitud en el reconocimiento del potencial.

Teniendo en cuenta el desafío abierto de detectar ERP-P00 visual usando un reducido número de trials con el adecuado porcentaje en la clasificación, en este trabajo se proponen tres nuevos métodos para reconocimiento de P300 basados en los coeficientes obtenidos del análisis de correlación canónica (CCA) respecto a dos señales de referencia, correspondiente al Grand-Average (GA) del conjunto de señales objetivo (Target) y no-objetivo (No-Target) para cada sujeto de pruebas.

El primer método propuesto consiste en el uso de características híbridas obtenidas del Mean-Amplitude y los coeficiente del CCA como entradas en un clasificador de tipo Linear Discriminant Analysis (LDA). El segundo método propuesto consiste en el uso de los coeficientes del CCA como características de entrada de un modelo de Regresión Logística Regularizada. El tercer método consiste en el uso de los coeficientes del CCA como características de entrada de una red neuronal artificial tipo Perceptrón Multicapa (MLP), con una capa oculta de 4 neuronas, cuya función de activación corresponde a la función sigmoideal.

Los métodos propuestos fueron evaluados en señales EEG-P300 correspondiente a 10 sujetos de prueba, de una base de datos pública disponible en (Lee et al., 2019) y comparados con dos métodos estándar propuestos en la literatura: Mean-Amplitude LDA (Lee et al., 2019; Hwang, Lee, y Lee, 2017) y Stepwise-LDA (Xiao, Xu, Wang, Jung, y Ming, 2019; Xiao, Xu, Jin, et al., 2019; Kabbara, Khalil, El-Falou, Eid, y Hassan, 2015), usando solo 1,2,3 y 4 trials y usando como métrica de comparación el porcentaje de clasificación del sistema en el reconocimiento de la señal P300 y el costo computacional de ejecución de cada método. Para este análisis se hace uso de la plataforma Matlab, junto con el toolbox EEGLab que cuyas funciones permiten procesar y visualizar señales ERP.

Entre estos recursos se encuentra los algoritmos propuestos junto con un protocolo de ad-

quisición para señales P300 a través del sistema BCI-P300 tradicional: deletreador o speller, usado comúnmente para rehabilitación de la comunicación (Rezeika et al., 2018; Farwell y Donchin, 1988; J. Li, Gu, Ji, Pang, y Li, 2016). Este protocolo se diseña con el objetivo de implementarlo en el laboratorio de simulación de la Universidad Antonio Nariño usando como equipo de adquisición de EEG el g.Nautilus-32 PRO y como plataforma de ejecución el sistema BCI2000 en modalidad speller.

1.1. Planteamiento del Problema

Según el último reporte realizado por la organización mundial de la salud (OMS) respecto a la discapacidad, cerca del 15.6% de la población mundial sufre de algún tipo de discapacidad (World Health Organization, 2011), por otro lado en Colombia esta estadística se aproxima al 6.3% de la población nacional (Gómez y Departamento Administrativo Nacional de Estadística, 2008).

Durante los últimos años, las tecnologías BCI se han enfocado en mejorar la calidad de vida de esta población, a través de dispositivos que no requieren manipulación motora. No obstante, el procesamiento y caracterización de la señal EEG, para extraer comandos que reflejen la intención del paciente todavía es un reto, debido principalmente a la baja amplitud y la baja relación señal a ruido.

La señal P300 (Farwell y Donchin, 1988) es ampliamente estudiada y aplicada en sistemas BCI, en el contexto de la rehabilitación de la comunicación a través del Speller-BCI. Teniendo en cuenta la baja relación señal a ruido del potencial P300, la técnica del promediado ha sido ampliamente usada, en la cual se promedian múltiples repeticiones, con el objetivo de eliminar el ruido de fondo. De esta forma, los métodos de detección del potencial P300 convencionales requieren de un mayor número de repeticiones (trials) en el momento de la adquisición para promediar mayor cantidad de señales, eliminando el ruido aleatorio, lo cual representa una latencia significativa en la detección P300, al tener que registrarse múltiples repeticiones.

Por otro lado, cuando se busca usar un reducido número de repeticiones o inclusive usar una única repetición, los algoritmos matemáticos suelen ser costosos y no generan una clasificación adecuada para la detección del P300 (Xiao, Xu, Wang, et al., 2019; Xiao, Xu, Jin, et al., 2019; Kabbara et al., 2015).

Otro limitante que surge durante la implementación de sistemas BCI, corresponde a la variabilidad de las señales EEG, debido a que no son estacionarias y son variantes en el tiempo y el sujeto (Boelts et al., 2015). Por lo que en ocasiones es necesario estandarizar el ambiente y la metodología para la adquisición de señales a través de un protocolo, realizando una previa sesión de entrenamiento o calibración para que el sujeto de pruebas se familiarice con el sistema, además de hacer una correcta elección de canales, bandas de frecuencia y otras características que influyen durante la ejecución.

1.2. Justificación

Como se ha mencionado anteriormente, el desarrollo de técnicas que permitan el reconocimiento de la señal P300 todavía es un desafío. Existen métodos estándar en la literatura (Lee et al., 2019; Hwang et al., 2017; Xiao, Xu, Jin, et al., 2019), a pesar de que el porcentaje en la clasificación es aceptable y el costo computacional no es tan alto, existen otras variables que afectan la usabilidad y su aplicación en entornos reales

Por este motivo, en este trabajo se propone un nuevo método de reconocimiento para P300 visual, no reportado antes en la literatura, que corresponde a usar la regresión logística regularizada con coeficientes del análisis de correlación canónica (CCA). La definición matemática de estos métodos es más compleja que el mean-amplitude (MA) aunque computacionalmente puede ser más liviano que otros métodos.

El método propuesto se evaluó con un conjunto de datos de EEG (Lee et al., 2019) disponible gratuitamente, y se comparó con dos métodos ampliamente utilizados: Mean-Amplitude LDA Step-wise LDA, utilizando solo 1,2,3 y 4 trials, usando dos métricas de comparación, que se encuentra relacionada con el porcentaje en la clasificación y el costo computacional.

Otro aspecto importante de este trabajo de grado radica en que hace parte del desarrollo del proyecto “Neuroprótesis Motora basada en las Tecnologías Brain-Computer-Interface (BCI) y Estimulación Eléctrica Muscular (EEM) para Rehabilitación Funcional – Fase I”, el cual está siendo implementado por el Grupo Bioingeniería de la Universidad Antonio Nariño y cuyo propósito es el desarrollo e implementación de una neuroprótesis motora basada en las tecnologías BCI y Estimulación Eléctrica Muscular, para rehabilitación funcional de actividades básicas.

Es de interés en el Grupo Bioingeniería el desarrollo de métodos que permita una identificación adecuada del potencial P300, como un paradigma de potencial uso para la implementación de sistemas BCI, con detecciones en tiempo real y en un entorno de lazo cerrado. De otro lado, los métodos de detección del P300 establecen una oportunidad de investigación en otros contextos, incluyendo otras aplicaciones en salud (comunicación, disartria, etc), en psicología (detección de emociones, estrés, etc), educación (concentración, atención, memoria), entre otros.

1.3. Objetivos

1.3.1. Objetivo general

Realizar un estudio comparativo de diferentes algoritmos para la detección de potenciales EEG P300, validando estos métodos en una interfaz cerebro-computador.

1.3.2. Objetivos específicos

1. Definir las especificaciones, los requerimientos y estructura del sistema BCI basado en señales P300.
2. Definir e Implementar los métodos de detección de potenciales P300.
3. Validar los algoritmos matemáticos en una base de datos conocida.
4. Definir un protocolo de medidas con personas sanas.

1.4. Estado del Arte

Son múltiples los campos de aplicación de las tecnologías BCI (Rezeika et al., 2018; Patelia y Patel, 2019; Chaudary et al., 2016; Abdulkader et al., 2015). En el campo de la medicina y de la ingeniería, se han usado como apoyo en la rehabilitación de pacientes con diversidad funcional.

En (Ono et al., 2014) se usan potenciales relacionados a sincronización/desincronización (ERS/ERD) en terapias de rehabilitación motora superior en pacientes con hemiplejia con retroalimentación somatosensorial a través de un exoesqueleto, concluyendo que esta técnica terapéutica puede ser mejor que la estandarizada con retroalimentación visual. En (Frolov et al., 2017) se hace uso de esta técnica para rehabilitación de mano en pacientes con accidentes cerebro vasculares y de médula espinal, encontrando una correlación positiva entre el uso de BCI y la restauración de la función motora de la extremidad. En otros casos de accidente neuromotor, como lo es la pérdida de alguna extremidad, los sistemas BCI se han implementado junto con la robótica para la rehabilitación de estas funciones a través del control de neuro-prótesis de miembros superiores (Muller-Putz y Pfurtscheller, 2008; Bright, Nair, Salvekar, y Bhisikar, 2016) o generación de comandos de neuro-prótesis de miembros inferiores (Murphy et al., 2017; Bai et al., 2015), Ver Figura 1-1.

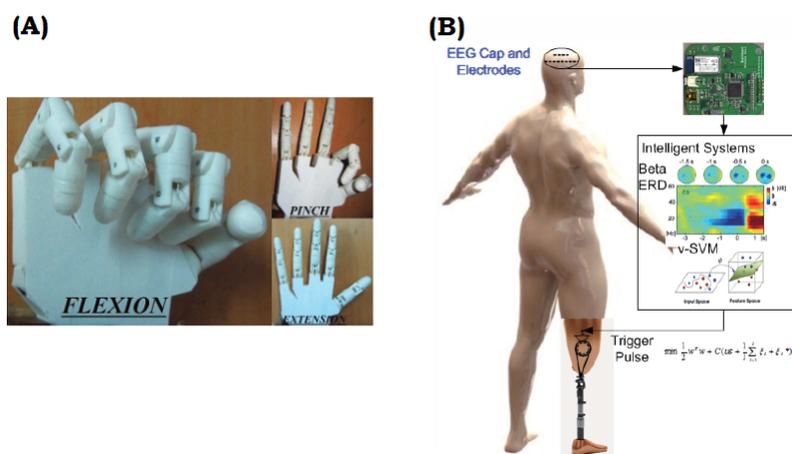


Figura 1-1: Ejemplos de sistemas BCI aplicados en prótesis. **(A)** Movimientos ejecutados por una neuroprótesis de miembro superior (Bright et al., 2016). **(B)** Control de interruptor de prótesis de miembro inferior (Bai et al., 2015).

No obstante, es importante tener en cuenta que el diseño del sistema BCI puede variar dependiendo del tipo de potenciales que se utilicen: Potencial Relacionado a Eventos (ERP), Potenciales evocados Visuales (VEP), conectividad, Eventos Relacionados a Desincronización/Sincronización (ERD/ERS), entre otros. Sillas de ruedas diseñadas para facilitar el desplazamiento de pacientes con parálisis han sido implementadas por medio de la señal

P300 Visual (Mendoza, 2017; Tang, Liu, Hu, y Zhou, 2018). Sin embargo, el sistema BCI tradicional para estudio e implementación del paradigma P300 es el deletreador o Speller (Patelia y Patel, 2019; Elsaywy, Eldawlatly, Taher, y Aly, 2013; Haider y Fazel, 2017).

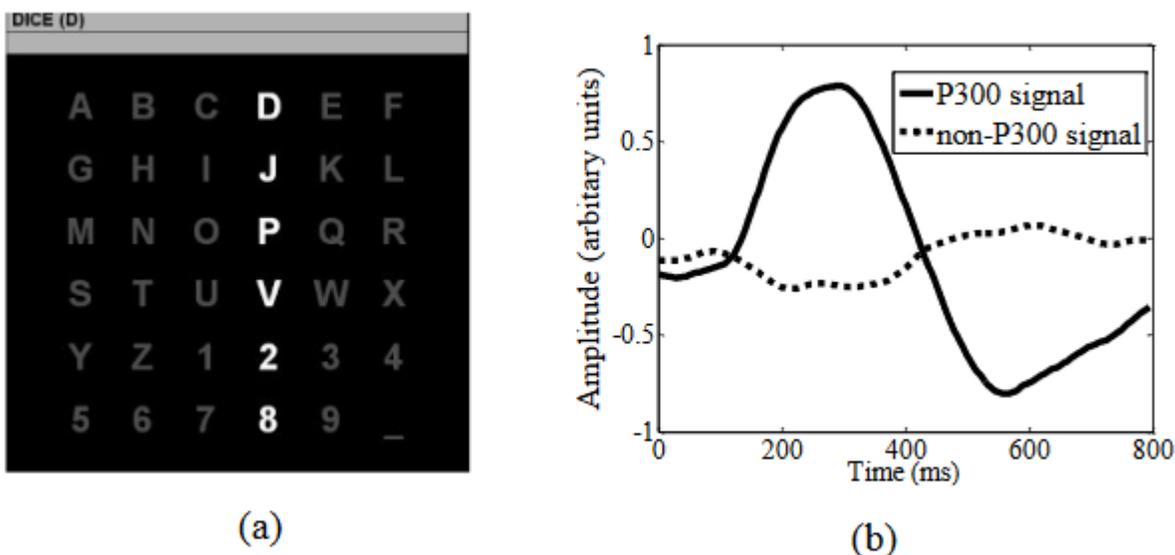


Figura 1-2: (a) Speller de 6x6 (b) Comportamiento de la señal P300 respecto al Speller (Elsawy et al., 2013).

Como se observa en la Figura 1-2, el fenómeno consiste en un Speller que cuenta de 6x6 a las cuales se les realiza un barrido iluminando cada cierto tiempo una fila y una columna. Cuando una letra es motivo de atención del usuario, entre los 250 ms y 500 ms de latencia se registra la señal P300 en la corteza parieto-central del cerebro (Farwell y Donchin, 1988). El speller es comunmente usado para rehabilitación de la capacidad de comunicación en personas que padecen de alguna afectación de esta función.

Las técnicas de detección de la señal P300 son extensamente estudiadas, con el reto abierto de dar respuesta a los problemas abiertos mencionados en la sección 1.1. Teniendo en cuenta que el objetivo de un sistema BCI es identificar la intención del usuario en el menor tiempo ejecutando una acción con la exactitud adecuada.

Uno de los métodos consiste en el promedio de varias repeticiones con el objetivo de eliminar el ruido aleatorio. En el proceso de detección del potencial P300 de la señal EEG, comúnmente se implementan tres etapas: preprocesamiento, extracción de características y clasificación. En la etapa de extracción de características, la amplitud media (MA) es un método conocido que consiste en promediar las señales objetivo, de acuerdo con el número

de pruebas realizadas, y permite obtener el valor medio como característica, generalmente entre 0 y 800 ms. Por otro lado, para la identificación de P300, se ha utilizado ampliamente el Análisis de Discriminante Lineal(LDA) (Hwang et al., 2017) con el que se han obtenido altos porcentajes de clasificación, aproximadamente 80 % para la detección de P300 y alrededor de 100 % para la identificación de caracteres del Speller(Lee et al., 2019). Se han utilizado múltiples variantes de LDA para detectar potenciales P300, entre los cuales se encuentra el Análisis discriminante lineal por pasos o step-wise LDA(SWLDA) con el que múltiples estudios han obtenido porcentajes de clasificación de alrededor del 70 % con único ensayo o single trial (Xiao, Xu, Wang, et al., 2019; Xiao, Xu, Jin, et al., 2019; Kabbara et al., 2015) y más del 80 % utilizando múltiples ensayos o trials para el reconocimiento de P300 (Xu, Long, y He, 2016; Raksha, Sahana, Sahana, y Niranjana, 2018) y más del 90 % en la identificación del carácter del Speller (Xu et al., 2016).

Además, varios autores también han reportado sobre el uso de otras características en el dominio del tiempo para detectar potenciales P300, como la amplitud pico a pico, la amplitud máxima, el área positiva, el área negativa, entre otros (Orellana y Cuenca, 2017). Por otro lado, los filtros espaciales son efectivos para mejorar la detección de P300, entre los que se encuentran el Análisis de componentes independientes (ICA), el algoritmo xDAWN y el Análisis de componentes principales (PCA) que han proporcionado clasificaciones con porcentajes superiores al 90 % pero utilizando técnicas computacionalmente más costosas (Chiou y Puthusserypady, 2016).

El análisis de correlación canónica (CCA) se ha utilizado ampliamente en la literatura para el reconocimiento de VEP (Hwang et al., 2017; J. Li et al., 2016; Blanco y Ruiz, 2020); para el reconocimiento P300 se ha utilizado como filtro espacial (Spuler, Walter, Rosenstie, y Bogdan, 2014) obteniendo porcentajes en la clasificación de alrededor del 84 % utilizando métodos combinados.

Por otro lado, un método estadístico interesante que reporta pocos estudios relacionados a la detección del potencial P300 en la literatura está relacionado con la regresión logística. La regresión logística se comparó con la Máquina de Soporte Vectorial o Support Vector Machine en (Motlagh y Ibrahim, 2015) usando como características los coeficientes de la transformada Wavelet obteniendo una clasificación máxima de 96 %, mejor que la clasificación del SVM de 89 %. Este método también se implementó en (Viana, Batista, y Melges, 2014) para elegir las mejores características para el reconocimiento de P300, sin embargo, este estudio no analizó los coeficientes de CCA. En ese estudio, los autores implementaron la máquina de soporte vectorial (SVM) obteniendo porcentajes entre 60 % y 96 % para una sola prueba. Los métodos de regresión con CCA se han implementado en BCI, (Wang, Wang, Jing, y Wang, 2015; Wang et al., 2016) donde los autores implementaron la Regresión lineal multivariante para la extracción de características y el reconocimiento de los potenciales evo-

cados visuales en estado estacionario (SSVEP) obteniendo porcentajes superiores al 80 %, utilizando hipótesis lineales y ecuación normal como alternativa del gradiente descendiente para optimizar las ponderaciones de características.

También métodos de aprendizaje de máquina tales como Redes neuronales han sido implementados para reconocimiento de patrones de señales de EEG. En (Cecotti y Graeser, 2011) se implementa una red neuronal convolucional (CNN) con 5 capas profundas para el reconocimiento de P300 en un sistema BCI-Speller, usando como características de entrada el promedio del grand average de 10 ensayos o trials y 64 canales de dos sujetos de pruebas, obteniendo un error aproximado del 1 %. Por otro lado, en (Tal y D.Friedman, 2019) la red neuronal CNN es comparada con una red neuronal recurrente (RNN) de tipo Long Short Term Memory Layer - LSTM de dos capas profundas, usando 55 canales y 11 sujetos de prueba, donde el porcentaje de clasificación obtenido fue de alrededor del 97 %. Sin embargo, en la literatura no se reportan estudios donde se haya usado como el CCA como método previo a la red neuronal para P300, aunque en sistemas BCI en general , se han usado para identificación de SSVEP (Kwak, Müller, y Lee, 2017; Zhang et al., 2019). Las redes neuronales pueden ser una buena opción para el reconocimiento de patrones de EEG, pero el principal problema de su implementación es el alto costo computacional y la baja tasa de transferencia de datos.

2 Marco Teórico

2.1. Interfaz Cerebro-Computador

Una Interfaz Cerebro-Computador o Brain Computer Interface (BCI) es un sistema que funciona como un canal de comunicación entre el cerebro y los computadores, de tal manera que permite controlar el entorno del usuario de manera compatible con las intenciones de este (Nicolas y Gomez, 2012). Tradicionalmente, un sistema BCI se implementa principalmente mediante tres(3) fases: Adquisición de señales, procesamiento de la señal y aplicación (McFarland y Wolpaw, 2011; Chaudary et al., 2016; Kołodziej, Majkowski, y Rak, 2010), como se observa en la figura 2-1.

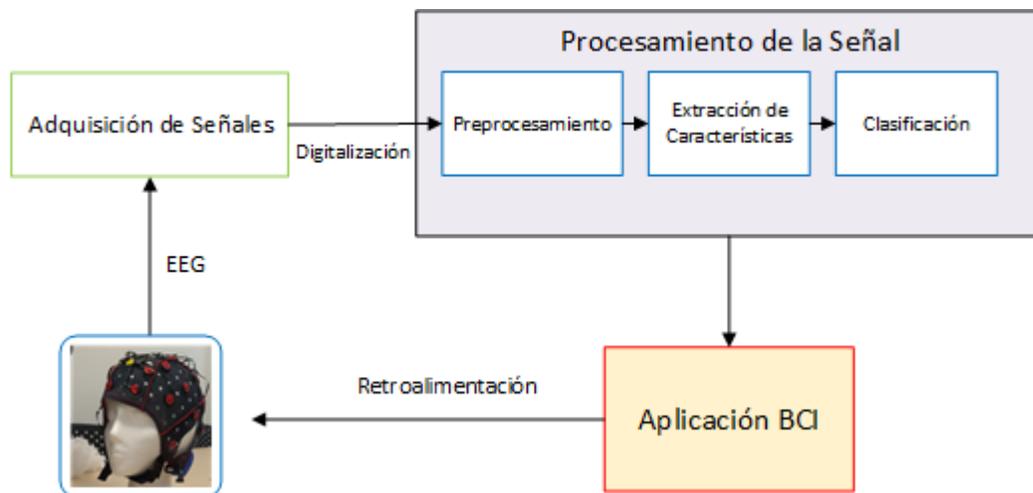


Figura 2-1: Diagrama de bloques de un sistema BCI.

2.1.1. Adquisición de señales

En la actualidad, existen dos(2) tipos de métodos que permiten registrar la actividad cerebral: los métodos invasivos y los no invasivos. Los métodos invasivos son usados para registrar actividad dentro del cerebro, entre los que se destacan la Electrocorticografía y la implantación de microelectrodos (Becedas, 2012). Por otro lado, las técnicas no invasivas son aquellas que permiten registrar actividad cerebral sin necesidad de ingresar a través del cráneo, entre los que se destacan la Electroencefalografía (EEG), la Magnetoencefalografía y las imágenes

de resonancia magnética funcional (Becedas, 2012).

La Electroencefalografía es la técnica más usada en sistemas BCI y consiste en el registro de la actividad eléctrica generada por una gran cantidad de neuronas, después de que se produce un estímulo externo(Niedermeyer y da Silva, 2004). Se lleva a cabo a partir de electrodos colocados estratégicamente en el cuero cabelludo(Becedas, 2012), actualmente, mediante estándares internacionales para registro de EEG, como el estándar 10-5, 10-10 y 10-20 (Baura, 2011; Seeck et al., 2017), ver figura 2-2.

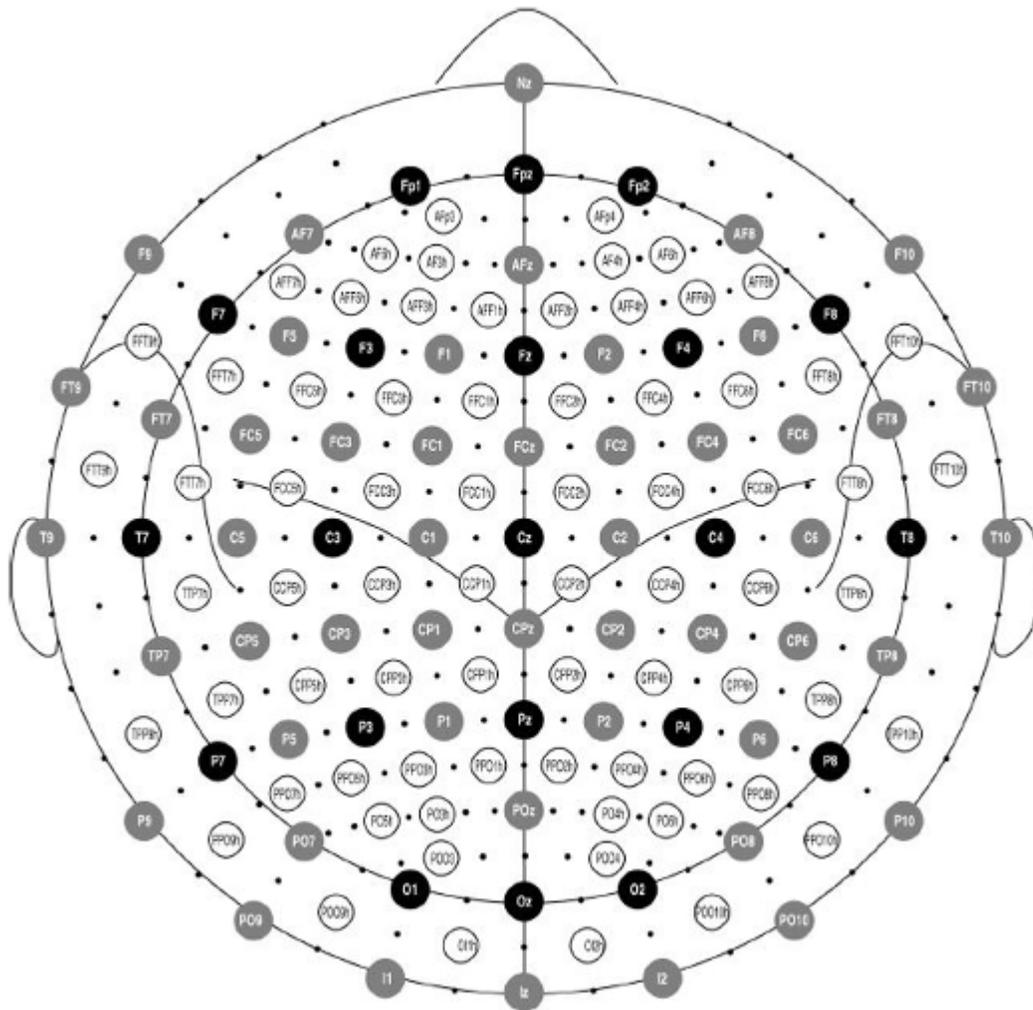


Figura 2-2: Ubicación de los electrodos para registros de EEG según estándar 10-5(Blanco), estándar 10-10(Gris) y estándar 10-20(Negro)(Seeck et al.,2017).

El comportamiento de las señales de EEG generalmente es oscilatoria, lo cual permite que estas sean clasificadas según el rango de frecuencia(Delta, Theta,Alpha, Beta y Gamma) y las cuales están asociadas a alguna actividad cotidiana que realiza el cerebro (Kumar y

Bhuvanewari, 2012), ver tabla 2-1.

Tabla 2-1: Clasificación de las ondas EEG conforme a las bandas de frecuencia

Onda EEG	Rango de frecuencia (Hz)	Características
Delta (δ)	0.1 - 4	Es la onda con mayor amplitud pero más lenta de todas, y normalmente aparece en los estados 3 y 4 del sueño
Theta (Θ)	4 - 8	Se manifiesta principalmente en los sujetos menores de 13 años, en fases de meditación profunda y se encuentra relacionada con la producción de serotonina y la relajación
Alpha (α)	8 - 13	Se manifiesta en su mayoría en adultos en estado de relajación o concentración, ojos cerrados y es registrada principalmente en los lóbulos occipitales y parietales
Beta (β)	13 - 30	Se manifiesta en estados de imaginación y acciones, relacionada con los sentidos, la memoria, la toma de decisiones y la solución de problemas, registrada en los lóbulos frontales y parietales
Gamma (γ)	30-100	Relacionada con la percepción y la conciencia, alta actividad cerebral en estados de alerta

2.1.2. Análisis de la señal EEG para un sistema BCI

Pre-procesamiento

Durante la fase de adquisición y digitalización de las señales EEG, es recomendable una fase de preprocesamiento. En esta fase se incluyen técnicas que permiten el aumento de la relación señal a ruido de la señal, entre estas técnicas se pueden destacar la implementación de filtros pasabanda entre 0.5 y 60 Hz para la eliminación de las componentes DC y filtro Notch a 50 o 60 Hz para eliminar el ruido de la alimentación. En otros estudios se recomienda la eliminación del baseline que corresponde a la media de la señal durante un tiempo anterior a la presentación del estímulo y la eliminación de artefactos como el parpadeo o el movimiento muscular de la cara que pueden contaminar la señal (Gupta y Singh, 1996). También en algunos casos para mejorar la extracción de características, se recomienda la implementación de filtros espaciales (Materka y Poryzala, 2014).

Extracción de características

En esta fase se implementan métodos que permiten obtener características para el reconocimiento de patrones asociados a la señal de EEG, esta fase varía dependiendo del paradigma que se está utilizando (Sección 2.1.3), aunque entre los métodos más utilizados en

el dominio del tiempo se reporta en la literatura el valor medio de la señal, voltaje pico a pico, voltaje RMS, varianza, entre otros (Orellana y Cuenca, 2017); en el dominio de la frecuencia se reporta la transformada rápida de Fourier o el análisis de densidad de potencia espectral (Ameera, A.Saidatul, y Ibrahim, 2018) y usando los dos dominios normalmente se reporta la transformada Wavelet (Motlagh y Ibrahim, 2015; Al-Fahoum y Al-Fraihat, 2014).

Clasificación

Tradicionalmente, para el reconocimiento de patrones en la señal EEG se implementan algoritmos que permitan clasificar la intención del usuario y con base a ello, ejecutar alguna acción. Esta fase también puede variar respecto al paradigma y a las características obtenidas. En la literatura se reportan clasificadores como el Linear Discriminant Analysis (LDA) (Hwang et al., 2017; Lee et al., 2019), Support Vector Machine (SVM) (Motlagh y Ibrahim, 2015) o inclusive algoritmos de aprendizaje de máquina tal como las redes neuronales (Kwak et al., 2017; Zhang et al., 2019).

2.1.3. Paradigmas para usarse en BCI

Como se ha mencionado, las aplicaciones y el procesamiento de las señales EEG de un sistema BCI pueden variar respecto al paradigma y el tipo de respuesta utilizada, según Becedas en (Becedas, 2012), estas respuestas pueden ser evocadas o inducidas.

Respuesta Evocada o Potenciales Evocados

Son producidos posteriormente a un estímulo (visual, auditivo o somatosensorial) de tipo continuo. La señal registrada se encuentra relacionada con el estímulo a través de la fase de la señal.

- **Potenciales Evocados Visuales (VEP):**

Son producidos en la corteza visual del cerebro (lóbulo occipital), en presencia de una estimulación visual (Leds, Imágenes, etc). Los Potenciales Evocados Visuales en Estado Estacionario (SSVEP) hacen parte de este grupo, donde un tipo de estimulación corresponde a imágenes parpadeantes, cuya frecuencia fundamental genera oscilaciones en las señales EEG de la misma frecuencia (Wang et al., 2015, 2016; Kwak et al., 2017).

Respuesta Inducida

Son producidos después de la aparición de un estímulo discreto y la relación entre la respuesta el estímulo es dada por un cambio sincronizado de amplitud o potencia de la señal.

- **Potencial Relacionado a Eventos (ERP):**

Los ERPs como su nombre lo indica, aparece como respuesta a un evento específico. En principio, existen dos tipos de ERPs: La señal P300 (Discutida en la sección 2.2)

y los Potenciales Corticales Lentos (SCP). Estos últimos, son cambios en los ritmos cerebrales producidos a través de la realización de tareas específicas, con una latencia aproximadamente entre 0.5 s y 10 s (Becedas, 2012).

- **Eventos Relacionados a Sincronización/Desincronización (ERS/ERD):**

Este fenómeno corresponde a una respuesta oscilatoria generada por un gran grupo de neuronas en actividades relacionadas procesos cognitivos específicos que se pueden controlar de forma innata, como por ejemplo la imaginación motora (Becedas, 2012). Esta última genera un aumento en la potencia de la señal (Sincronización) o disminución (Desincronización), en dos bandas de frecuencias principales: α y β , ver Tabla 2-1.

2.2. Potencial Relacionado a Evento P300

2.2.1. Definición y características

La señal P300 es una deflexión positiva en la corteza parieto-central del cerebro como consecuencia de la concentración de un sujeto en un estímulo de interés, en presencia de estímulos aleatorios (Becedas, 2012), más específicamente en los canales F_z , C_z y P_z (Karimi et al., 2019). Recibe su nombre debido a que la latencia entre la aparición del fenómeno y la presentación del estímulo es de aproximadamente 300 ms (Picton, 1992), no obstante esta latencia puede variar entre los 200 ms y 500 ms debido a la ubicación de los electrodos y las características del sujeto de pruebas (Becedas, 2012). A pesar de que esta señal no es clasificada por tipo de contenido frecuencial, se analiza en (Basar y A.Duzgun, 2015) que la señal P300 tiene un mejor comportamiento en las bandas de baja frecuencia (δ , θ y α).

El método más utilizado para evocar la respuesta P300 corresponde al paradigma *oddball*, este consiste en la presentación aleatoria de estímulos repetitivos (No-Targets) que son interrumpidos infrecuentemente por un objetivo de interés (Target), por lo que el experimento consiste en registrar la respuesta eléctrica cerebral ante este objetivo (F. Li et al., 2019). Este paradigma puede ser de tipo visual (J. Li et al., 2016; F. Li et al., 2019), tipo auditivo (Hohne, Tangermann, y Towards, 2014) o de tipo táctil (Brouwer y Erp, 2010).

La señal P300 visual contiene componentes que pueden ser diferenciados según la ubicación espacial, los componentes **P3a**, **P3b** y **P2**. El Componente P3a se encuentra asociado a la respuesta P300 obtenida en la aparición de un objetivo después de un patrón de estímulos irrelevantes, principalmente en la corteza frontal-central. Por otro lado los componentes P2 y P3b se encuentran relacionados con la discriminación entre estímulos raros y estímulos frecuentes de forma aleatoria, generando una actualización en la memoria de trabajo y provocando una amplitud positiva de mayor amplitud en la corteza parieto-central del cerebro.

Por lo que, en la implementación del paradigma oddball, la señal P3b es de mayor interés (Bolduc-Teasdale, Jolicoeur, y McKerral, 2012), ver Figura 2-3.

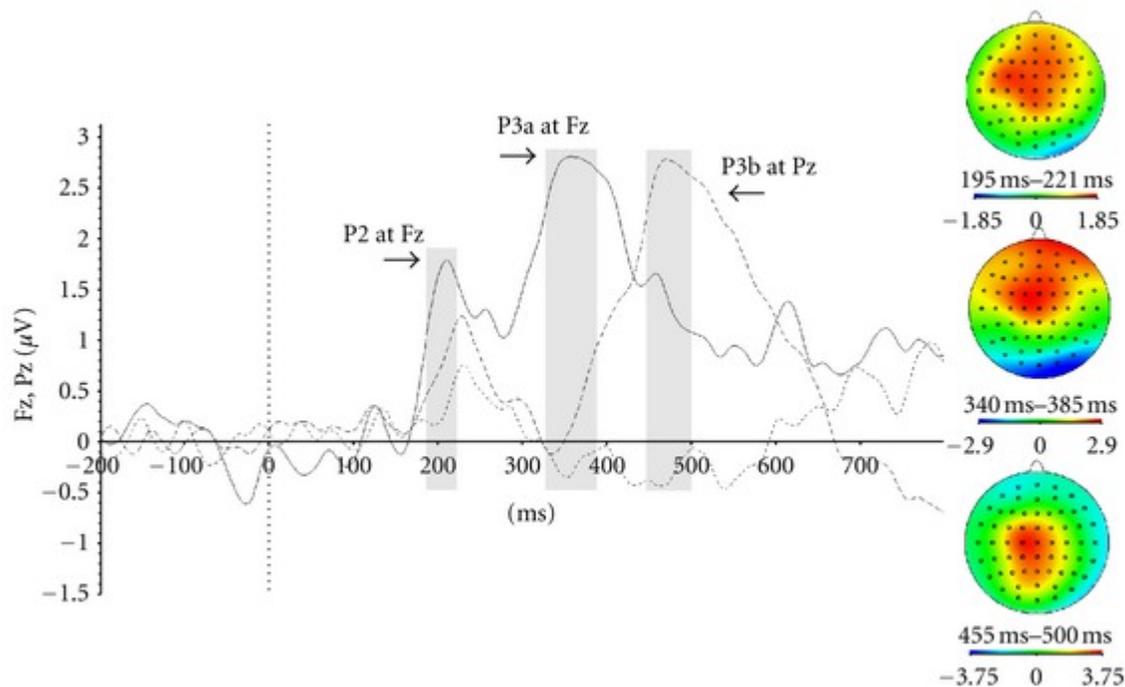


Figura 2-3: Componentes P3a, P3b y P2 en los canales F_z y P_z durante la respuesta ERP-P300 (Bolduc-Teasdale et al., 2012).

Además de estas componentes, durante la respuesta P300 también pueden presentarse una serie de respuestas tempranas o tardías en forma de deflexiones positivas o negativas en diferentes segmentos de tiempo (Sur y Sinha, 2009), ver Tabla 2-2.

Tabla 2-2: Otros ERPs generados durante la estimulación con paradigma oddball

Nombre	Latencia(ms)	Características
N100 ó N1	90-200	También llamado potencial de vértice, es una deflexión negativa con máxima magnitud en C_z .
P200 ó P2	100-250	Deflexión positiva, se sugiere que este ERP puede reflejar el comportamiento de búsqueda de sensaciones de un individuo.
N200 ó N2	200	Deflexión negativa formada por 3 componentes: N2a: Representa el proceso automático del cerebro involucrado en la codificación de cambios de estímulo. N2b: Aparece cuando los cambios en la propiedad física del estímulo son relevantes para la tarea. N3c: Obtenida cuando se requiere clasificación de estímulos dispares.
N300	300	Hallazgo reciente.
N400	300-600	Deflexión negativa relacionada con la expectativa de una palabra dada de terminar una oración.
P600	600	Deflexión positiva relacionada con la formación de oraciones de sintaxis compleja.

2.2.2. Factores que afectan el ERP P300

El paradigma oddball permite evocar la señal P300 mediante una tarea de alta concentración, por este motivo en (Picton, 1992) se establece que existen factores psicológicos que afectan el comportamiento de la señal. Por ejemplo, en ese estudio reportan que un sujeto de pruebas tuvo su potencial P300 de máxima amplitud el día donde estaba en menor presencia de ruido y más concentrado en el experimento, por otro lado, la menor amplitud la obtuvo el día donde tenía otro tipo de preocupaciones, esto podría establecer que el nivel de estrés del sujeto puede ser un factor determinante durante la realización de una prueba. En este mismo estudio, se establece que la señal P300 tiene una mayor amplitud cuando el estímulo parpadeante tiene menos posibilidades de aparecer, en pocas palabras, cuando el sujeto de pruebas menos se lo espera.

En (Picton, 1992) se establece que un factor que se encuentra correlacionado con la señal P300 es la edad, se concluye que la edad de los sujetos de pruebas donde los resultados son mejores son entre los 18 y los 76 años, sin embargo, también se establece que en cuanto sea mayor el sujeto, la latencia es más retrasada, la amplitud de la señal es más baja y la distribución la tendencia espacial puede variar. También en este estudio se aborda si la inteligencia y la personalidad se encuentran correlacionadas con la amplitud y latencia de la P300, estableciendo que el grupo de personas con IQ más altos obtenían una señal P300 de más baja amplitud y baja latencia, las personas con neuroticismo obtenían baja latencia y las personas que sufrían psicocitismo obtenían baja amplitud. Por otro lado se estableció que las personas introvertidas generaban ondas con mayor amplitud a comparación de las extrovertidas y que la persistencia está inversamente proporcionada con la amplitud de la señal.

Los estudios P300 no sólo se han realizado en personas sanas, también existen correlaciones entre su comportamiento y los trastornos psiquiátricos y neuróticos de las personas (Sur y Sinha, 2009). Entre los trastornos que afectan el P300 se encuentran: Esquizofrenia, Desordenes afectivos bipolares, síndrome de dependencia al alcohol, Fobias, Ansiedad, Trastorno Obsesivo Compulsivo, Trastorno por estrés post-traumático y Trastorno Disociativo.

2.3. Métodos de reconocimiento P300 Visual

Una de las principales ventajas de usar un sistema BCI-P300 es que el tiempo de calibración es rápido por lo que la gran mayoría de los sujetos lo pueden usar, obteniendo precisiones muy altas. Entre las principales desventajas radica la fatiga por alto tiempo de concentración y enfoque visual (Abiri, Borhani, Sellers, Jiang, y Zhao, 2018). Además de que las personas con discapacidad visual no lo pueden usar.

El sistema BCI más utilizado P300 corresponde al Speller de 6x6 introducido por primera vez por (Farwell y Donchin, 1988). En este sistema BCI el método de extracción y clasificación más usado corresponde al Step-wise Linear Discriminant Analysis (SWLDA). No obstante, en la Tabla **2-3** se pueden observar otras aplicaciones de los sistemas P300, junto con sus respectivas técnicas de reconocimiento, reportados en la literatura (Abiri et al., 2018).

2.3.1. Análisis de Discriminante Lineal (LDA)

El análisis de discriminante lineal o LDA, consiste en una técnica utilizada en estadística, reconocimiento de patrones y aprendizaje de máquinas para encontrar una combinación lineal de rasgos que caracterizan o separan dos o más clases de objetos o eventos. La combinación resultante puede ser utilizada como un clasificador lineal, o, más comúnmente, para la reducción de dimensiones antes de la posterior clasificación (Hastie, Tibshirani, y Friedman, 2009). En general los clasificadores lineales toman una decisión a partir de la combinación de un vector de características (Mendoza, 2017). Si x representa un vector de n características, el modelo de clasificación evalúa la función:

$$f(x) = g \left(\sum_{i=1}^n b_i \cdot x_i + c \right), \quad (2-1)$$

Donde $b = [b_1, b_2, \dots, b_n]$ y c son los coeficientes de la función lineal y $g(a)$ es una función escalar. Posteriormente, el asigna una etiqueta $l \in -1, 1$ a la observación dada sobre la base de la evaluación de x . Por medio de este umbral se establece que todo número superior a uno pertenece a la esta clase ($l = 1$) y todo número inferior pertenece a la contraria ($l = -1$). LDA encuentra la clase l que maximiza la probabilidad $p(L = l | X = x)$. La función de

Tabla 2-3: Técnicas de extracción y clasificación para reconocimiento de P300

Técnicas de extracción	Método de clasificación	Aplicación	Referencia
Datos obtenidos de P_z y submuestreados a 50 Hz	SWLDA	Speller 6x6	(McFarland y Wolpaw, 2011)
Media amplitud y diezmado con factor de 12	SWLDA	Speller 6x6	(Krusienski et al., 2007, 2008)
Datos normalizados y submuestreo de 32 Hz	BLDA, FLDA y SWLDA	Speller único carácter	(Fazel y Abhari, 2009)
Datos obtenidos de F_z , P_z , C_z y P_z y Análisis de componente independiente(ICA)	Red neuronal artificial de tres capas	Control de un bola virtual en 2D	(Piccione et al., 2006)
Datos obtenidos de 8 canales, aplicando filtros espaciales basados en CCA y Fisher	SWLDA	Control de una silla de ruedas	(Mendoza, 2017)
Datos obtenidos del Grand-Average de 10 trials y 64 canales	Red neuronal Convolutiva de 5 capas	Speller 6x6	(Cecotti y Graeser, 2011)
Datos obtenidos del grand-average de 10 trials y 55 canales	Red Neuronal Recurrente de 2 capas profundas	Speller 6x6	(Tal y D.Friedman, 2019)
Coeficientes de la transformada Wavelet	Máquina de Soporte Vectorial (SVM) y regresión logística	Speller 6x6	(Motlagh y Ibrahim, 2015)

densidad de probabilidad $p(X = x|L = -1)$ y $p(X = x|L = 1)$ se distribuyen normalmente entre los medios m_{-1} , m_1 y las matrices de covarianzas C_{-1} , C_1 . Estas condiciones establecen $p(L = 1|X = x) > p(L = -1|X = x)$ como:

$$(x - m_1)'C_1^{-1}(x - m_1) + \ln(|C_1|p(L = 1)) > (x - m_{-1})'C_{-1}^{-1}(x - m_{-1}) + \ln(|C_{-1}|p(L = -1)), \quad (2-2)$$

Donde $|C|$ expresa el determinante de la matriz C . El modelo LDA considera que las matrices de covarianza son iguales ($C_{-1} = C_1 = C$). De la ecuación 2-2 se puede demostrar que la regla de la decisión se puede reducir a:

$$b'x + c > 0, \quad (2-3)$$

Donde

$$b = 2C^{-1}(m_1 - m_{-1}), \quad (2-4a)$$

$$c = \ln\left(\frac{P(L = -1)}{P(L = 1)}\right) + m'_{-1}C_{-1}^{-1}m_{-1} - m'_1C_1^{-1}m_1 \quad (2-4b)$$

y $P(L = l)$ es la probabilidad de la clase l .

2.3.2. Análisis de Discriminante Lineal Paso a Paso(SWLDA)

Consiste en la obtención de características a través de la regresión paso a paso, las cuales funcionan como coeficientes de entrada al modelo LDA (Mendoza, 2017). En este modelo, cada subconjunto de características es usado para ajustar un modelo de regresión lineal cuya variable de salida corresponde a la etiqueta de clase. Posteriormente el coeficiente de cada predicción es evaluado en la hipótesis H_0 cuyo valor es cero. La hipótesis alternativa H_1 es aquella cuyo valor es diferente de cero. Dado un conjunto de características $X = [x_1, x_2, \dots, x_n]$ y dos umbrales $p^{in} \in [0, 1]$, $p^{out} \in [0, 1]$, este procedimiento de selección paso a paso consiste en:

1. Comenzar con un conjunto de características vacío $Y_0 = \{\}$. Establecer contador $i = 0$.
2. Para cada característica x_k que esté en X pero no en Y_i , ajustar un modelo de regresión lineal usando las predicciones $Y_k = Y_i \cup x_k$.
3. Calcular el valor p_k para cada característica x_k .
4. Encontrar la característica \hat{x} con el valor p más bajo. Si $\hat{p} < p^{in}$, $\hat{Y} = Y_i \cup \hat{x}$, sino $\hat{Y} = Y_i$.
5. Encontrar la predicción \tilde{y} con el valor más alto de p en el modelo ajustado con el conjunto de características \hat{Y} . Si este valor es mayor que p^{out} , $Y_{i+1} = \hat{Y} - \tilde{y}$, sino $Y_{i+1} = \hat{Y}$.
6. Si $Y_{i+1} \neq Y_i$, incremente el valor de i y repita los pasos del 2 al 6.

2.3.3. Análisis de Correlación Canónica(CCA)

El análisis de correlación canónica o CCA, consiste en una técnica estadística que permite calcular la correlación entre dos conjuntos multivariados. Por lo que, el coeficiente de correlación canónica mide la magnitud de asociación entre dos variables canónicas (Hastie et al., 2009).

Considere dos variables multidimensionales: $\mathbf{X} \in \mathbb{R}^{n \times p}$ y $\mathbf{Y} \in \mathbb{R}^{n \times q}$, donde n es el número de muestras, p es la dimensión de \mathbf{X} y q es la dimensión de \mathbf{Y} . La técnica CCA se enfoca en calcular las combinaciones lineales $\mathbf{x} = \mathbf{X} \cdot \mathbf{w}_x$ and $\mathbf{y} = \mathbf{Y} \cdot \mathbf{w}_y$, donde $\mathbf{w}_x \in \mathbb{R}^{p \times 1}$ y $\mathbf{w}_y \in \mathbb{R}^{q \times 1}$ representan los vectores de pesos que permiten maximizar la correlación ρ entre \mathbf{x} y \mathbf{y} . Al resolver el problema de optimización se obtiene que:

$$\rho = \max_{\mathbf{w}_x, \mathbf{w}_y} \text{corr}(\mathbf{x}, \mathbf{y}), \quad (2-5)$$

por lo que, el coeficiente de correlación canónica de las variables es definido por:

$$\rho = \max_{\mathbf{w}_x, \mathbf{w}_y} \frac{\mathbf{w}_x^n \mathbf{S}_{xy} \mathbf{w}_y}{\sqrt{\mathbf{w}_x^n \mathbf{S}_{xx} \mathbf{w}_x \mathbf{w}_y^n \mathbf{S}_{yy} \mathbf{w}_y}}, \quad (2-6)$$

donde S , representa la matriz de covarianza.

2.3.4. Regresión Logística Regularizada

La regresión logística regularizada es un método estadístico que permite predecir el comportamiento de un conjunto de clases, utilizando la técnica *One vs All* para calcular la probabilidad de las clases, reduciendo el número de características para eliminar el sobreajuste. el objetivo general de esta técnica consiste en hallar las ponderaciones más óptimas para los valores de entrada de la hipótesis formulada, minimizando el error, a través del gradiente descendiente o la ecuación normal. La formulación matemática es más detallada en la sección 3.

2.3.5. Redes Neuronales Artificiales (RNA)

Las redes neuronales artificiales o RNA surgen como un intento para emular el funcionamiento de las neuronas biológicas. Esto se realiza con el objetivo de desarrollar un sistema que cuente con gran capacidad de procesamiento y realice tareas de alta complejidad, a partir de señales de entrada. Una neurona artificial al igual que la biológica se encuentra comunicada con otras neuronas a través de sinapsis con un respectivo peso, lo que permite la generación de una o varias salidas (Caicedo y López, 2009; Gámez Albán, Cabrera, Salas, y Bravo Bastidas, 2016), ver Figura 2-4.

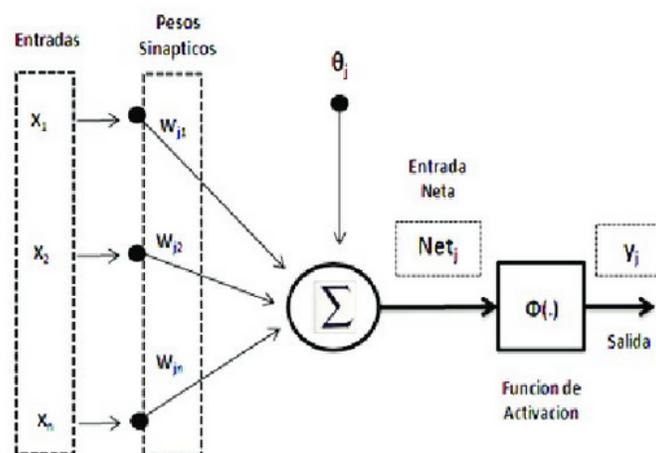


Figura 2-4: Modelo de red neuronal artificial (Gámez Albán, Cabrera, Salas, y Bravo Bastidas, 2016)

Perceptrón Multicapa(MLP)

Al igual que el cuerpo humano, no todos los tipos de neuronas artificiales son iguales, un tipo de red neuronal artificial corresponde al Perceptrón multicapa o MLP. Esta arquitectura, consiste en una versión mejorada del perceptrón monocapa, por lo que como indica su nombre cuenta con por lo menos tres niveles de neuronas: capa de entrada, capa oculta(puede ser más de una, aunque no se recomienda pues se aumenta la complejidad computacional) y capa de salida. En las redes neuronales, la conectividad consiste en la forma como una neurona de cualquier capa está interconectada con las neuronas de la capa previa y la capa siguiente. Para el MLP, la conectividad es total (Caicedo y López, 2009), como se muestra en la Figura 2-5.

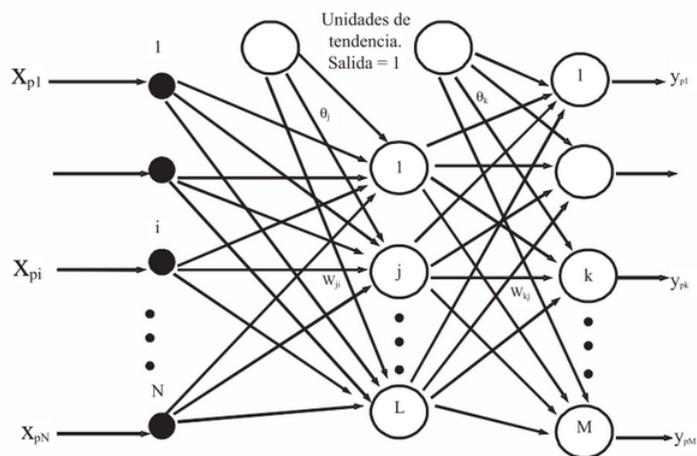


Figura 2-5: Modelo general del Perceptrón Multicapa(Caicedo y López,2009).

Al igual que cualquier técnica de machine learning, es necesario el entrenamiento del modelo, en el caso del MLP el algoritmo de aprendizaje corresponde a la retropropagación o Backpropagation. Este consiste en la propagación del error de la capa de salida hasta las capas ocultas, lo que permite hallar y modificar los pesos sinápticos a través de un número de iteraciones. La formulación matemática se explica a más detalle en la sección 3.

3 Metodología

Para desarrollo de este trabajo se abordó la siguiente metodología:

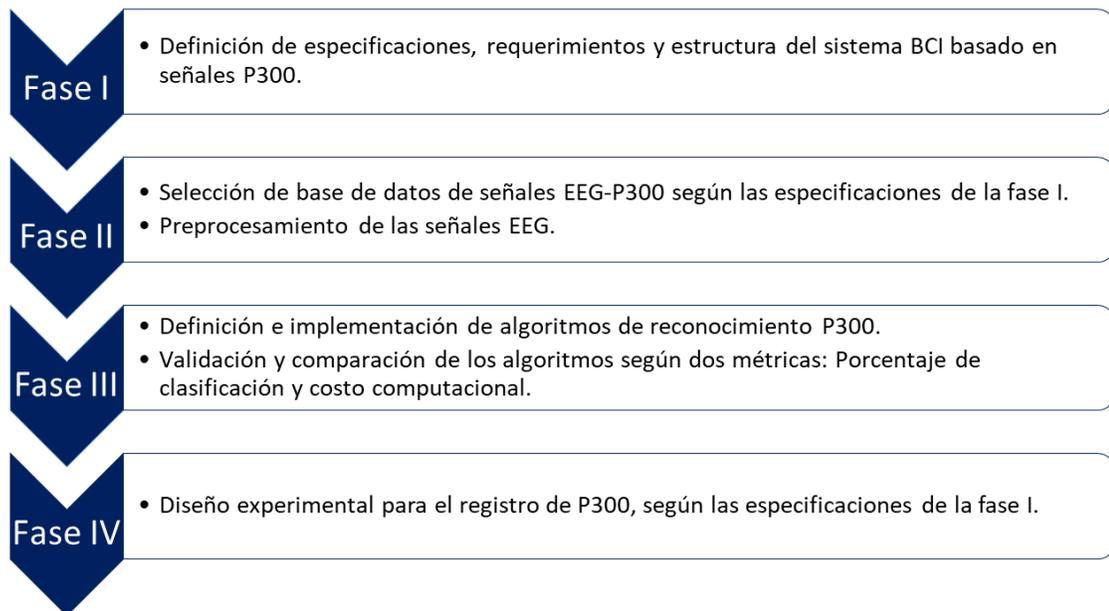


Figura 3-1: Metodología

3.1. Definición del paradigma del sistema BCI-P300

Teniendo en cuenta que el presente trabajo se enfoca en un estudio comparativo de diferentes métodos para la detección del potencial P300, el diseño experimental se centró en paradigmas ampliamente utilizados en la literatura. De esta forma, el paradigma oddball implementado mediante el deletreador o Speller de 6x6, es uno de los más estudiados para evocar el potencial P300 (Cecotti y Graeser, 2011; Fazel y Abhari, 2009; Krusienski et al., 2008; Lee et al., 2019; McFarland y Wolpaw, 2011; Motlagh y Ibrahim, 2015). Además, existen múltiples bases de datos que sirven de referencia (benchmarking) para realizar la comparación con los métodos desarrollados.

3.2. Base de datos de señales EEG registradas con el paradigma Oddball

Se utilizó una base de datos pública disponible en (Lee et al., 2019), Las señales EEG-P300 fueron adquiridas según el estándar 10-10, en el cual fueron registrados 62 canales con una frecuencia de muestreo de 1000 Hz. El experimento consistió en un deletreador o Speller de 6 filas y 6 columnas (6x6) con un tiempo de intervalo entre estímulo de 80 ms y un tiempo entre estímulos de 135 ms. Se usaron 33 caracteres del deletreador para la sesión de entrenamiento y 36 caracteres para la sesión de prueba, cada uno repetido 10 veces para un total de 330 estímulos objetivo (Target) en el entrenamiento(1980 en total) y 360 estímulos objetivo(Target) en la prueba(2160 en total), ver Figura 3-2. Para este estudio se usaron 10 sujetos.

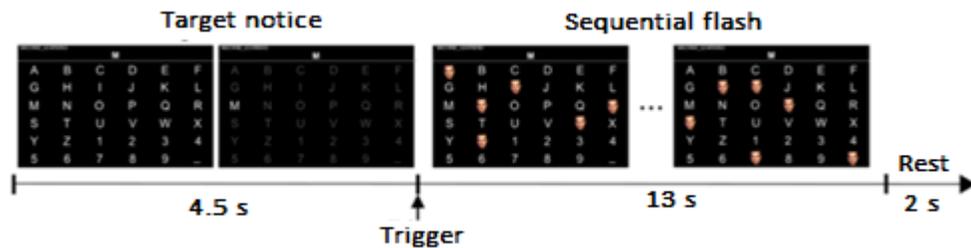


Figura 3-2: Diseño experimental para paradigma BCI-P300 basado en el Speller 6x6, implementado por (Lee et al.,2019).

3.3. Preprocesamiento

Para el preprocesamiento de las señales, es implementado un filtro pasabandas que permite reducir el ruido. Considerando que la señal P300 es una señal de baja frecuencia, específicamente entre 0.5 y 13 Hz (Banda Delta, Theta y Gamma)(Basar y A.Duzgun, 2015), las señales EEG son filtradas entre 0.5 y 40 Hz con un filtro Butterworth de orden 5, segmentadas entre 0 y 800 ms y un segmento de tiempo entre -200 ms y 0 es usado para la eliminación del baseline (Lee et al., 2019). Los canales son reducidos de 62 a 8 canales, teniendo en cuenta la corteza parieto-central de el cerebro y los electrodos que han sido más usados en la literatura para ERP visuales (Karimi et al., 2019): F_Z , C_Z , P_Z , P_3 , P_4 , O_Z , PO_3 and PO_4 (Ver Figura). Posteriormente, las señales fueron submuestreadas a 100 Hz, obteniendo un total de 80 muestras entre 0 y 800 ms.

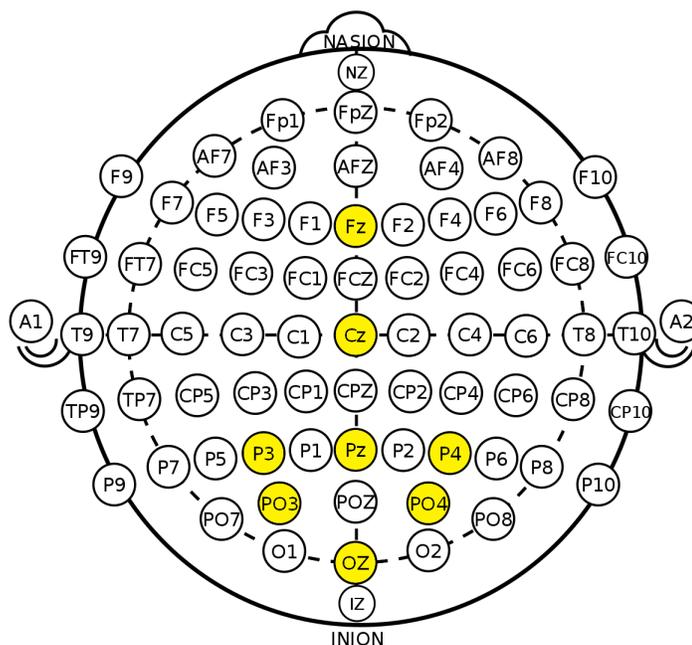


Figura 3-3: Posición topográfica de los 8 canales usados, según estándar 10-20.

3.4. Técnicas de reconocimiento

3.4.1. Amplitud Media con Análisis de Discriminante Lineal (MA-LDA)

Como se ha mencionado en la sección 2.2, el P300 consiste en una desviación positiva de voltaje a los 300 ms después del estímulo, por esta razón se esperaría que el valor medio de las señales EEG correspondientes a objetivos sea mayor que las señales EEG correspondientes a no-objetivos. Además, la desviación estándar puede ser un factor diferencial en la diferenciación entre señales objetivos y no-objetivos, por lo que para este estudio son implementadas el valor medio absoluto de la amplitud de la señal y la desviación estándar, entre 0 y 800 ms, como características de entrada para el clasificador, ver Figura 3-4. El LDA fue entrenado con las características obtenidas del conjunto de datos de entrenamiento y fue evaluado con las características obtenidas del conjunto de datos de prueba. El procedimiento fue repetido con las señales resultantes del promedio correspondiente a 1, 2, 3 y 4 trials.

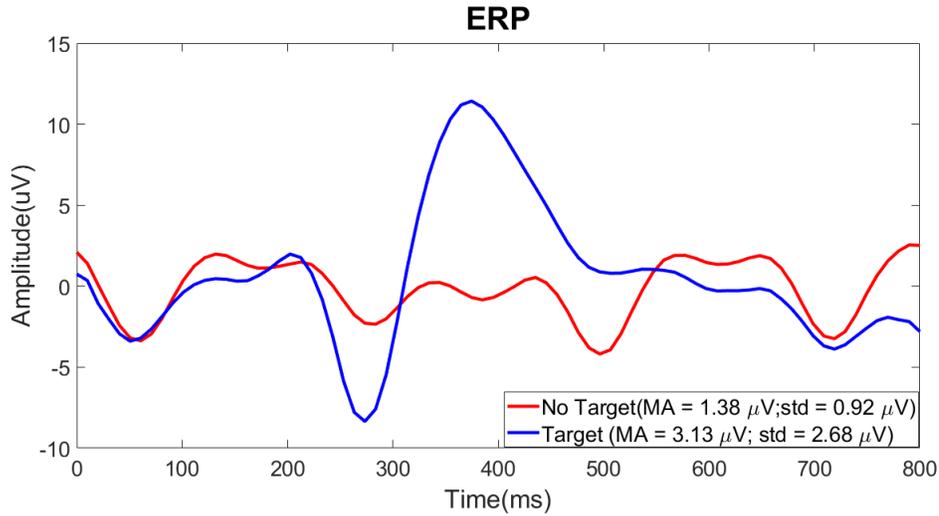


Figura 3-4: Respuesta P300 en el dominio del tiempo, con características discriminantes como el valor medio absoluto de la señal y la desviación estándar para objetivos y no objetivos.

3.4.2. Análisis Discriminante Lineal Paso a Paso(SWLDA)

Esta técnica consiste en una serie de pasos mediante un proceso iterativo(pasos hacia adelante y hacia atrás) que explican la mayor cantidad de varianza única, es decir, selecciona las características con el valor p más bajo provenientes de la amplitud de la señal EEG entre 0 y 800 ms (Xiao, Xu, Wang, et al., 2019), para implementar en el modelo de ajuste. Fue implementada la función de matlab `stepwisefit` con un ajuste de $p < 0.1$ para la regresión hacia atrás y eliminar características con valores de $p > 0.15$, ejecutándose hasta que se agoten las características del modelo. Posterior a esto, las características resultantes del conjunto de entrenamiento se implementaron para entrenar el LDA y se evaluaron con las características resultantes del conjunto de datos de prueba. El procedimiento fue repetido con las señales resultantes del promedio correspondiente a 1, 2, 3 y 4 trials.

3.4.3. Análisis de Correlación Canónica con Análisis de Discriminante Lineal(CCA-LDA)

De acuerdo con las ecuaciones 2-5 y 2-6, se considera que $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_k]^n$ es una variable multidimensional que representa la señal EEG registrada de k electrodos, donde $\mathbf{y}_i = [y(0), y(1), \dots, y(n-1)]$ es la actividad del i -th electrodo y n es el número de muestras. Así, \mathbf{y}_i es la señal ERP, medida como la diferencia de potencial eléctrico entre un electrodo i y un electrodo de referencia.

El Grand Average (GA) consiste en una señal que resulta de promediar señales de EEG en todos los trials que son generados bajo dos posibles condiciones: objetivo y no-objetivo. De esta manera se considera que $\mathbf{X} = [\mathbf{x}_{T1}, \mathbf{x}_{NT1}, \mathbf{x}_{T2}, \mathbf{x}_{NT2}, \dots, \mathbf{x}_{Tk}, \mathbf{x}_{NTk}]^n$ es una variable multidimensional que

representa el GA de la respuesta P300 para objetivos(T) y no-objetivos(NT), de k electrodos registrados. Los GA individuales para cada canal EEG y cada sujeto de pruebas se crearon utilizando el conjunto de datos de entrenamiento.

En el método de extracción propuesto, El CCA proporciona la correlación entre las señales P300 registradas y un conjunto de señales de GA, donde cada señal GA incluye respuestas a objetivos y no-objetivos, de k electrodos. Es decir, el CCA encuentra la correlación entre dos conjuntos de datos multidimensionales \mathbf{y}_i y \mathbf{X}_{Ti} obteniendo ρ_{Ti} y la correlación entre \mathbf{y}_i y \mathbf{X}_{NTi} obteniendo ρ_{NTi} , donde $i = 1, 2, 3, \dots, k$.

$$\rho_{Ti} = \max_{\mathbf{w}_x, \mathbf{w}_y} \text{corr}(\mathbf{X}_{Ti}, \mathbf{y}_i) \quad (3-1a)$$

$$\rho_{NTi} = \max_{\mathbf{w}_x, \mathbf{w}_y} \text{corr}(\mathbf{X}_{NTi}, \mathbf{y}_i) \quad (3-1b)$$

Después, el vector ρ corresponde a la concanetación de los vectores ρ_{Ti} y ρ_{NTi} , obteniendo que $\rho_i \in \mathbb{R}^{2k}$. Posteriormente, el vector ρ se usa como características de entrada, complementadas con las características obtenidas de la Amplitud Media (Sección 3.4.1) con el fin de mejorar la precisión del LDA en el reconocimiento del ERP.

3.4.4. Análisis de Correlación Canónica con Regresión Logística Regularizada

Para entrenar el modelo de regresión logística regularizado, inicialmente es necesario obtener los valores θ , donde $\theta \cdot \rho \in \mathbb{R}^m$ con θ_0 representando el *bias*. El parámetro θ se modifica de con el gradiente descendiente, inicializando su valor en cero como se menciona en (Hastie et al., 2009). Después, el vector con los parámetros θ se multiplica por los coeficientes de correlación ρ (Hallados en la sección 3.4.3), en un proceso de ponderación, cuyo resultado proporciona los valores de entrada para el modelo.

$$\theta^T \rho = \theta_0 + \theta_1 \cdot \rho_1 + \theta_2 \cdot \rho_2 + \dots + \theta_k \cdot \rho_k \quad (3-2)$$

En el proceso de clasificar los ERP como objetivo y no-objetivo, la hipótesis representada por $h_\theta(\rho)$ calcula la función sigmoide, cuyos parámetros de entrada es la multiplicación matricial de θ y ρ .

$$h_\theta(\rho) = \frac{1}{1 + e^{-\theta^T \rho}} \quad (3-3)$$

La hipótesis se implementó en la función de costo regularizada ($J(\theta)$) para llevar a cabo el proceso de minimización y encontrar los valores óptimos de θ , donde λ corresponde al parámetro de regularización que reduce la varianza en los parámetros de regresión estimados, en este caso es

igual a 1 debido a que no se reporta en la literatura un valor ideal (Hastie et al., 2009), m es el número de muestras en el subconjunto generado con el promedio de las señales respecto al número de trials(1,2,3 y 4) y ψ es la salida real: objetivo y no-objetivo(Clase binaria).

$$J(\theta) = - \left[\frac{1}{m} \sum_{i=1}^m \psi^{(i)} \log(h_{\theta}(\rho^{(i)})) + (1 - \psi^{(i)}) \log(1 - h_{\theta}(\rho^{(i)})) \right] + \frac{\lambda}{2m} \sum_{j=1}^n \theta_j^2 \quad (3-4)$$

Para minimizar la función de costo, fue implementado el algoritmo de gradiente descendiente, a pesar de que no existen valores ideales para los parámetros de este algoritmo, se recomienda en (Hastie et al., 2009) una tasa de aprendizaje de 0.001 y un número de 400 iteraciones con el objetivo de encontrar los valores θ óptimos. Los valores de θ óptimos fueron usados para predecir las clases del conjunto de datos de prueba, ver Figura **3-5**.

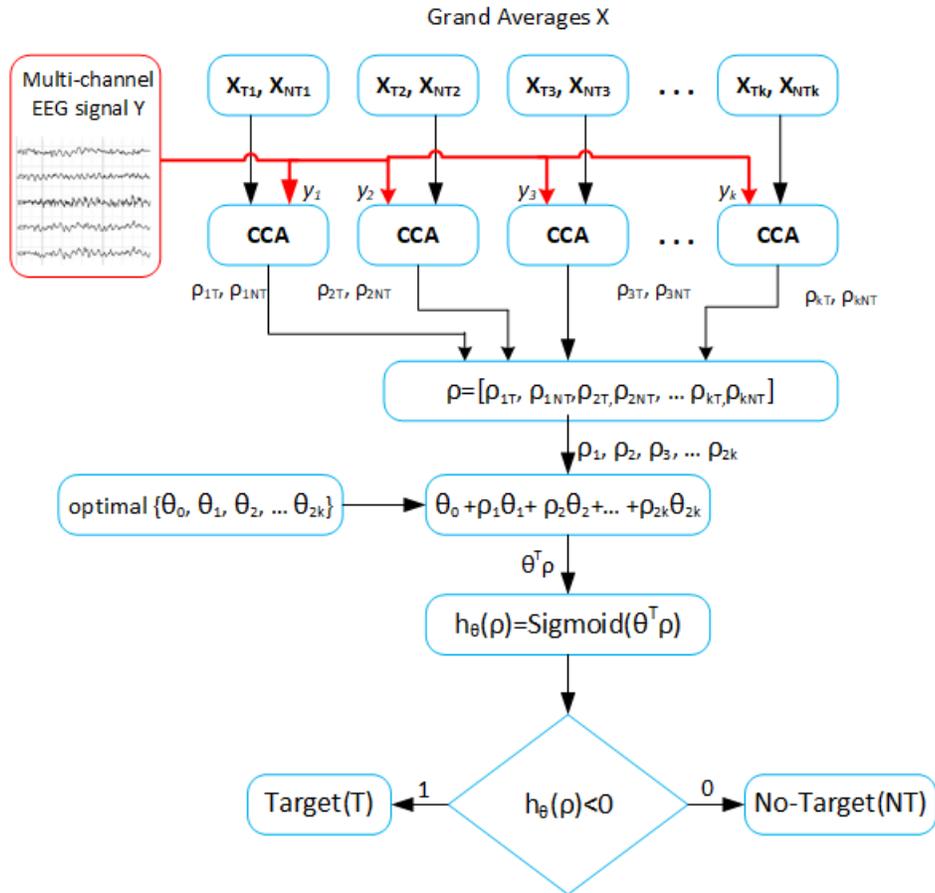


Figura 3-5: Diagrama de flujo del método propuesto basado en CCA-Regresión Logística Regularizada para detectar el P300 utilizando los datos de prueba.

3.4.5. Análisis de Correlación Canónica con Perceptrón Multicapa (CCA-MLP)

Teniendo en cuenta la estructura del MLP (Figura 2-5), se establecen tres capas ($L = 3$):

1. Capa de entrada ($l = 1$): Los valores de entrada del MLP corresponden a los coeficientes de correlación hallados en la sección 3.4.3, por lo que consta de 16 unidades o neuronas sin contar bias ($s_1 = 16$).
2. Capa oculta ($l = 2$): se establece una capa oculta con 4 unidades o neuronas sin contar bias ($s_2 = 4$).
3. Capa de salida ($l = 3$): La cantidad de unidades o neuronas de la capa de salida se encuentra asociado al número de clases usados en el problema, por lo que en este caso solo es necesario una neurona (Clase Binaria) ($s_3 = 1$).

Debido a que el MLP implementado en este problema cuenta con 3 capas interconectadas completamente, se establecen 2 matrices de pesos Θ . $\Theta^{(1)}$ es la matriz de peso de la sinapsis entre la capa de entrada y la capa oculta y $\Theta^{(2)}$ es la matriz de peso de la sinapsis entre la capa oculta y la capa de salida. Por lo que dimensionalmente $\Theta^{(1)} \in \mathbb{R}^{s_2 \times (s_1+1)}$ y $\Theta^{(2)} \in \mathbb{R}^{s_3 \times (s_2+1)}$. El MPL consiste en entrenar un modelo a partir de la propagación hacia adelante y hacia atrás, con el objetivo de hallar los pesos $\Theta^{(1)}$ y $\Theta^{(2)}$ que permitan minimizar el error (función de costo). En este caso, los pasos para entrenar el MLP son:

1. Inicializar los pesos $\Theta^{(1)}$ y $\Theta^{(2)}$ de forma aleatoria : En este caso no hay valores iniciales ideales establecidos en la literatura, no obstante en (Caicedo y López, 2009) se recomienda que estos parámetros sean valores aleatorios entre $-\epsilon/2$ y $\epsilon/2$ donde

$$\epsilon = \frac{\sqrt{6}}{\sqrt{L_{output} + L_{input}}}$$

Por lo que se establece $\epsilon \approx 0.59$.

2. Implementar propagación hacia adelante para obtener la hipótesis $h_{\Theta}(\rho^{(i)})$ para cualquier $(\rho^{(i)})$: Para este caso donde $L = 3$ y la función de activación corresponde a la función sigmoïdal ($g(z)$):

- $a^{(1)} = x$ (añadir bias $a_0^{(1)} = 1$).
- $z^{(2)} = \Theta^{(1)} \cdot a^{(1)}$.
- $a^{(2)} = g(z^{(2)})$ (añadir bias $a_0^{(2)} = 1$).
- $z^{(3)} = \Theta^{(2)} \cdot a^{(2)}$.
- $a^{(3)} = g(z^{(3)})$.
- $h_{\Theta}(\rho) = a^{(3)}$.

3. Calcular la función de costo $J(\Theta)$: Teniendo en cuenta la salida real ψ y el parámetro de regularización, que en este caso se escoge $\lambda = 0.04$, La función de costo es dada por:

$$J(\Theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{k=1}^{s_3} \psi_k^{(i)} \log(h_{\Theta}(\rho^{(i)}))_k + (1 - \psi_k^{(i)}) \log(1 - h_{\Theta}(\rho^{(i)}))_k \right] + \frac{\lambda}{2m} \left[\sum_{j=1}^{s_2} \sum_{k=1}^{s_1} (\Theta_{j,k}^{(1)})^2 + \sum_{j=1}^{s_3} \sum_{k=1}^{s_2} (\Theta_{j,k}^{(2)})^2 \right] \quad (3-5)$$

4. Implementar la retropropagación para calcular las derivadas parciales de $\frac{\partial}{\partial \Theta_{j,k}^{(l)}} J(\Theta)$: Para este caso se realiza un ciclo desde $i = 1$ hasta el número de ejemplos m , se inicializa el gradiente $\Delta_{ij}^l = 0$ para todo l, i, j y se aplican los siguientes pasos:

- $a^{(1)} = x$.

- Realizar propagación hacia adelante para calcular $a^{(2)}$ y $a^{(3)}$.
- Usando $\psi^{(i)}$, calcular $\delta^{(3)} = a^{(3)} - \psi^{(i)}$.
- Calcular $\delta^{(2)} = (\Theta^{(2)})^T \delta^{(3)} \cdot * g'(z^{(2)})$. No se calcula $\delta^{(1)}$ debido a que en la capa de entrada el error es cero.
- Calcular $\Delta_{ij}^l := \Delta_{ij}^l + a_{jl}^{(l)} \delta_i^{(l+1)}$

Posterior a este procedimiento se implementa la regularización en el gradiente:

- $D_{ij}^{(l)} = \frac{1}{m} \Delta_{ij}^{(l)} + \frac{\lambda}{m} \Theta_{ij}^{(l)}$ si $j \neq 0$.
- $D_{ij}^{(l)} = \frac{1}{m} \Delta_{ij}^{(l)}$ si $j = 0$.
- $\frac{\partial}{\partial \Theta_{j,k}^{(l)}} J(\Theta) = D_{ij}^{(l)}$.

5. Usar métodos de optimización avanzado con la retropropagación para minimizar $J(\Theta)$ como función de parámetros Θ . Se usan recursos proporcionados por (Caicedo y López, 2009; Shalev y Ben, 2014) para realizar este procedimiento, usando un número de 50 iteraciones.

Los valores $\Theta^{(1)}$ y $\Theta^{(2)}$ óptimos fueron implementados en el MLP para predecir las clases del conjunto de datos de prueba, ver Figura **3-6**.

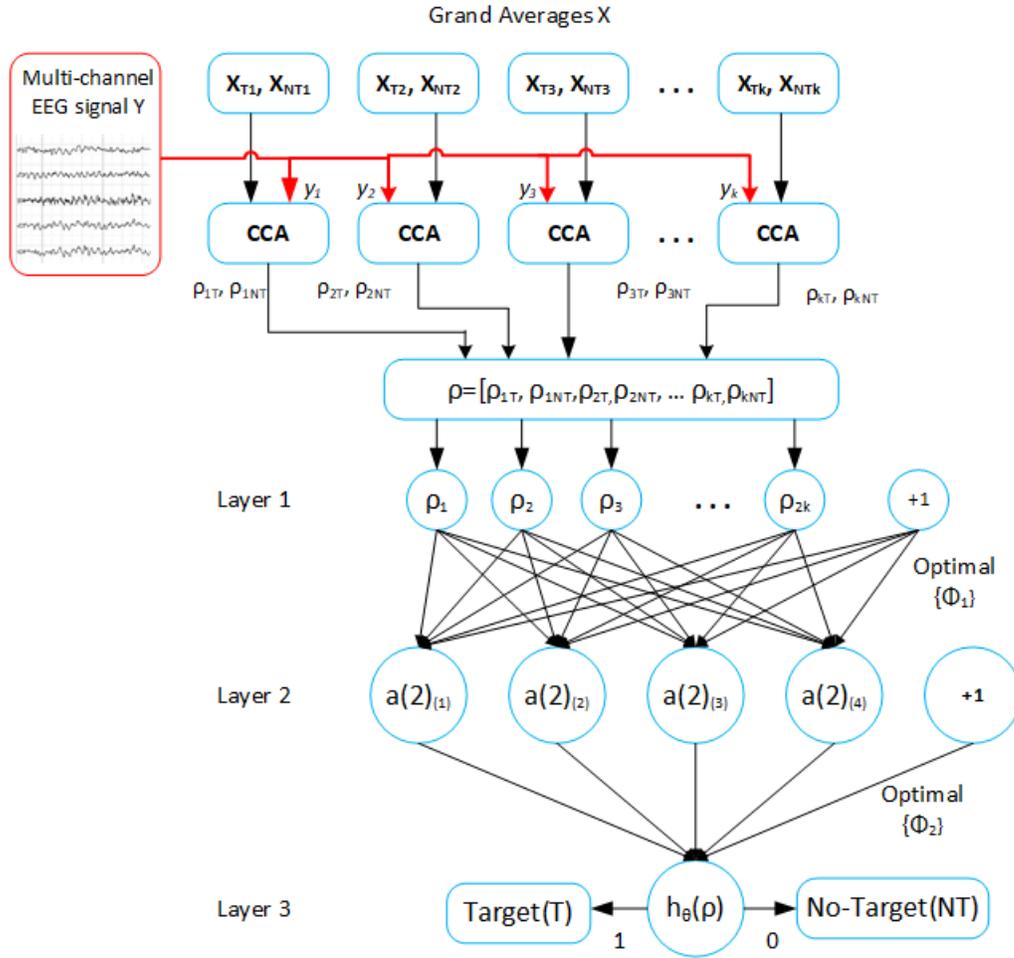


Figura 3-6: Diagrama de flujo del método propuesto basado en CCA-MLP para detectar el P300 utilizando los datos de prueba.

3.5. Métricas de comparación

3.5.1. Porcentaje de clasificación

En la literatura, una de las métricas más usadas para la comparación y evaluación de técnicas de reconocimiento de P300, corresponde al porcentaje de clasificación (Xiao, Xu, Wang, et al., 2019; Xu et al., 2016; Motlagh y Ibrahim, 2015; Tal y D.Friedman, 2019). Existen alternativas para hallar este parámetro, una de ellas corresponde a dividir el número de clasificaciones correctas (Aciertos) sobre el número de clasificaciones posibles.

$$Acc(\%) = \frac{Aciertos}{n} \cdot 100 \quad (3-6)$$

Donde n corresponde al número de muestras, que varía dependiendo del número de trials promediados(1,2,3 y 4). Este proceso se realiza con cada técnica de reconocimiento implementada en la sección 3.4.

3.5.2. Costo computacional

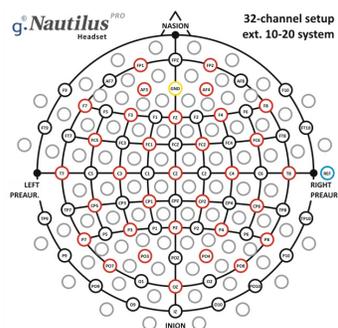
Esta variable se puede obtener de diversas formas, una de ellas corresponde a medir el tiempo de compilación del sistema durante el proceso de extracción de características y predicción del modelo, sin tener en cuenta el tiempo de entrenamiento del modelo. En este estudio se realiza usando el peor de los casos cuyo procesamiento pueda ser más demorado, por lo que se implementa para cada técnica de reconocimiento implementada en la sección 3.4 usando las señales resultantes de promediar 4 trials. Para este caso se usa la función *Tic-Toc* de Matlab en un computador con procesador intel core i5-8250 CPU @ 1.80 GHz, 8 GB de memoria RAM y sistema operativo de 64 bits.

3.6. Diseño Experimental para el registro P300

3.6.1. Sistema de adquisición EEG

G.NAUTILUS-PRO

Es un sistema médico y de adquisición de señales de EEG inalámbrico, certificado por la Conformidad Europea (CE) y Food and Drug Administration(FDA) distribuido por la empresa g.tec que transmite datos a través de la banda de 2.4 GHz con un rango de operación de aproximadamente de 10 metros. La sensibilidad de entrada es ajustable y la frecuencia de muestreo se puede configurar hasta 500 Hz (g.tec medical engineering GmbH, 2017). La Universidad Antonio Nariño cuenta con el dispositivo g.Nautilus-32-PRO en el laboratorio de simulación de la sede circunvalar, que permite el registro a través de 32 electrodos según el estándar 10-20(Baura, 2011). Más información acerca de este equipo en (Villamizar, 2019).



(a)



(b)

Figura 3-7: (a) Disposición de canales g.Nautilus-32-PRO (National Center for Adaptive Neurotechnologies, 2018). (b) Imagen real del dispositivo.

BCI2000

Es un software gratuito usado para la investigación e implementación de sistemas BCI, puede ser usado para lectura de datos, presentar estímulos y monitoreo cerebral. Los amplificadores de bioseñales de g.tec son totalmente compatibles con la plataforma BCI2000(Nacional Center for Adaptive Neurotechnologies, 2018).

3.6.2. Configuración del sistema de adquisición

Previo a realizar las sesiones de adquisición de señales de EEG, es necesario comprobar la funcionalidad del equipo. Se debe verificar que el equipo cuente con la carga suficiente y que las señales sean transmitidas de la forma correcta. Para ello se realiza la instrumentación correspondiente, disponiendo el dispositivo en el sujeto de pruebas y aplicando en cada electrodo gel conductor. La verificación de las señales e impedancias se realiza mediante la plataforma g.NeedAccess, que es el software base para los amplificadores g.tec, Figura 3-8.

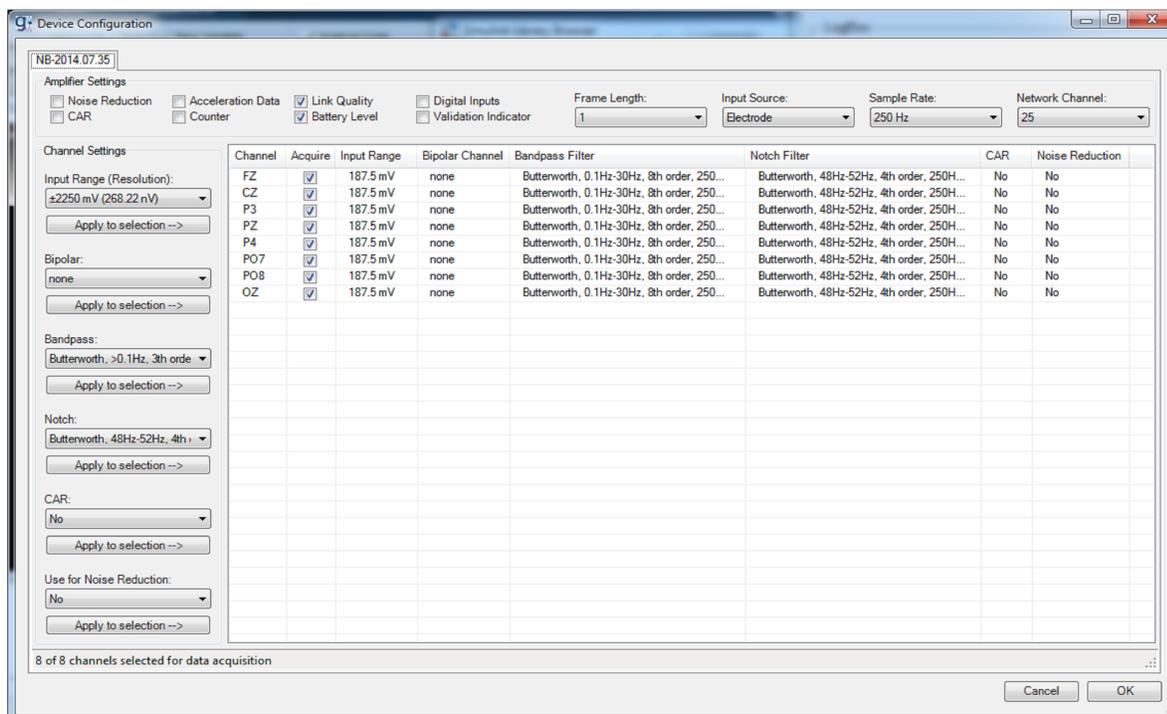


Figura 3-8: Configuración del entorno con g.NeedAccess.

Donde es necesario tener en cuenta parámetros importantes como:

- Sample Rate: Corresponde a la frecuencia de muestreo, se tiene la opción de 250 o 500 Hz, donde es recomendable establecer 250 Hz debido a que el ancho de banda de las señales EEG normalmente es hasta 60 Hz.
- Notch: Corresponde a un filtro Notch rechazabanda que se usa para eliminar el ruido de la línea, lo más indicado es entre 58 y 62 Hz.

- Bandpass: Corresponde a un filtro pasabandas digital de los canales de entrada, se puede establecer en un rango entre 0.1 y 60 Hz, aunque sus valores pueden ser escogidos según el ancho de banda de las señales EEG de interés, para este caso se define un ancho de banda entre 0.5 y 60 Hz.
- Channel-Acquire: Con el fin de reducir recursos, para P300 no es necesario tener en cuenta la totalidad de canales, se recomienda en (Karimi et al., 2019; Nacional Center for Adaptive Neurotechnologies, 2018) establecer 8 canales, Figura 3-3.

Verificación de impedancia de entrada de los electrodos

Previamente de realizar una adquisición de señales EEG es necesario verificar la impedancia de los electrodos, esto se realiza a través de la plataforma g.NeedAccess, donde el valor ideal de impedancia es menos de $30\text{ k}\Omega$ representado por el color verde. Por el contrario, si se establece una impedancia no adecuada se procede a seguir aplicando gel conductor.

Tabla 3-1: Clasificación de impedancias por color

Color	Valor
Verde	$\leq 30\text{ k}\Omega$
Amarillo	$\leq 50\text{ k}\Omega$
Azul	$\leq 100\text{ k}\Omega$
Rojo	$> 100\text{ k}\Omega$

Pruebas de visualización y verificación de las señales EEG

El dispositivo cuenta con un periodo de estabilización de aproximadamente 5 segundos, por lo que en este tiempo no se tiene en cuenta el registro. Previo a la ejecución del protocolo se realiza una inspección del comportamiento de las señales EEG, incluyendo tareas de:

- Movimiento ocular
- Movimiento mandibular

3.6.3. Definición del protocolo de adquisición

El protocolo de adquisición para señales EEG correspondientes a ERP-P300 para la Universidad Antonio Nariño es realizado teniendo en cuenta los dos protocolos anteriormente realizados en (Villamizar, 2019) para adquisición de señales EEG de ojos cerrados-abiertos e imaginación motora. También es implementado, teniendo en cuenta parámetros establecidos en (Lee et al., 2019) con el objetivo de que los recursos generados en estudios futuros y los resultados de los métodos usados en este trabajo, sean comparables.

Definición de los criterios de inclusión

Teniendo en cuenta las características expresadas en la sección 2.2 respecto al comportamiento de la señal ERP-P00 bajo aspectos físicos, psicológicos y psiquiátricos, se tienen en cuenta participantes con los siguientes criterios:

- Sujetos mayores a 18 años y menores a 76 años (Farwell y Donchin, 1988).
- Sujetos sin problemas neuromotores o cognitivos.
- El tamaño de la cabeza se debe ajustar al tamaño del casco talla M del equipo de adquisición g.Nautilus.

Objetivo del protocolo

Validar, registrar y reconocer el ERP-P300 a través de un sistema BCI en modalidad deletreador 6x6, donde el sujeto de pruebas será estimulado con el objetivo de formar una palabra.

Alcance

Número limitado de sujetos sanos, bajo condiciones de laboratorio.

Metodología del protocolo de medidas EEG

1. Fase preparatoria

- a. Conformación de grupo: Se realiza inicialmente con sujetos sanos, que pueden ser hombres o mujeres que cumplan los criterios de inclusión.
- b. Declaración del consentimiento informado: De acuerdo a la normatividad colombiana para el desarrollo de investigaciones en seres humanos consignada en la resolución 8430 de 1993 (Ministerio de salud, 1993) e internacionalmente en la declaración de Helsinki (Asociación Médica Mundial, 1964), de acuerdo a los principios éticos es requerido que el usuario sea instruido del procedimiento, los potenciales riesgos(aunque no haya ninguno), el tratamiento de los datos personales, entre otros. Posteriormente, el sujeto firmará de forma voluntaria.

2. Fase de elaboración Se siguen los siguientes pasos:

- a. La adquisición se realiza con BCI2000 con los parámetros de entorno establecidos para BCI-Speller, que son configurados como:

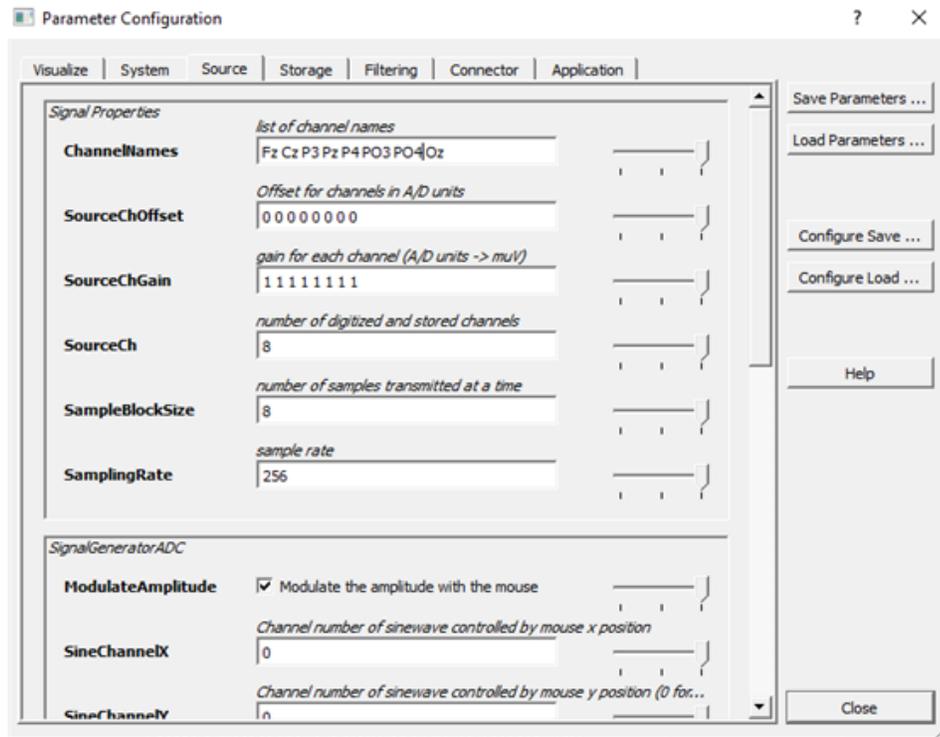


Figura 3-9: Entorno de adquisición con BCI2000 (National Center for Adaptive (Source) Neurotechnologies,2018)

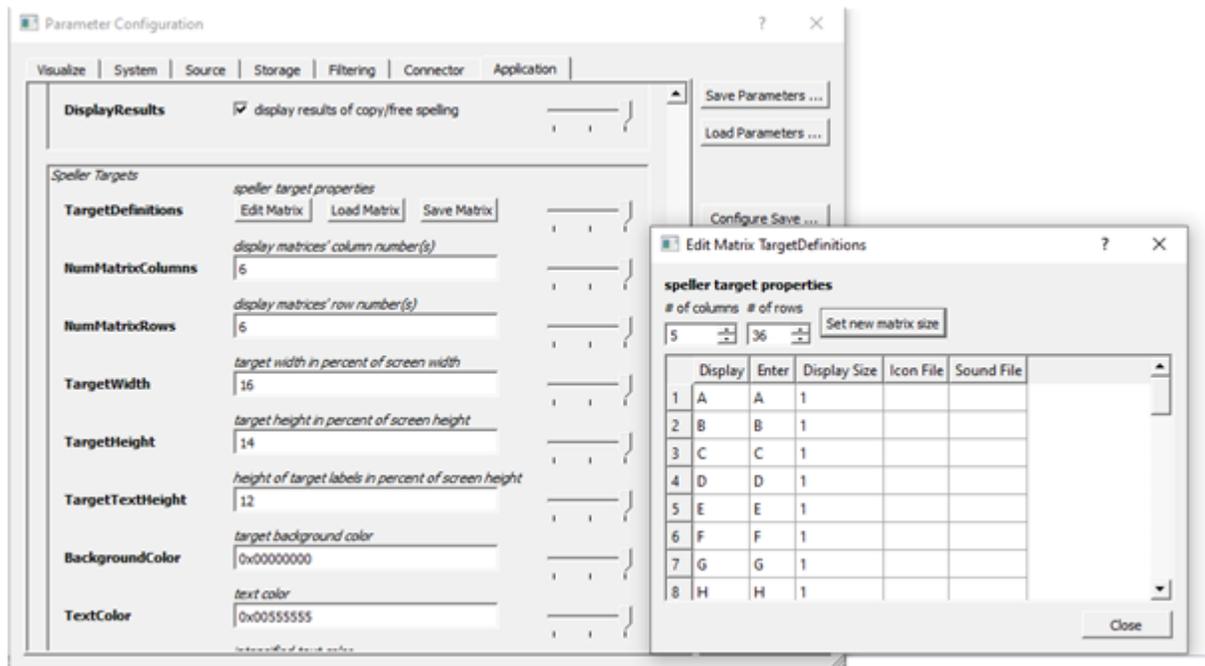


Figura 3-10: Entorno de adquisición con BCI2000 (National Center for Adaptive (Application) Neurotechnologies,2018)

Donde en Source sólo se modifica la frecuencia de muestreo de 256 Hz a 250 Hz. En Application se configura que el Speller sea de 6x6, también se establece que el número de épocas y promedios sea un número de 10, el tiempo de intervalo entre estímulo sea de 80 ms y el tiempo entre estímulos sea de 135 ms.

- b. Se realiza una obtención de parámetros en una prueba de calibración o entrenamiento, los cuales consisten en los electrodos donde mejor se observa respuesta del potencial, así como el tiempo donde hubo mayor varianza. Inicialmente se le indica al sujeto que tiene que concentrarse en una letra, con el objetivo de que cuente la cantidad de veces que esta parpadea, este procedimiento lo realiza letra por letra con la intención de formar la palabra "THEQUICKBROWNFOX", como se recomienda en (National Center for Adaptative Neurotechnologies, 2018). Los datos quedarán almacenados en la carpeta BCI2000 data.



Figura 3-11: Deletreador mostrado en la pantalla durante la fase de calibración(National Center for Adaptative Neurotechnologies,2018).

- c. Analizar la sesión de calibración de forma offline: BCI2000 proporciona una herramienta de análisis offline, que permite calcular la varianza a través del r^2 y permite identificar los canales que proporcionan información más discriminativa para realizar el reconocimiento del potencial P300 y con base a ello el sistema establece los parámetros de ponderación con el objetivo de minimizar los canales más ruidosos y maximizar los más relevantes. De los resultados de esta sesión, se obtienen las señales de referencia correspondientes a los Grand Averages(Target y No-Target).

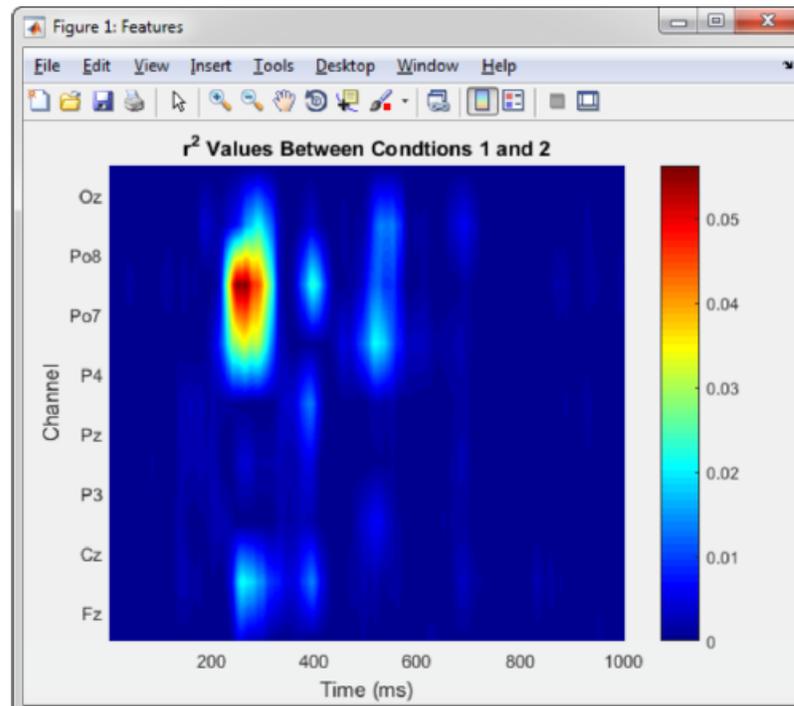


Figura 3-12: Análisis offline usando el entorno de BCI2000(National Center for Adaptive Neurotechnologies,2018).

Después del análisis offline se procede a realizar una sesión de prueba de manera on-line.

- d. Realizar una sesión de prueba: En esta fase, inicialmente se cargan los parámetros guardados en la fase de calibración a la plataforma BCI2000, adicionalmente se configura el número de trials a evaluar que en este caso sería desde 1 trial hasta 4. Posteriormente se le indica al sujeto de pruebas que a través de las mismas indicaciones anteriores, intente formar una palabra establecida por la persona que dirige la sesión, por ejemplo: "BIOINGENIERIAUAN". Las señales EEG quedarán guardadas en el mismo directorio donde quedaron guardadas las señales EEG correspondientes a la fase calibración junto con el orden de aleatoriedad de los caracteres presentados al usuario.
3. **Fase de acondicionamiento** Junto con las señales EEG obtenidas durante las fases de calibración y prueba, queda guardado el orden en el cual los caracteres del Speller fueron apareciendo durante el desarrollo del experimento, además, de establecer si en ese momento la letra resaltada correspondía a una letra objetivo(Target) o no objetivo(No-target). Haciendo uso de algoritmos generados en protocolos experimentales anteriores (Villamizar, 2019), es posible acondicionar las señales a formato **.mat** con información que se considere relevante del sujeto de pruebas, para realizar la construcción de una base de datos de señales EEG basadas en un sistema BCI-P300 con paradigma oddball.

4 Resultados y Discusión

4.1. Validación

En este estudio se evaluaron 3 técnicas nuevas para el reconocimiento de P300 usando un reducido número de trials basados en las coeficientes del análisis de correlación canónica y fue validada con dos métodos estándar reportados en la literatura. El estudio comparativo se llevó a cabo a través de los siguientes pasos:

1. Obtener los Grand Average(GA) del subconjunto de datos de entrenamiento para cada uno de los ocho canales utilizados.
2. Usar un trial para clasificar la señal P300, usando el subconjunto de datos de evaluación.
3. Utilizar el porcentaje de clasificación y el costo computacional para el reconocimiento de señales objetivo y no-objetivo como parámetro de evaluación.
4. Evaluar los algoritmos propuestos con los 2 métodos estándar.
5. Repetir los pasos del 2 al 4, usando 2,3 y 4 trials.

4.2. Grand Averages(GA)

Los GA fueron fundamentales en este estudio, debido a que estas corresponden a nuestras señales de referencia para el método CCA. Este conjunto de señales se halló a partir del gran promediado de las señales objetivo y las señales no-objetivo para cada canal. Por ejemplo, para un sujeto de pruebas:

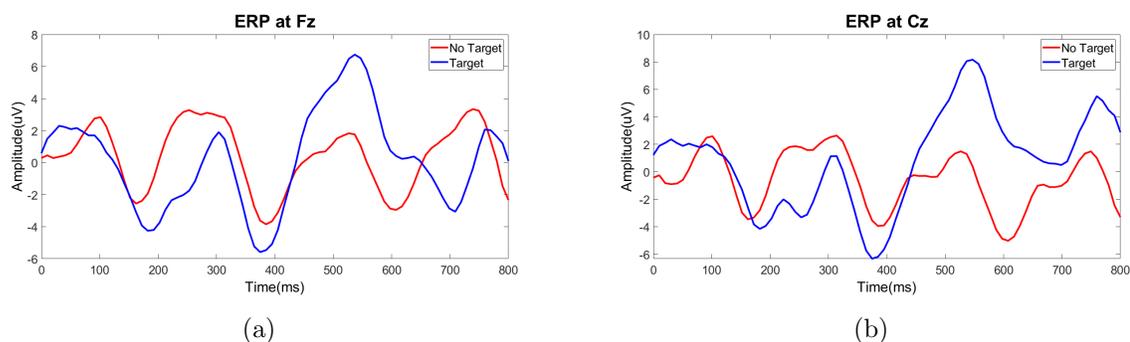


Figura 4-1: Comportamiento de las señales de referencia en los canales(a) F_z y (b) C_z .

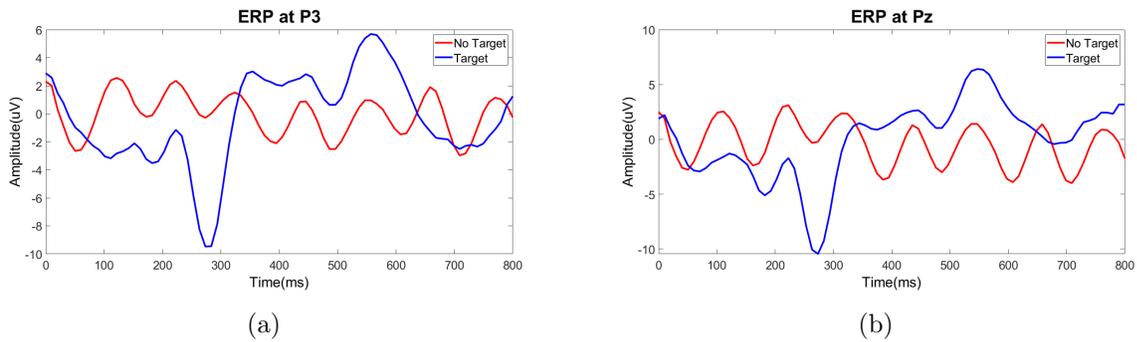


Figura 4-2: Comportamiento de las señales de referencia en los canales (a) P_3 y (b) P_z .

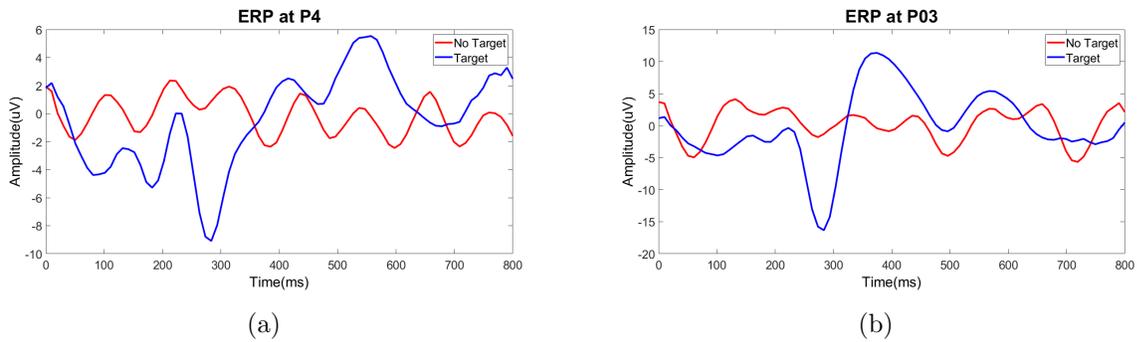


Figura 4-3: Comportamiento de las señales de referencia en los canales (a) P_4 y (b) PO_3 .

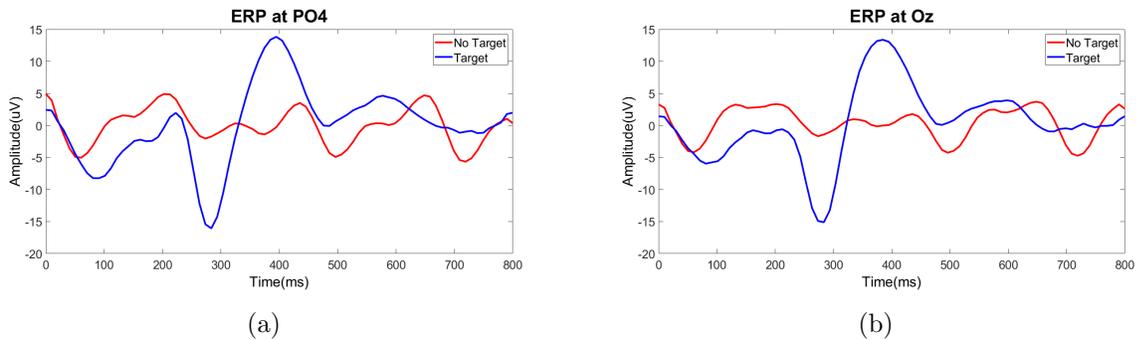


Figura 4-4: Comportamiento de las señales de referencia en los canales (a) PO_4 y (b) O_z .

Representando el comportamiento observado en las figuras 4-1, 4-2, 4-3 y 4-4 en una topografía de la corteza cerebral respecto a ciertos segmentos de tiempo de interés, se obtiene:

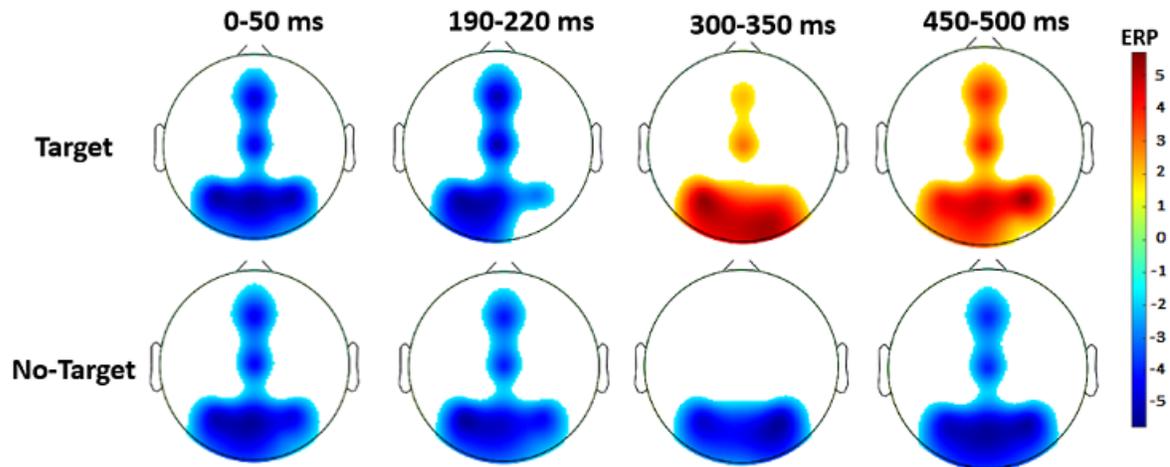


Figura 4-5: Topografía del comportamiento de las señales de referencia(objetivo y no-objetivo) en diferentes secciones de tiempo.

4.3. Análisis comparativo

Los porcentajes de clasificación de los métodos propuestos usando un único trial, se pueden observar en la Tabla 4-1.

Tabla 4-1: Porcentaje de clasificación por cada método, usando 1 trial.

Sujeto	MA-LDA	SWLDA	MA+CCA-LDA	CCA-Regresión Logística Regularizada	CCA-MLP
Sujeto 1	77.36 %	77.63 %	80.78 %	83.56 %	85.23 %
Sujeto 2	68.42 %	78.47 %	68.05 %	83.33 %	84.25 %
Sujeto 3	63.56 %	61.57 %	64.35 %	83.33 %	83.33 %
Sujeto 4	61.52 %	71.85 %	65.97 %	83.40 %	83.28 %
Sujeto 5	66.52 %	72.08 %	84.86 %	84.86 %	84.30 %
Sujeto 6	72.45 %	76.66 %	78.65 %	84.58 %	85.00 %
Sujeto 7	71.71 %	56.06 %	70.87 %	83.19 %	83.10 %
Sujeto 8	65.60 %	76.06 %	71.25 %	83.51 %	83.50 %
Sujeto 9	55.97 %	59.39 %	56.67 %	83.33 %	83.33 %
Sujeto 10	51.43 %	62.13 %	59.26 %	83.33 %	83.33 %
Mean	65.46 %	69.19 %	68.98 %	83.65 %	83.87 %

Los porcentajes de clasificación de los métodos propuestos usando 2 trials, se pueden observar en la Tabla 4-2.

Tabla 4-2: Porcentaje de clasificación por cada método, usando 2 trials.

Sujeto	MA-LDA	SWLDA	MA+CCA-LDA	CCA-Regresión Logística Regularizada	CCA-MLP
Sujeto 1	88.70 %	81.30 %	90.28 %	85.19 %	89.54 %
Sujeto 2	73.70 %	87.13 %	79.17 %	84.35 %	85.19 %
Sujeto 3	66.85 %	65.09 %	70.74 %	83.52 %	83.52 %
Sujeto 4	66.39 %	77.31 %	73.33 %	84.44 %	84.35 %
Sujeto 5	76.85 %	75.65 %	84.63 %	87.87 %	88.24 %
Sujeto 6	79.26 %	80.19 %	86.02 %	88.89 %	89.63 %
Sujeto 7	82.50 %	57.04 %	80.09 %	83.70 %	84.54 %
Sujeto 8	75.46 %	81.20 %	81.30 %	84.63 %	86.76 %
Sujeto 9	55.56 %	60.46 %	61.20 %	83.33 %	83.98 %
Sujeto 10	60.74 %	63.98 %	65.83 %	83.33 %	83.06 %
Mean	72.60 %	72.94 %	77.26 %	84.93 %	85.88 %

Los porcentajes de clasificación de los métodos propuestos usando 3 trials, se pueden observar en la Tabla 4-3.

Tabla 4-3: Porcentaje de clasificación por cada método, usando 3 trials.

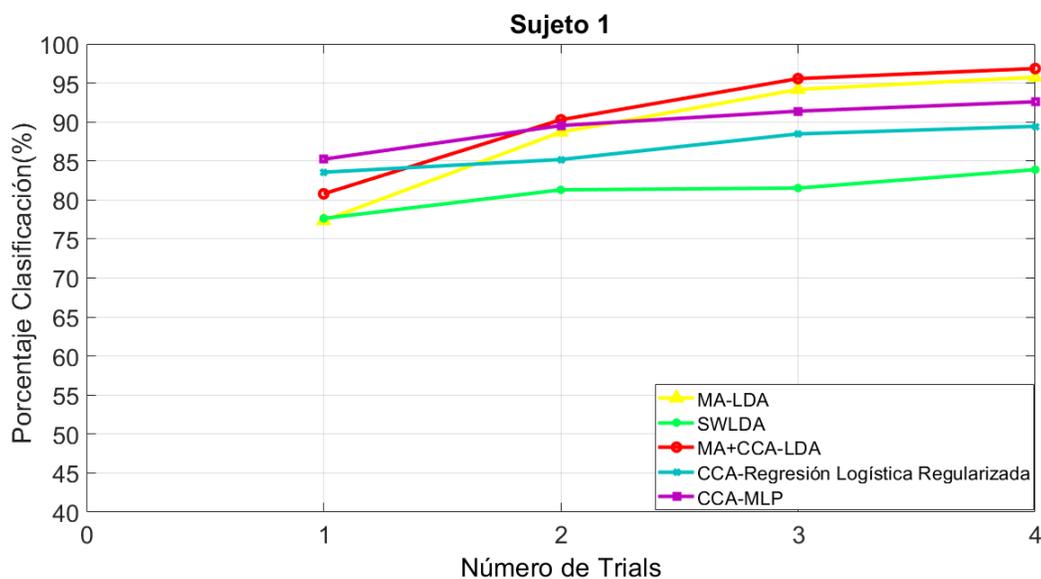
Sujeto	MA-LDA	SWLDA	MA+CCA-LDA	CCA-Regresión Logística Regularizada	CCA-MLP
Sujeto 1	94.17 %	81.53 %	95.56 %	88.47 %	91.39 %
Sujeto 2	77.22 %	90.14 %	82.50 %	85.28 %	87.36 %
Sujeto 3	74.72 %	67.78 %	75.69 %	84.31 %	83.06 %
Sujeto 4	70.42 %	82.78 %	76.81 %	85.97 %	84.86 %
Sujeto 5	85.14 %	80.56 %	92.08 %	90.97 %	92.08 %
Sujeto 6	86.53 %	85.14 %	91.81 %	89.72 %	91.11 %
Sujeto 7	85.56 %	58.19 %	86.39 %	84.86 %	85.28 %
Sujeto 8	76.17 %	85.56 %	89.17 %	87.36 %	89.03 %
Sujeto 9	58.61 %	61.81 %	65.57 %	83.47 %	83.61 %
Sujeto 10	68.33 %	66.11 %	72.78 %	83.06 %	83.19 %
Mean	77.99 %	75.96 %	82.83 %	86.35 %	87.09 %

Los porcentajes de clasificación de los métodos propuestos usando 4 trials, se pueden observar en la Tabla 4-4.

Tabla 4-4: Porcentaje de clasificación por cada método, usando 4 trials.

Sujeto	MA-LDA	SWLDA	MA+CCA-LDA	CCA-Regresión Logística Regularizada	CCA-MLP
Sujeto 1	95.74 %	83.89 %	96.85 %	89.44 %	92.59 %
Sujeto 2	81.85 %	92.78 %	85.93 %	84.81 %	87.04 %
Sujeto 3	79.26 %	66.48 %	82.22 %	84.44 %	85.37 %
Sujeto 4	73.52 %	85.37 %	81.30 %	86.85 %	88.33 %
Sujeto 5	88.15 %	82.22 %	92.78 %	92.40 %	92.22 %
Sujeto 6	91.48 %	86.11 %	95.56 %	93.15 %	95.56 %
Sujeto 7	90.19 %	60.56 %	88.70 %	85.00 %	85.37 %
Sujeto 8	85.74 %	85.93 %	92.04 %	88.70 %	90.19 %
Sujeto 9	62.04 %	65.00 %	68.70 %	83.33 %	83.89 %
Sujeto 10	73.70 %	67.78 %	75.56 %	83.15 %	82.22 %
Mean	82.17 %	77.61 %	85.96 %	87.13 %	88.31 %

Teniendo en cuenta los resultados anteriores, es posible determinar que a medida que se aumenta el número de trials promediados, independientemente del método, aumenta el porcentaje de clasificación:

**Figura 4-6:** Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 1.

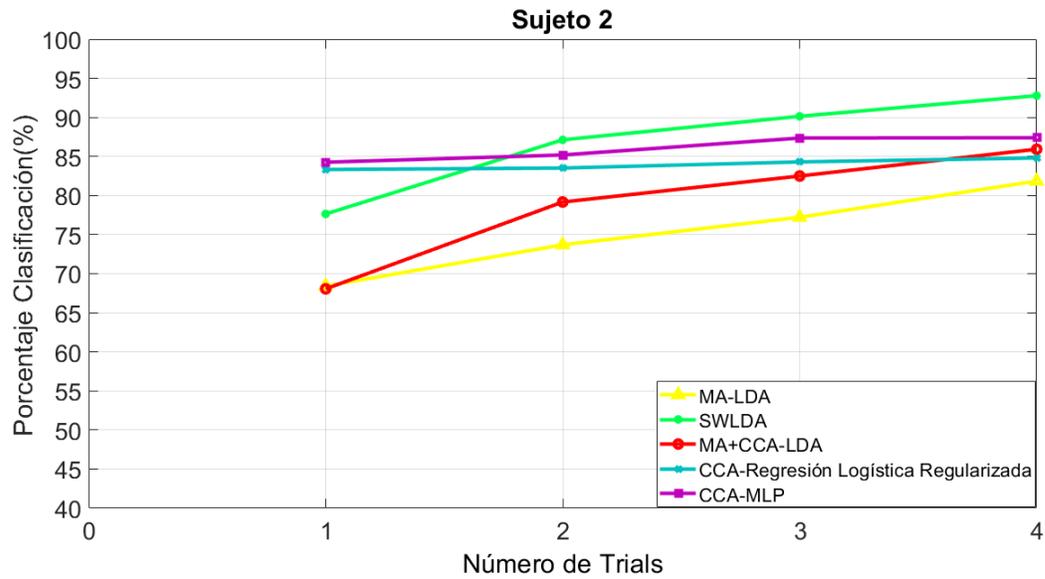


Figura 4-7: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 2.

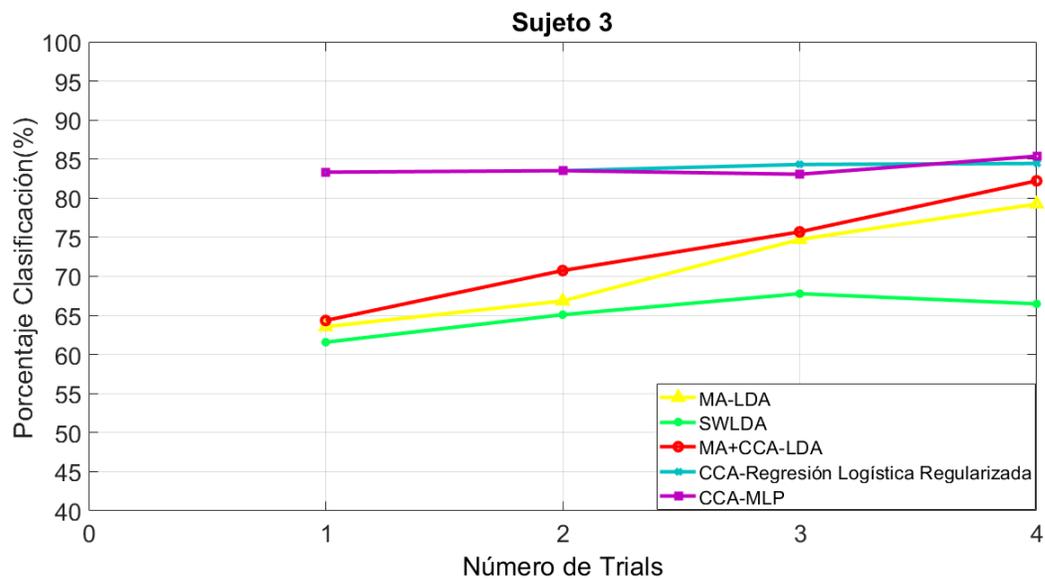


Figura 4-8: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 3.

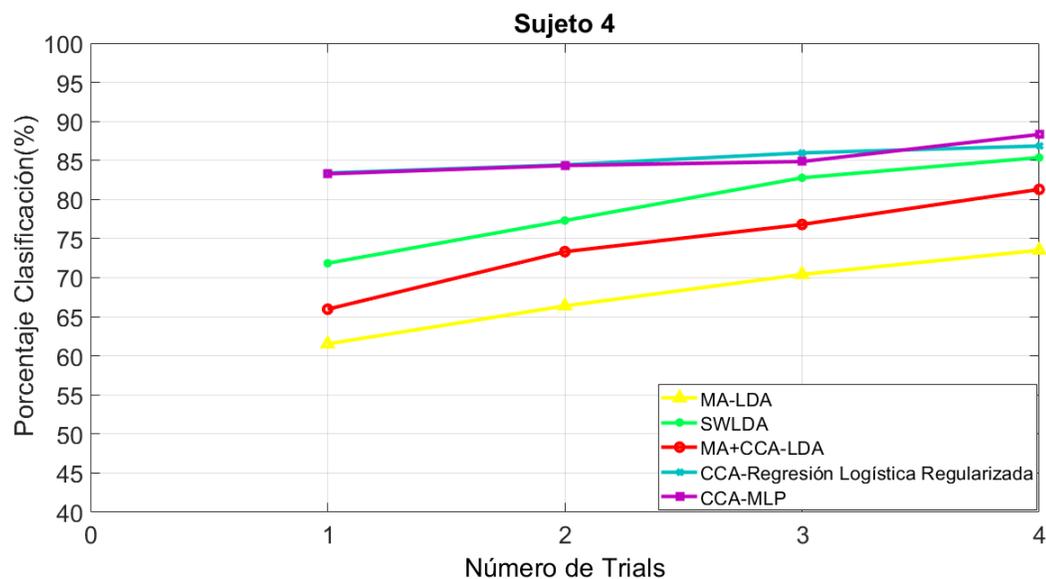


Figura 4-9: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 4.

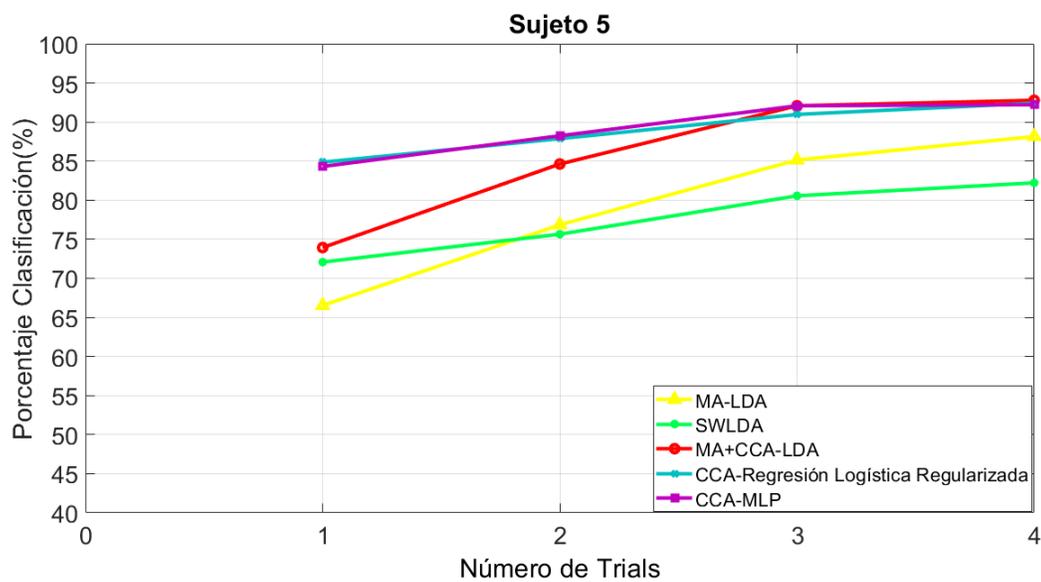


Figura 4-10: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 5.

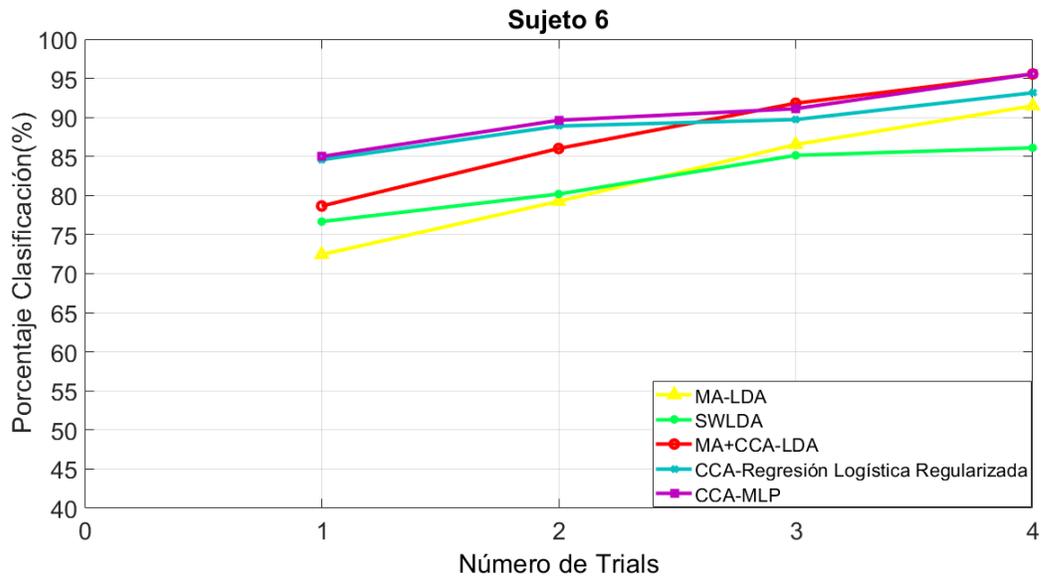


Figura 4-11: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 6.

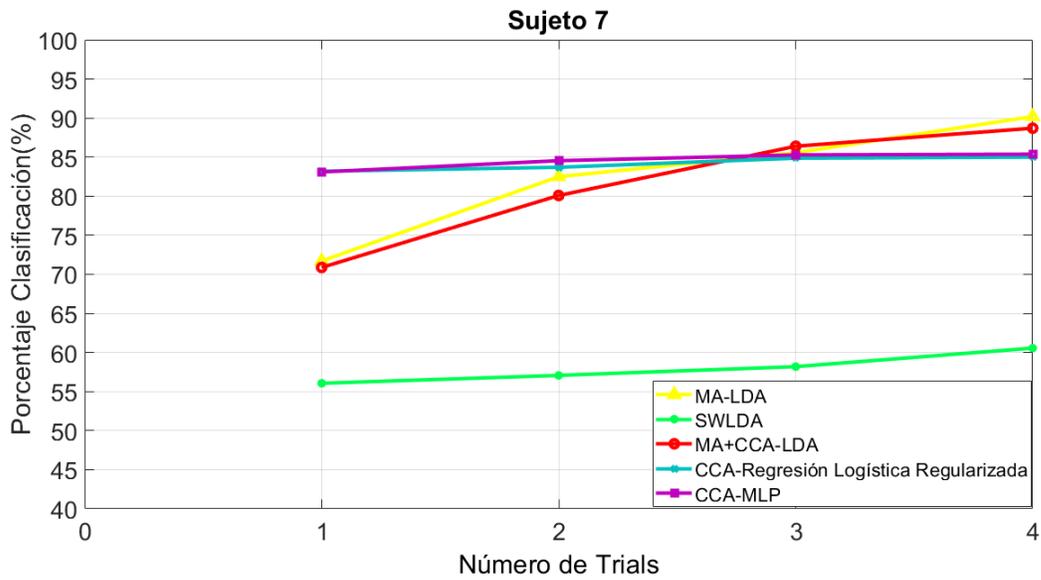


Figura 4-12: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 7.

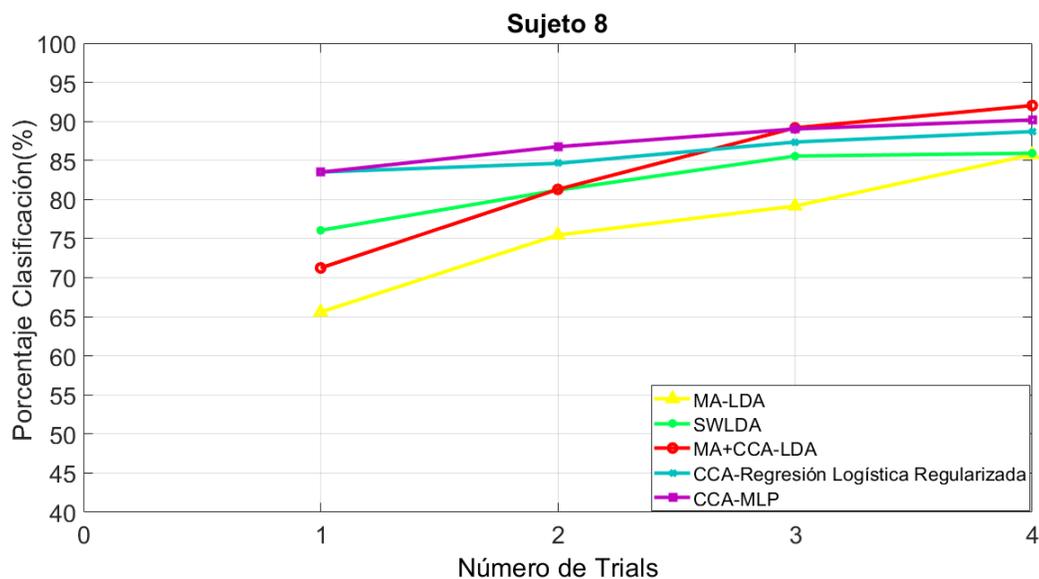


Figura 4-13: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 8.

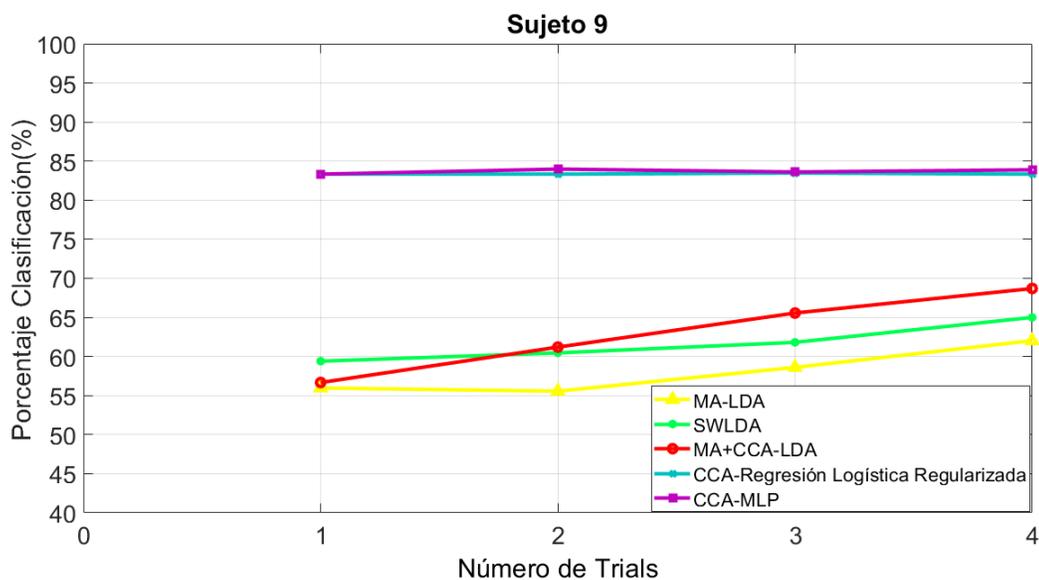


Figura 4-14: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 9.

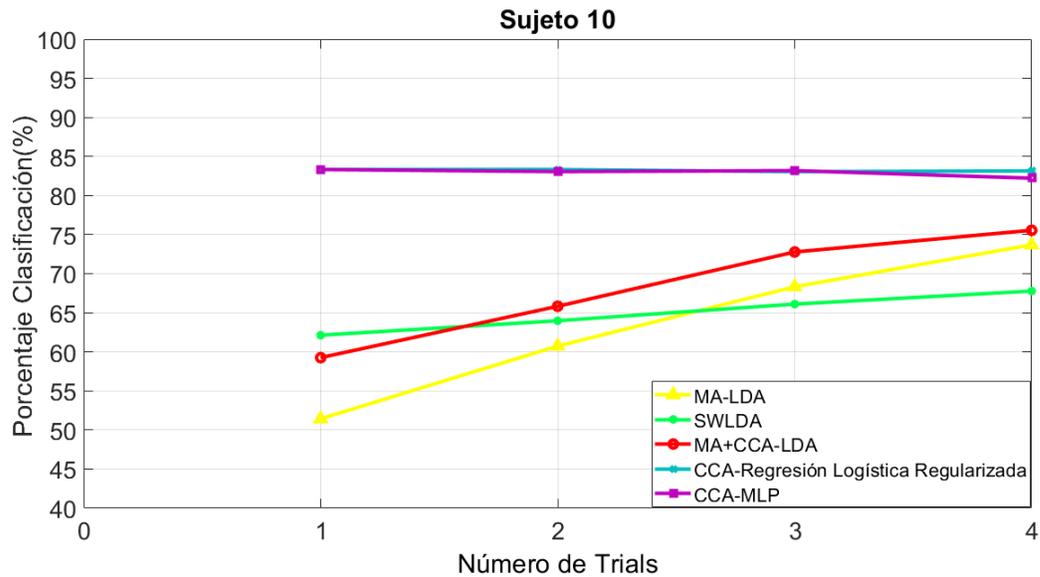


Figura 4-15: Porcentaje de clasificación de cada método para identificación de ERP-P300 correspondiente al sujeto de pruebas 10.

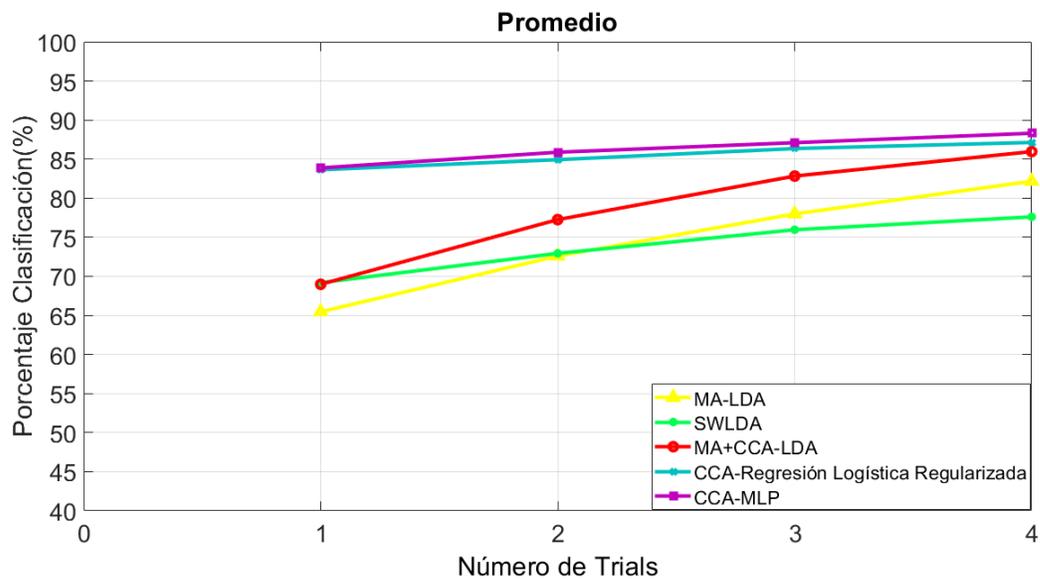


Figura 4-16: Porcentaje de clasificación media de cada método para identificación de ERP-P300.

Por otro lado el costo computacional en el peor de los casos, usando 4 trials, se ve representado en la Tabla 4-5.

Tabla 4-5: Costo computacional por cada método expresado en segundos(s), usando 4 trials

Sujeto	MA-LDA	SWLDA	MA+CCA-LDA	CCA-Regresión Logística Regularizada	CCA-MLP
Sujeto 1	0.1918	1.3595	0.5964	0.5313	0.7759
Sujeto 2	0.6230	1.0954	0.7710	0.5316	1.3348
Sujeto 3	0.2156	1.2706	0.6051	0.3756	0.7616
Sujeto 4	0.2172	1.3510	0.5939	0.3777	0.7789
Sujeto 5	0.4086	1.3640	0.6951	0.3837	0.7575
Sujeto 6	0.4689	1.2210	0.6240	0.4362	0.4389
Sujeto 7	0.2253	1.3509	0.6263	0.3757	0.7779
Sujeto 8	0.2343	1.2728	0.6062	0.3690	0.8832
Sujeto 9	0.3635	1.2894	0.6411	0.4726	0.7948
Sujeto 10	0.4115	1.3232	0.6658	0.3742	0.7721
Mean	0.3360	1.2898	0.6425	0.4228	0.8076

De acuerdo con los estudios reportados en la literatura, para un solo ensayo, los porcentajes en la clasificación usando SWLDA con un solo ensayo o trial fueron alrededor del 70 % (Xiao, Xu, Wang, et al., 2019; Xiao, Xu, Jin, et al., 2019; Kabbara et al., 2015) y el uso de más ensayos fue superior al 80 % Xu16, Rak18, en el presente trabajo se obtuvieron porcentajes de 69.19 % para un solo trial, 72.93 %, 75.95 % y 77.61 % para 2,3 y 4 trials respectivamente. Este método tuvo un buen rendimiento en este estudio, siendo el mejor en la identificación del P300 para el sujeto 2, Figura 4-7.

El MA-LDA obtuvo clasificaciones medias de 65.45 % (1 trials), 72.60 % (2 trials), 77.98 % (3 trials) y 82.16 % (4 trials). Siendo el mejor en el reconocimiento de P300 para el sujeto 7, Figura 4-12.

El comportamiento de las señales de referencia correspondientes al Grand Average (GA) permiten destacar de que a pesar de que en la literatura se establece que el canal donde el comportamiento del P300 es más evidente es el C_z (Picton, 1992), cuando la estimulación es visual, el fenómeno puede verse más notorio en O_z , como es evidente en las Figuras 4-1 y 4-4. Además, se puede observar en la topografía de la Figura 4-5 que el ERP no aparece en los canales P_3 y P_4 , lo cual puede ocasionar que los coeficientes obtenidos del CCA en estos canales sean de naturaleza ruidosa y afecten en la diferenciación del clasificador para objetivos y no objetivos.

El método propuesto basado en MA-CCA-LDA obtuvo mayor porcentaje de clasificación que el método estándar MA-LDA, con aproximadamente 65.46 % (1 trial), 72.60 % (2 trials), 77.99 % (3 trials) y 82.17 % (4 trials), lo que indica que el uso de coeficientes obtenidos del CCA usados como características puede complementar el método estándar y dependiendo el sujeto, como se puede observar en las figuras 4-6, 4-10, 4-11 y 4-13, con los sujetos de prueba 1,5,6 y 8 fue el mejor método de reconocimiento.

Por otro lado el método basado en CCA con Regresión Logística Regularizada obtuvo un buen rendimiento, especialmente usando un único trial donde su clasificación media fue de aproximadamente 83.65 %. Obtuvo también porcentajes de 84.93 %(2 trials), 86.35 %(3 trials) y 87.13 %(4 trials). Obtuvo su mejor rendimiento con el sujeto 10, Figura 4-15.

El método CCA-MLP, fue en general la técnica que mejor rendimiento obtuvo con porcentajes en la clasificación de aproximadamente: 83.87 %(1 trial), 85.88 %(2 trials), 87.09 %(3 trials) y 88.31 %(4 trials). Además de ser el mejor método de reconocimiento con los sujetos 3, 4, 6 y 9, Figuras 4-8,4-9, 4-11 y 4-14.

Según (Nacional Center for Adaptative Neurotechnologies, 2018) se obtiene que en promedio, durante el desarrollo de un experimento usando un sistema BCI-P300 en tiempo real, la exactitud más óptima se encuentra al promediar las señales correspondientes a 5 trials, esto donde el sistema usa un clasificador SWLDA y un filtraje espacial basados en ICA. Los resultados en este trabajo de grado permiten observar que los métodos de reconocimiento basados en CCA pueden llegar a ser mejor que el estándar SWLDA, al obtener un porcentaje de clasificación considerable usando menos de 4 trials, destacando su comportamiento con un único trial. Ahora, teniendo en cuenta estas características, puede ser viable la combinación con otras técnicas que permitan una mayor diferenciación entre señales objetivos y no objetivos tales como el uso de filtrajes espaciales o características en tiempo-frecuencia(Wavelet), que permitan mejorar estos porcentajes de clasificación usando un único trial.

Tabla 4-6: Técnicas para el reconocimiento de P300 según paradigma Oddball en Speller 6x6 reportadas en la literatura

Técnicas de extracción	Método de clasificación	Aplicación	Porcentaje de clasificación	Número de ensayos (Trials)	Referencia
Mean Amplitude	LDA	Speller 6x6	90 %	10	(Krusienski et al., 2007, 2008)
Datos normalizados y submuestreados a 32 Hz	BLDA, FLDA y SWLDA	Speller 6x6	81.7 %	1	(Fazel y Abhari, 2009)
Filtros espaciales basados en ICA	SWLDA	Speller 6x6	70 %	1	(Xiao, Xu, Jin, et al., 2019)
Coefficientes de la transformada Wavelet	SVM y Regresión Logística	Speller 6x6	60-96 %	1	(Motlagh y Ibrahim, 2015)
Datos obtenidos del Grand Average	Red Neuronal Convolutiva y Recurrente	Speller 6x6	99 % y 97 %	10	(Cecotti y Graeser, 2011; Tal y D.Friedman, 2019)

Teniendo en cuenta los porcentajes de clasificación reportados en la literatura expresados en la tabla 2-3 y los resultados obtenidos en este trabajo de grado, ver Figura 4-16, es bueno resaltar que se logró un aumento en los porcentajes de clasificación correspondientes a un único trial, donde en la literatura se reporta un máximo de 81.7% y en este trabajo se obtienen 83.65% y 83.87% usando los métodos CCA-Regresión Logística Regularizada y CCA-MLP respectivamente. Además, pese a que usando otros métodos se puede alcanzar porcentajes de clasificación cercanos al 100%, se observa que estos requieren de mayor costo computacional y mayor latencia durante la adquisición en tiempo real(10 trials), por lo que los nuevos métodos formulados en este trabajo son de impacto, debido a que permiten el reconocimiento de P300 con un porcentaje aceptable, usando menos número de trials y técnicas matemáticas menos complejas.

También es posible visualizar el incremento porcentual en la clasificación en cada método, respecto al número de trials, ver Figura 4-17.

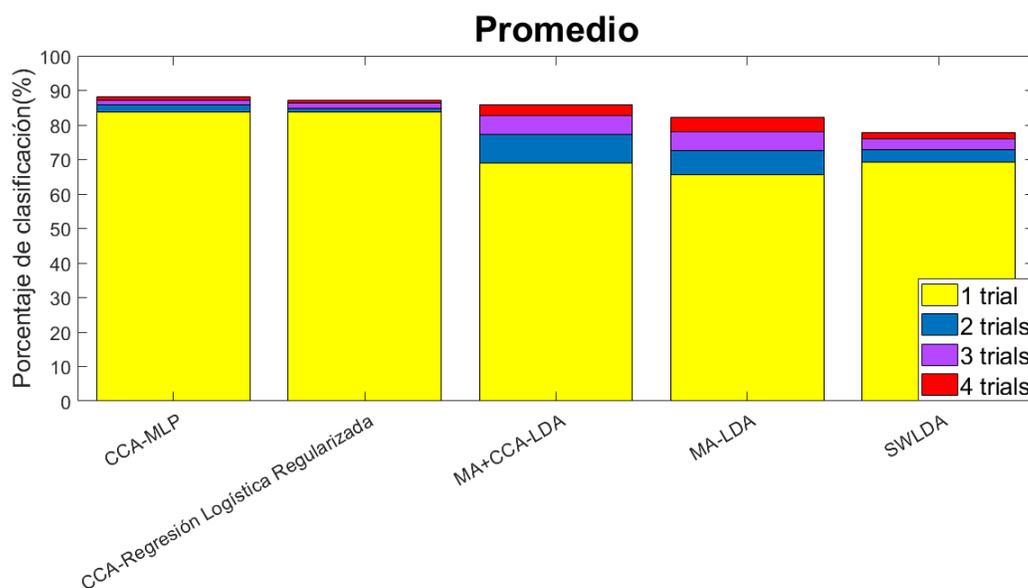


Figura 4-17: Aumento en el porcentaje de clasificación de cada método respecto al número de trials utilizados.

Finalmente, respecto al costo computacional, la variedad en la naturaleza de los algoritmos utilizados permiten establecer cuales tienen mejor rendimiento en el tiempo de respuesta para la clasificación entre objetivos y no objetivos usando las mismas características de entrada, con base en esto el método más liviano fue el MA-LDA con un promedio de tiempo de ejecución de 0.3360 segundos, seguido por el CCA-Regresión Logística Regularizada con 0.4228 segundos, el MA-CCA-LDA con un promedio de 0.6425 segundos, el MA-MLP con un promedio de 0.8076 segundos y finalmente el SWLDA con 1.2898 segundos. A pesar de que el mejor método en porcentaje de clasificación (CCA-MLP) no sea el que tenga mejor rendimiento en tiempo, si se tiene en cuenta que el estudio se realizó utilizando un mínimo número de trials o ensayos, en la implementación de un sistema tiempo real el uso de un menor número de repeticiones puede compensar el costo

computacional del algoritmo.

5 Conclusiones

5.1. Conclusiones

En los últimos años, la investigación de sistemas BCI ha tenido un alto crecimiento así como su aplicación en la ingeniería de rehabilitación. El impacto del surgimiento de esta tecnología ha motivado a la comunidad científica a desarrollar nuevas técnicas que permitan la traducción de la actividad cerebral. Este trabajo de grado abordó un estudio comparativo de técnicas de reconocimiento de Potenciales Relacionados a Eventos-P300 con el fin de generar un algoritmo adecuado para la implementación de un sistema BCI-P300 en tiempo real.

Dando respuesta a los objetivos planteados al inicio del presente trabajo, Se definieron las especificaciones del sistema BCI para implementar un deletreador o Speller con activación P300 de 6x6. Se desarrolló el estudio comparativo utilizando una base de datos disponible al público con las especificaciones mencionadas anteriormente (Lee et al., 2019).

Se implementaron 5 algoritmos en la base de datos mencionada anteriormente, 2 altamente reportados en la literatura: MA-LDA(Lee et al., 2019; Hwang et al., 2017) y SWLDA(Xiao, Xu, Wang, et al., 2019; Kabbara et al., 2015; Xiao, Xu, Jin, et al., 2019) y 3 nuevas propuestas cuya característica principal consistió en el uso de coeficientes obtenidos del CCA con una señal de referencia correspondiente a los Grand Average(GA) de cada canal y sujeto de pruebas: MA-CCA-LDA, CCA-Regresión Logística Regularizada y CCA-MLP.

El procedimiento se realizó usando las señales promedio de 1 trial, 2 trials, 3 trials y 4 trials usando como métrica de evaluación el porcentaje de clasificación y costo computacional. En general, el método con mejor rendimiento respecto a la precisión fue el CCA-MLP, seguido por el CCA-Regresión Logística Regularizada, el MA-CCA-LDA, el MA-LDA y por último SWLDA. Por otro lado, respecto al costo computacional el método más liviano fue el MA-LDA y el más pesado fue el SWLDA. Esto permite concluir que por razones lógicas los métodos basados en Machine learning como regresiones o redes neuronales suelen tener mayor costo computacional. No obstante, como resultado de este trabajo de grado se pudo observar un porcentaje de clasificación aceptable de estos métodos usando un número reducido de trials, lo que permitiría una disminución de latencia en un sistema en tiempo real, que compensaría el aumento del costo computacional.

Los nuevos métodos basados en CCA permitieron demostrar que esta técnica puede ser viable en la implementación de sistemas BCI en tiempo real, debido a que consumen mayor tiempo de computación, requieren un reducido número de trials o ensayos, lo que en un sistema en tiempo

real puede ahorrar recursos. Sin embargo, se observó en el desarrollo de este trabajo, que existieron canales donde el comportamiento de los Grand Averages (GA) no fue el más efectivo, como sucedió en los canales P_3 y P_4 lo que pudo ocasionar que el desempeño del método propuesto no tuviera un mayor porcentaje de clasificación, lo que quiere decir que estos métodos pueden ser mejorados en futuros estudios. A partir de esto, también se puede establecer que existen otras formas de obtener coeficientes del CCA que permitan la identificación del P300, como por ejemplo usar como referencia señales simuladas con un comportamiento específico tal como se usa en la literatura para los potenciales evocados (Blanco y Ruiz, 2020) o por otro lado, se puede ver la posibilidad de usar como características los coeficientes del CCA al realizar correlaciones entre canales.

En este trabajo se usaron los coeficientes obtenidos del CCA junto con la Regresión Logística Regularizada y el Perceptrón Multicapa de forma independiente, no obstante el comportamiento del MA+CCA-LDA permite concluir que la combinación de estas características pueden complementarse entre sí para mejorar el porcentaje de clasificación.

Por otro lado, se desarrolló un protocolo de adquisición para la Universidad Antonio Nariño, teniendo en cuenta los lineamientos de los anteriormente ya desarrollados en (Villamizar, 2019), con el objetivo de implementarlo para la realización de una base de datos de ERP-P300 y el desarrollo de un sistema en tiempo real basado en el clásico deletreador o Speller.

5.2. Trabajos Futuros

Los sistemas BCI al ser un tema de investigación tan amplio y reciente, permiten abordar múltiples oportunidades de trabajo en entorno a este trabajo de grado, entre ellos:

- La implementación del protocolo de adquisición en el laboratorio de la Universidad Antonio Nariño usando el equipo g-Nautilus y el software BCI2000 con el fin de la elaboración de una base de datos propia y la implementación de un sistema en tiempo real basado en el Speller.
- El método CCA a pesar de no ser implementado frecuentemente con ERP, demostró que puede generar resultados interesantes en el momento del reconocimiento de P300, por lo que se proponen nuevos métodos usando esta característica y diferentes clasificadores, así como el uso de características híbridas con las reportadas en la literatura. Como también la implementación de otras técnicas en la fase de extracción como filtraje espacial, ICA, PCA, Transformada Wavelet, entre otros.
- El comportamiento de la señal P300 puede variar dependiendo las características físicas, psicológicas y psiquiátricas del sujeto. Por lo que el estudio profundo de esta señal, junto con otras disciplinas, puede permitir el diagnóstico de enfermedades o trastornos, o por otro lado, permite un mejor desarrollo del criterio de inclusión generando mejores resultados.
- El diseño de otros sistemas BCI con sus respectivos protocolos basados en ERP-P300 usando otro tipo de estimulación como auditiva, somatosensorial o visual con ciertas modificacio-

nes. Así mismo, como es reportado en la literatura también es posible la implementación de sistemas híbridos, de los cuales se puede destacar el sistema BCI basado en P300-SSVEP.

- se proyecta la implementación del algoritmo validado en este trabajo para el desarrollo de un sistema en tiempo real BCI-P300 enfocado hacia la línea de investigación "Neuroprótesis Motora basada en las Tecnologías Brain-Computer Interface (BCI) y estimulación eléctrica muscular (EEM) para rehabilitación Funcional-Fase I" dirigida por el grupo de Bioingeniería de la UAN.

5.3. Artículos obtenidos en el trabajo

- Con base en los resultados de este trabajo de grado, el artículo titulado **A Novel Method based on Regularized Regression Logistic and CCA for P300 Detection using a Reduced Number of EEG Trials** fue sometido a revisión en la revista **Computer Methods in Biomechanics and Biomedical Engineering** el día 30 de marzo del 2020.

Referencias

- Abdulkader, S., Atia, A., Mostafa, S., y Mostafa, M. (2015). Brain computer interfacing: Applications and challenges. *Egyptian Informatic Journal*, 16, 213-230.
- Abiri, R., Borhani, S., Sellers, E., Jiang, Y., y Zhao, X. (2018, 11). A comprehensive review of EEG-based brain-computer interface paradigms. *Journal of Neural Engineering*, 16.
- Al-Fahoum, A., y Al-Fraihat, A. (2014). Methods of EEG signal features extraction using linear analysis in frequency and time-frequency domains. *ISRN Neuroscience*, 1-7.
- Ameera, A., A.Saidatul, y Ibrahim, Z. (2018). Analysis of EEG spectrum bands using power spectral density for pleasure and displeasure state. En *IOP conference series: Materials science and engineering*.
- Asociación Médica Mundial, A. (1964). *Declaración de helsinki*.
- Bai, O., Kelly, G., Fei, D., Murphy, D., Fox, J., Burkhardt, B., ... Soars, J. (2015). A wireless, smart EEG system for volitional control of lower-limb prosthesis. En *Tencon 2015 - 2015 IEEE region 10 conference* (p. 1-6).
- Basar, E., y A.Duzgun. (2015). The clair model: Extention of bronnmanns areas based on brain oscillations and connectivity. *International Journal of Psychophysiology*, 103, 185-198.
- Baura, G. (2011). *Medical device technologies:a system-based overview using engineering standars*. San Diego(CA): Oxford Academic Press.
- Becedas, J. (2012). Brain-machine interfaces: Basis and advances. *IEEE Transactions on Systems, Man and Cybernetics-Part C: Applications and Reviews*, 42(6), 825-836.
- Blanco, C., y Ruiz, A. (2020). Caracterización de señales de EEG relacionadas a potenciales evocados visuales en estado estacionario. *Revista Ontare*, 7.
- Boelts, J., Cerquera, A., y Ruiz, A. (2015). Decoding of imaginary motor movements of fists applying spatial filtering in a BCI simulated application. En *International work-conference on the interplay between natural and artificial computation (IWINAC 2015)*. Elche, Spain.
- Bolduc-Teasdale, J., Jolicoeur, P., y McKerral, M. (2012). Multiple electrophysiological markers of visual-attentional processing in a novel task directed toward clinical use. *Journal of ophthalmology*, 2012, 618-654.
- Bright, D., Nair, A., Salvekar, D., y Bhisikar, S. (2016). EEG-based brain controlled prosthetic arm. En *2016 conference on advances in signal processing (CASP)*. Pune, India.
- Brouwer, A., y Erp, J. V. (2010). A tactile P300 brain-computer interface. *Frontier in Neuroscience*, 4, 1-19.
- Caicedo, E., y López, J. (2009). *Una aproximación práctica a las redes neuronales*. Cali: Programa editorial universidad del Valle.
- Cecotti, H., y Graeser, A. (2011). Convolutional neural networks for P300 detection with application to brain-computer interfaces. *IEEE transactions on pattern analysis and*

- machine intelligence*, 33, 433-45.
- Chaudary, U., Birbaumer, N., y Ramos, A. (2016). Brain-computer interfaces for communication and rehabilitation. *Nature Reviews Neurology*, 12, 513-525.
- Chiou, E., y Puthusserypady, S. (2016). Filter feature extraction methods for P300 BCI speller: A comparison. En *2016 IEEE international conference on systems, man, and cybernetics*. Budapest, Hungary.
- Elsawy, A., Eldawlatly, S., Taher, M., y Aly, G. (2013). A principal component analysis ensemble classifier for P300 speller applications. En *8th international symposium on image and signal processing and analysis (ISPA)*.
- Farwell, L., y Donchin, E. (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and clinical Neurophysiology*, 70, 510-523.
- Fazel, R., y Abhari, K. (2009). A region-based P300 speller for brain-computer interface. *Electrical and Computer Engineering, Canadian Journal of*, 34, 81 - 85.
- Frolov, A., Mokienko, O., Lyukmanov, E. K. S., R. and Biryukova, Lydia, T., Georgy, N., y Yulia, B. (2017). Post-stroke rehabilitation training with a motor-imagery-based brain-computer interface (BCI)-controlled hand exoskeleton: A randomized controlled multicenter trial. *Frontiers in Neuroscience*, 11, 400.
- Gómez, J., y Departamento Administrativo Nacional de Estadística, D. (2008). *Discapacidad*. url <https://www.dane.gov.co/index.php/estadisticas-por-tema/demografia-y-poblacion/discapacidad>.
- g.tec medical engineering GmbH. (2017). Instruction for use v1.16.06 g.nautilus pro [Manual de software informático]. Schiedlberg.
- Gupta, S., y Singh, H. (1996). Preprocessing EEG signals for direct human-system interface. En *Proceedings IEEE international joint symposia on intelligence and systems*.
- Gámez Albán, H., Cabrera, J., Salas, O., y Bravo Bastidas, J. (2016). Aplicación de mapas de kohonen para la priorización de zonas de mercado: una aproximación práctica. *Revista EIA*, 13, 157-169.
- Haider, A., y Fazel, R. (2017). *Chapter2: applications of p300 event related potential in brain computer interface*. Croatia: Oxford Academic Press.
- Hastie, T., Tibshirani, R., y Friedman, J. (2009). *The elements of statistical learning*. New York (NY): Springer.
- Hohne, J., Tangermann, M., y Towards, M. (2014). User-friendly spelling with an auditory Brain Computer Interface: The charstreamer paradigm. *Plos ONE*, 9.
- Hwang, J., Lee, M., y Lee, S. (2017). A brain-computer interface speller using peripheralstimulus-based SSVEP and P300. En *5 th international winter conference on brain-computer interface(BCI)*. Sabuk, South Korea.
- Kabbara, A., Khalil, M., El-Falou, W., Eid, H., y Hassan, M. (2015). Functional brain connectivity as a new feature for P300 speller. *PLOS One*, 11, 1-18.
- Karimi, S., Mijani, A., Talebian, M., y Mirzakuchaki, M. (2019). Comparison of the P300

- detection accuracy related to the BCI speller and image recognition scenario. *Arxiv*, 1912.11371.
- Kołodziej, M., Majkowski, A., y Rak, R. (2010). Matlab FE-toolbox - an universal utility for feature extraction of EEG signals for BCI realization. *Przeeglpmd Elektrotechniczny*, 86, 44-46.
- Krusiński, D., Sellers, E., Cabestaing, F., Bayouhd, S., Mcfarland, D., Vaughan, T., y Wolpaw, J. (2007). A comparison of classification techniques for the P300 speller. *Journal of neural engineering*, 3, 299-305.
- Krusiński, D., Sellers, E., Cabestaing, F., Bayouhd, S., Mcfarland, D., Vaughan, T., y Wolpaw, J. (2008). Toward enhanced P300 speller performance. *Journal of neuroscience methods*, 167, 15-21.
- Kumar, J., y Bhuvaneswari, P. (2012). Analysis of electroencephalography (EEG) signals and its categorization—a study. *Clinical Neurophysiology*, 38, 2525-2536.
- Kwak, N., Müller, K., y Lee, S. (2017). A convolutional neural network for steady state visual evoked potential classification under ambulatory environment. *PLOS ONE*, 12(2), 1-20.
- Lee, H., Kwon, Y., Kim, Y., Kim, H., Lee, Y., Williamson, J., ... Lee, S. (2019). EEG dataset and open BMI toolbox for three BCI paradigms: an investigation into BCI illiteracy. *Giga-Science*, 8, 1-16.
- Li, F., Yi, C., Jiang, Y., Liao, Y., Si, Y., Dai, J., ... Xu, P. (2019). Different contexts in the oddball paradigm induce distinct brain networks in generating the P300. *Frontiers in Human Neuroscience*, 12, 520.
- Li, J., Gu, R., Ji, H., Pang, Z., y Li, M. (2016). Interaction study of SSVEP and P300 in electroencephalogram. En *Paper presented at: Proceedings of the PIERS Progress in Electromagnetic Research Symposium*. Shanghai, China.
- Materka, A., y Poryzala, P. (2014). A robust asynchronous ssvpe brain-computer interface based on cluster analysis of canonical correlation coefficients. *Advances in Intelligent Systems and Computing*, 300, 3-14.
- McFarland, D., y Wolpaw, J. (2011). Brain-computer interfaces for communication and control. *Communications of the ACM*, 5, 60-66.
- Mendoza, O. (2017). *Development of a Hybrid Brain-Computer Interface for Autonomous System* (Tesis Doctoral no publicada). Free University of Berlin.
- Ministerio de salud, M. (1993). *Resolucion numero 8430 de 1993*.
- Motlagh, E., y Ibrahim, F. (2015). Developing an optimized single-trial P300-based brain computer interface system. En *International Conference for Innovation in Biomedical Engineering and Life Sciences*. Putrajaya, Malaysia.
- Muller-Putz, G., y Pfurtscheller, G. (2008). Control of an electrical prosthesis with an SSVEP-based BCI. *IEEE Transactions on Biomedical Engineering*, 55, 361 - 364.
- Murphy, D., Bai, O., Gorgey, O., Fox, A., Lovegreen, J., William, T., ... Fei, D. (2017). Electroencephalogram-based brain-computer interface and lower-limb prosthesis con-

- trol: A case study. *Frontiers in Neurology*, 8, 696.
- Nacional Center for Adaptative Neurotechnologies, N. (2018). *BCI2000*. url https://www.bci2000.org/mediawiki/index.php/Main_page.
- Nicolas, L., y Gomez, J. (2012). Brain computer interfaces, a review. *Sensors*, 12(6), 1211-1279.
- Niedermeyer, E., y da Silva, F. (2004). *Electroencephalography:basic principles, clinical applications and related fields*. Philadelphia(PA): Lippincot Williams Wilkins.
- Ono, T., Shindo, K., Kawashima, K., Ota, N., Ito, M., Ota, T., ... Ushiba, J. (2014). Brain-computer interface with somatosensory feedback improves functional recovery from severe hemiplegia due to chronic stroke. *Frontiers in Neuroengineering*, 7, 19.
- Orellana, D., y Cuenca, J. (2017). Comparative study of feature extraction methods and classification of event-related potentials P300. *CEDAMAZ*, 7, 71-82.
- Patelia, V., y Patel, M. (2019). Brain computer interface: Applications and P300 overview. En *10th ICCCNT International Conference on Computing, Communication and Networking Technologies*. Kanpur, India.
- Piccione, F., Giorgi, F., Tonin, P., Priftis, K., Giove, S., Silvoni, S., ... Beverina, F. (2006). P300-based brain computer interface: Reliability and performance in healthy and paralysed participants. *Clinical Neurophysiology*, 117(3), 531 - 537.
- Picton, T. (1992). The P300 a wave of the human event-related potential. *Journal of Clinical Neurophysiology*, 9, 456-479.
- Pugh, G. (1977). *The biological origin of human values*. Michigan(MI): Basic Books.
- Raksha, N., Sahana, S., Sahana, P., y Niranjana, K. (2018). Stepwise and quadratic discriminant analysis of P300 signals for controlling a robot. En *2018 international conference on networking, embedded and wireless system (ICNEWS)*. Bangalore, India.
- Rezeika, A., Benda, M., Stawicki, P., Gembler, F., Saboor, F., y Volosyak, I. (2018). Brain-computer interface spellers: A review. *Brain Sciences*, 8, 1-38.
- Seeck, M., Koessler, L., Bast, T., Leijten, F., Michel, C., Baumgartner, C., ... Beniczky, S. (2017). The standardized EEG electrode array of the IFCN. *Clinical Neurophysiology*, 128(10), 2070-2077.
- Shalev, S., y Ben, D. (2014). *Understanding machine learning: From theory to algorithms* (draft ed.). CUP.
- Spuler, M., Walter, A., Rosenstie, W., y Bogdan, M. (2014). Spatial filtering based on canonical correlation analysis for classification of evoked or event-related potentials in EEG data. *IEEE transactions on neural systems and rehabilitation engineering.*, 22, 1097-1103.
- Sur, S., y Sinha, V. (2009). Event-related potential: An overview. *Ind Psychiatry J*, 18(1), 70-73.
- Tal, O., y D.Friedman. (2019). Recurrent neural networks for P300-based BCI. *arXiv*.
- Tang, J., Liu, Y., Hu, D., y Zhou, Z. (2018). Towards BCI-actuated smart wheelchair system. *Biomedical engineering online*, 17, 111.

- Viana, S., Batista, D., y Melges, D. (2014). Logistic regression models: Feature selection for P300 detection improvement. En *XXIV congresso brasileiro de engenharia biomédica-CBEB*. Belo Horizonte, Brazil.
- Villamizar, N. (2019). *Elaboración y ejecución de un protocolo para adquisición de señales de electroencefalografía para una interfaz cerebro-computadora, aplicado a ingeniería de rehabilitación*. Bogotá: Universidad Antonio Nariño.
- Wang, H., Wang, Y., Jing, J., y Wang, X. (2015). SSVEP recognition using multivariate linear regression for brain computer interface. En *IEEE international conference on computer and communications(ICC)*. Chengdu, China.
- Wang, H., Zhang, Y., Waytowich, N., Krusienski, D., Zhou, G., Jin, J., ... Chichocki, A. (2016). Discriminative feature extraction via multivariate linear regression for SSVEP-based BCI. *IEEE transactions on neural systems and rehabilitation engineering.*, 24, 1-10.
- World Health Organization. (2011). World report on disability [Manual de software informático]. Geneve. (ISBN 9789241564182)
- Xiao, X., Xu, M., Jin, J., Wang, Y., Jung, T., y Ming, D. (2019). Discriminative canonical pattern matching for single-trial classification of ERP components. *IEEE Transaction on Biomedical Engineering*, 1-1.
- Xiao, X., Xu, M., Wang, Y., Jung, T., y Ming, D. (2019). comparison of classification methods for recognizing single-trial P300 in brain-computer interfaces. En *41st annual international conference of the IEEE engineering in medicine and biology society*. Berlin, Germany.
- Xu, M., Long, C., y He, F. (2016). Incorporation of inter-subject information to improve the accuracy of subject-specified P300 classifiers. *International Journal of Neural Systems*, 26, 1-10.
- Zhang, X., Xu, G., Mou, X., Ravi, A., Li, M., Wang, Y., y Jiang, N. (2019). A convolutional neural network for the detection of asynchronous steady state motion visual evoked potential. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(6), 1303-1311.

Anexos

5.4. Anexo A- Consentimiento Informado

DOCUMENTO DE CONSENTIMIENTO INFORMADO SEÑALES DE ELECTROENCEFALOGRAFIA

Nombre del investigador: Cristian Felipe Blanco Díaz. Estudiante de Ingeniería Biomédica de la Universidad Antonio Nariño.

Introducción

Las Electroencefalografía(EEG) es un procedimiento que permite medir y registrar el comportamiento eléctrico del cerebro de forma superficial no-invasiva, inicialmente fue implementado en el campo de la medicina para el diagnóstico de enfermedades. Con el avance de la tecnología, esta técnica se ha visto inducida en la ingeniería de rehabilitación con el objetivo de diseñar herramientas que permitan mejorar la calidad de vida de personas en condiciones de discapacidad, las Interfaces Cerebro Computador o BCI por sus siglas en inglés(Brain-Computer Interface). Un sistema BCI es un canal de comunicación y control que permite a las personas interactuar con su entorno sin necesidad de usar su sistema muscular.

No obstante, el procedimiento para que un sistema BCI pueda reconocer las intenciones de los usuarios todavía es motivo de estudio, por lo que es necesario la implementación de estímulos que permitan de cierta forma generar patrones en el cerebro que el sistema BCI pueda reconocer y con ello, ejecutar una acción.

Objetivo

Teniendo en cuenta la normatividad colombiana para el desarrollo de investigaciones en seres humanos consignada en la Resolución 8430 de 1993, así como en la Declaración de Helsinki (1964), donde se describen los principios éticos para la investigación biomédica en personas, este documento tiene el objetivo de informar al usuario el procedimiento de captura de señales de EEG que contribuirán en la construcción de una base de datos documentada y la evaluación de un sistema BCI con fines investigativos. Este formulario de consentimiento informado se dirige a personas que serán sometidos a pruebas y que han sido invitadas a la investigación que se lleva a cabo en la facultad de Ingeniería Mecánica, Electrónica y Biomédica (FIMEB) de la Universidad Antonio Nariño como parte del trabajo de grado de uno de los estudiantes de Ingeniería Biomédica.

Tipo de Intervención de Investigación:

Esta investigación incluirá capturas de señales de EEG con la ayuda del dispositivo g.Nautilus, Mostrado en la Figura 5-1, que distribuye 32 electrodos en la superficie de la cabeza, aunque el registro sólo se realizará con 8, las tomas se harán en diferentes momentos de tiempo no mayor a dos (2) horas, donde se harán como mínimo dos sesiones: una de calibración y adaptación al equipo y otra de validación.



Figura 5-1: Dispositivo g.Nautilus

Selección de participantes:

Estamos invitando a las personas que estén enteradas de esta investigación a participar en la evaluación de funcionalidad de un sistema BCI y la creación de la base de datos. Se tomarán datos de personas sanas que no presenten ninguna patología física.

Participación Voluntaria:

Su participación en esta investigación es totalmente voluntaria. Usted puede elegir participar o no hacerlo. Usted puede cambiar de idea más tarde y dejar de participar aun cuando haya aceptado antes. Por la participación en el presente estudio no habrá ningún tipo pago

Procedimientos y Protocolo:

Se ubica el dispositivo g.Nautilus sobre la cabeza y en cada electrodo se pone una cantidad de gel conductor. Para verificar que ha quedado bien ubicado y que la toma va a ser correcta, se usara un software que permite verificar la impedancia presente en cada uno de los electrodos buscando que según la escala de la siguiente tabla se encuentren todos o en su mayoría en verde y/o amarillo:

Color	Valor
Verde	$\leq 30 \text{ k}\Omega$
Amarillo	$\leq 50 \text{ k}\Omega$
Azul	$\leq 100 \text{ k}\Omega$
Rojo	$> 100 \text{ k}\Omega$

Si los valores se encuentran entre azul o rojo, se aplicará un poco más del gel conductor hasta lograr los valores deseados de impedancia en cada uno. Al establecerse un rango correcto de dichas impedancias, se empezará a hacer la adquisición de señales respecto al siguiente protocolo:

1. Se le presentará una pantalla con el siguiente deletreador de 6 filas y 6 columnas:



Figura 5-2: Deletreador

2. Inicialmente el deletreador estará apagado, el sistema le presentará una palabra que usted deberá intentar formar usando su actividad cerebral. Para esto cuando se le sea indicado, se concentrará en una única letra intentando contar cuantas veces parpadea, teniendo en cuenta que todo el tablero parpadea de forma aleatoria. No importa si no se acuerda de la palabra inicial, el sistema le cuando complete el proceso con una letra le indicará cual es la siguiente hasta que termine.
3. La primera sesión se realiza con el fin de calibrar el equipo y de que usted se adapte al funcionamiento de este, por lo que es difícil que en este primer intento usted logre formar la palabra completamente.
4. Posteriormente se tomará un tiempo de descanso mientras los investigadores realizan unos procedimientos con las señales que se acaban de registrar y nuevamente se procederá a realizar una sesión de prueba con una palabra diferente. Si es necesario se realizará otra prueba, de lo contrario se procede a retirar el equipo y se realiza una limpieza del gel sobre su cabello si es necesario.

5. Los datos registrados serán guardados y organizados en una base de datos que en un futuro se usen con fines investigativos, manteniendo en todo momento la confidencialidad.

Duración

La instrumentación para poder hacer la adquisición se extiende aproximadamente por 15 minutos. En total la prueba tiene una duración de máximo dos (2) horas, tiempo durante el cual será necesario que permanezca en el laboratorio de simulación de la Universidad Antonio Nariño (sede circunvalar).

Riesgos

El registro de datos y su interacción con el sistema BCI no trae implícitos riesgos o efectos secundarios, a excepción de un posible cansancio visual debido a la estimulación con parpadeo y una ligera incomodidad del casco y la gel sobre su cuero cabelludo.

¿A quién contactar?

Si tiene cualquier pregunta puede hacerlas ahora o más tarde, incluso después de haberse iniciado la toma de datos. Si desea hacer preguntas más tarde, puede contactar al ingeniero Andrés F. Ruiz (andresru@uan.edu.co) y al estudiante Cristian F. Blanco (cblanco88@uan.edu.co).

FORMULARIO CONSENTIMIENTO

He sido invitado a participar en la realización de pruebas de una Interfaz Cerebro-Computador y la construcción de una base de datos de señales de Electroencefalografía con fines investigativos. Entiendo que me será puesto el dispositivo g.Nautilus que tiene electrodos no invasivos. He sido informado que los riesgos son mínimos, a excepción de un posible cansancio ocular y ligera incomodidad producida por el gel administrado. Comprendo que esta investigación no me generará algún beneficio personal ni económico. Se me ha proporcionado el nombre de un investigador y un estudiante que pueden ser fácilmente contactados usando el nombre y la dirección de correo electrónico que me fue entregada.

He leído la información proporcionada o me ha sido leída. He tenido la oportunidad de preguntar sobre ella y se me ha contestado satisfactoriamente las preguntas que he realizado.

Consiento voluntariamente participar en esta investigación como participante y entiendo que tengo el derecho de retirarme de la investigación en cualquier momento sin que me afecte en ninguna manera.

Nombre del participante:

Documento de identidad del participante:

Firma del participante:

Fecha: