

A Novel Method Based on Regularized Logistic Regression and CCA for P300 Detection Using a Reduced Number of EEG Trials

C. F. Blanco-Díaz and A. F. Ruiz-Olaya

Abstract—The Event-Related Potential (ERP) P300 is an Electroencephalography (EEG) signal evoked by external stimuli, characterised by a positive deflection at the 300 ms after presentation of an interesting stimulus for the user. In literature, P300-based Brain-Computer Interface (BCI) has been implemented to translate the subject's intent for restoring communication and control functions. In order to detect the ERP of the EEG signals and taking into account low signal-to-noise ratio (SNR) of the P300 signal, multiple trial averaging has been widely used, which permit diminishing the random noise. However, the signal averaging technique requires processing multiple EEG trials, thus the ITR (Information Transfer Rate) of the P300-based BCI is significantly reduced. An open challenge of P300-based BCI systems focuses on recognizing ERP signals (as target and no-target) using a reduced number of trials with an enough classification rate. In this work, we propose a novel method based on Regularized Logistic Regression (RLR) using as features the coefficients obtained from a Canonical Correlation Analysis (CCA), as method for detection of visual P300 ERPs using a reduced number of EEG trials (1, 2, 3 and 4 trials). The proposed method was evaluated with a freely available EEG dataset and was compared with two widely used methods: Mean-Amplitude LDA and Step-Wise LDA. Finally, the proposed method outperforms standard algorithms for P300 detection, providing a maximum accuracy of 86.3% ($p = 0.27$ to Mean Amplitude LDA and $p < 0.05$ to Stepwise-LDA) and maximum Area Under Curve (AUC) of the Receiver Operating characteristic (ROC) of 0.753 ($p = 0.715$ to Mean Amplitude LDA and $p = 0.228$ to Stepwise LDA) on the recognition. Despite the performance of some metrics of proposed method are not significant, the results allow concluding that this one have an acceptable performance for the recognition of P300, using a reduced number of trials.

Index Terms—Brain Computer Interface, Event Related Potential, P300, Canonical Correlation Analysis, Regularized Logistic Regression.

I. INTRODUCCIÓN

El último reporte de la Organización Mundial de la Salud (OMS) indica que aproximadamente el 15.6% de la población global posee alguna discapacidad y que el 2.2% tiene impedimentos en su sistema neuromotor [1]. En los últimos años, con el objetivo de apoyar la rehabilitación y mejorar la calidad de vida de esta población, se han propuesto diversas soluciones entre las que se encuentran las Interfaces Cerebro-Computador (BCI-Brain Computer Interface por sus siglas en inglés) para ayudar a restaurar capacidades de comunicación y control de personas con diversidad funcional,

teniendo en cuenta que les permite interactuar con su entorno, sin hacer uso de sus nervios y músculos periféricos, mediante el uso de señales cerebrales [2]. El ámbito de aplicación de los sistemas BCI abarca múltiples campos tales como la medicina, educación, neuroergonomía, juegos, rehabilitación motora y de comunicación, robótica, entre otras [3]–[7].

Un sistema BCI se fundamenta en identificar la intención del usuario de ejecutar alguna acción mediante la identificación de patrones en las señales de Electroencefalografía (EEG), relacionados con ciertas tareas o estrategias mentales. Un paradigma para implementar estos sistemas es mediante la realización de tareas de atención selectiva por parte del usuario.

El Potencial Relacionado a Evento (ERP por sus siglas en inglés Event Related Potential) P300, es una respuesta a una tarea de atención selectiva, el cual se define como una desviación positiva de voltaje de pocos microvoltios, con una latencia (retraso entre el estímulo y la respuesta) de aproximadamente 300 ms, registrado mediante EEG después de la presentación de un estímulo poco frecuente para el sujeto [3], [8]. El estímulo puede ser auditivo [9], somatosensorial [10] o visual [11], donde este último ha sido uno de los más utilizados para implementar deletreadores BCI como solución en la rehabilitación de la comunicación. De acuerdo con el estándar internacional 10-20 para el posicionamiento de electrodos de EEG [12], la señal P300 se registra principalmente en la corteza parietocentral del cerebro [13]. El P300 visual también se registra en canales relacionados con la corteza occipital del cerebro, tales como O_z [13]. En la literatura, el P300 visual registrado mediante EEG, ha sido extensamente estudiado para implementarse en sistemas BCI, entre los que resaltan los deletreadores.

Farwell y Donchin en 1988 propusieron e implementaron un deletreador BCI basado en P300 visual, el cual ha sido extensamente usado como herramienta de comunicación para personas con algún tipo de discapacidad severa que les impida moverse y hablar. En el deletreador BCI basado en P300, se presenta al usuario en una pantalla una serie de estímulos repetidos (tal como letras), y el usuario para seleccionar los elementos, debe atender el estímulo asociado deseado e ignorar el resto (lo cual permite evocar el potencial P300), en un paradigma denominado bicho raro (Oddball en inglés) [14].

El principal inconveniente en la implementación de sistemas BCI basados en P300 radica en la identificación de la intención del usuario mediante la detección del potencial P300, el cual presenta baja relación señal a ruido, teniendo en cuenta que

C. Blanco and A. Ruiz-Olaya are with the Faculty of Mechanical, Electronics and Biomedical Engineering, Universidad Antonio Nariño, Bogotá, Colombia, e-mail: (cblanco88; andresru)@uan.edu.co.

la amplitud de la señal es del orden de μV y por tanto frecuentemente contaminada por ruido externo (ambiente) y ruido interno (procesos cognitivos, movimiento, etc).

La promediación es una de las técnicas empleadas en la literatura para abordar la eliminación del ruido aleatorio presente en la señal P300, mediante la ejecución del experimento utilizando múltiples registros (repeticiones), con el fin de promediar las señales obtenidas de las repeticiones. Sin embargo, significa que por cada comando (o letra en el caso del deletreador) a identificar, al usuario se le debe presentar múltiples veces el mismo estímulo objetivo, lo cual se traduce en un incremento en el tiempo de respuesta del sistema y una baja tasa de transferencia de información (ITR por sus siglas en inglés Information Transfer Rate).

En el proceso de detección del potencial P300 de la señal EEG, se implementan tres etapas: pre-procesamiento, extracción de características y clasificación. En el pre-procesamiento de la señal P300, es requerido realizar diferentes tipo de filtrados (espacial y frecuencial). El P300 se considera una señal de baja frecuencia con contenido espectral que ocurre principalmente en las bandas Delta (δ), Theta (θ) y Alpha (α) [15].

Una característica ampliamente usada en la etapa de extracción corresponde a la amplitud media (MA por sus siglas en inglés Mean amplitude), que consiste en calcular el valor promedio de la señal, generalmente entre 0 y 800 ms [16]. Para la clasificación es ampliamente usado el Análisis de Discriminante Lineal (LDA por sus siglas en inglés Lineal Discriminant Analysis). Esta combinación ha proporcionado altas tasas de clasificación en implementación de deletreadores BCI, por ejemplo en 2016 Hwang *et al.* reportaron una tasa de clasificación de aproximadamente el 75% con 4 sujetos de prueba [17] y en el 2019 Lee *et al.* reportaron una tasa de clasificación del 96% con 54 sujetos [16], ambos usaron los datos obtenidos de 10 repeticiones.

Variantes del LDA también han sido utilizados, como el Análisis de Discriminante Lineal por pasos (SWLDA por sus siglas en inglés Step-Wise Lineal Discriminant Analysis). Usando este método, Xiao *et al.* (2019) obtuvieron áreas bajo la curva (AUC por sus siglas en inglés Area Under Curve) de

la característica operativa del Receptor (ROC por sus siglas en inglés Receiver Operating Characteristic), para 30 ejemplos y una única repetición, de 0.58 con 12 sujetos, 0.63 con 11 sujetos, 0.55 con 12 sujetos y 0.55 para 12 sujetos de 4 bases de datos diferentes, para estos dos últimos se implementaron deletreadores como metodología de estimulación [18].

Colwell *et al.* (2014) reportaron un complemento para este método donde reportaron AUC entre 0.75 y 0.86 realizando un filtrado espacial de canales, SWLDA y correlación cruzada, en una muestra de 18 personas con múltiples repeticiones para un sistema BCI basado en deletreador [19]. Por otro lado, diversos métodos de extracción y clasificación han sido utilizados con el objetivo de mejorar la detección de la señal P300, tales como el Análisis de Componentes Independientes (ICA por sus siglas en inglés Independent Component Analysis) y rechazo de artefactos para múltiples repeticiones, Won *et al.* (2019) reportaron un AUC cercano al 0.84 usando la combinación de estos métodos en un deletreador [20].

El Análisis de Correlación Canónica (CCA por sus siglas en inglés Canonical Correlation Analysis) ha sido ampliamente usado para el reconocimiento de Potenciales Evocados Visuales en Estado Estable (SSVEP por sus siglas en inglés Steady-State Visual Evoked Potentials) [11], [17], [21]. Para la detección de ERP P300 esta técnica fue usada por Spuler *et al.* (2014) para implementar un filtrado espacial, sin embargo, no ha sido utilizada para extracción de características [22].

La Regresión Logística Regularizada (RLR por sus siglas en inglés Regularized Logistic Regression) es un modelo estadístico que permite predecir el comportamiento de un conjunto de clases regularizando el número de características con el objetivo de reducir el sobre entrenamiento, que ha sido utilizada en la etapa de clasificación del ERP [23]. En 2015, Motlagh *et al.* reportaron tasas de clasificación entre 60 y 96% usando como método de extracción las características Wavelet para una única repetición [24] y Acevedo *et al.* (2019) reportaron tasas de clasificación cercanas al 78% para una única repetición de dos sujetos de pruebas [25].

Un reto abierto de la comunidad científica en la implementación de deletreadores BCI es realizar la detección del potencial P300 con un alto porcentaje de clasificación [16],

TABLA I
ESTADO DEL ARTE DE MÉTODOS USADOS PARA EL RECONOCIMIENTO DE P300

Autores	Índice de rendimiento	Rendimiento	No. de sujetos	Método	No. de repeticiones	Referencia
Hwang <i>et al.</i> (2016)	Tasa de clasificación	75%	4	MA-LDA	10	[17]
Lee <i>et al.</i> (2019)	Tasa de clasificación	96%	54	MA-LDA	10	[16]
Xiao <i>et al.</i> (2019)	AUC	0.58; 0.63; 0.55; 0.55	12; 11; 12; 12	SWLDA	1	[18]
Colwell <i>et al.</i> (2014)	AUC	0.75-0.86	18	Filtrado espacial, SWLDA y correlación cruzada	Múltiples	[19]
Won <i>et al.</i> (2019)	AUC	0.84	-	ICA y rechazo de artefactos	Múltiples	[20]
Acevedo <i>et al.</i> (2019)	Tasa de clasificación	78%	2	Características Wavelet	1	[25]

[17], [19], [20] pero utilizando un reducido número de repeticiones [18], [24], [25], ver tabla I.

En este estudio se propone un nuevo método que aborda tal reto, basado en la RLR, el cual utiliza como características los coeficientes obtenidos al aplicar una correlación mediante CCA, entre señales EEG registradas y señales de referencia calculadas en la etapa de calibración. El método fue evaluado en 10 personas, utilizando 8 canales EEG registradas de una base de datos pública de EEG-P300 diseñada por Lee *et al.* (2019) [16]. El experimento de la base de datos consiste en un deletreador basado en una matriz de 6 columnas y 6 filas de caracteres (letras y números), implementando el paradigma oddball. Este método fue comparado utilizando la información correspondiente a 1, 2, 3 y 4 repeticiones, con dos métodos ampliamente usados en la literatura: MALDA y SWLDA, donde obtuvo un mayor rendimiento en las métricas de tasa de clasificación (83.5%; $p < 0.05$), sensibilidad (46.1%; $p < 0.05$) y AUC (0.65; $p = 0.5946$) para única repetición. Para 4 repeticiones se obtuvo la máxima tasa de clasificación (86.3%; $p < 0.05$), sensibilidad (62.4%; $p < 0.05$) y AUC (0.753; $p = 0.71$). A pesar de que algunas métricas de evaluación no poseen un rendimiento significativo, los resultados demuestran que el método propuesto es efectivo para el reconocimiento del ERP P300 utilizando un reducido número de repeticiones, lo que proporcionará un tiempo de respuesta más corto en un deletreador BCI on-line con una exactitud de ejecución adecuada.

II. MÉTODO EXPERIMENTAL

A. Base de Datos de Señales EEG

En este estudio se ha utilizado una base de datos EEG disponible en [16], las señales ERP se adquirieron de acuerdo con el estándar internacional de posicionamiento de electrodos EEG 10-20, en el que se registraron 62 canales con una frecuencia de muestreo de 1000 Hz. El experimento consistió en un deletreador basado en el paradigma oddball con seis filas y seis columnas con un tiempo de intervalo de 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 validación, cada uno repetido 10 veces para un total de 330 estímulos objetivo en el entrenamiento (total de 1980) y 360 estímulos objetivo en la validación (total de 2160) (Fig. 1). Para este estudio, se realizó el análisis con 10 personas, donde los datos correspondientes a la sesión de entrenamiento fueron usados para entrenar los modelos y los de la sesión de evaluación fueron usados para evaluar los modelos, donde el número de ejemplos fue el mismo para cada uno de los tres métodos evaluados.

B. Pre-procesamiento de las Señales

Las señales EEG fueron filtradas en el rango de frecuencias entre 0.5 Hz y 40 Hz con un filtro Butterworth de orden 5, segmentadas entre 0 y 800 ms, utilizando para la eliminación de la línea de base una ventana de tiempo entre -200 y 0 ms [16]. Los canales en este estudio se seleccionaron de los 62 registrados a 8, de acuerdo con la zona donde se evoca principalmente el P300, correspondiente a la corteza

parietocentral del cerebro y los canales más usados en la literatura para ERP visual: \mathbf{F}_Z , \mathbf{C}_Z , \mathbf{P}_Z , \mathbf{P}_3 , \mathbf{P}_4 , \mathbf{O}_Z , \mathbf{PO}_3 y \mathbf{PO}_4 (Fig. 2). Posteriormente, las señales se submuestrearon por un factor de 10, obteniendo un total de 80 muestras entre 0 y 800 ms. Las salidas del sistema corresponden a las señales objetivo (P300) identificadas como salidas positivas del sistema y las señales no objetivos (no P300) como salidas negativas del sistema (clasificación binaria).

C. Regresión Logística Regularizada para la Detección de ERP-P300 Basada en los Coeficientes del Análisis de Correlación Canónica (CCA-RLR)

El método propuesto utiliza como características los coeficientes obtenidos al aplicar una correlación mediante CCA, entre la señales EEG registradas y señales de referencia calculadas en la etapa de entrenamiento. El CCA consiste en una técnica estadística que permite calcular la correlación entre dos conjuntos multivariados. Por lo que, el coeficiente de correlación canónica (r) mide la magnitud de asociación entre dos variables canónicas. La técnica CCA es ampliamente usada en sistemas BCI para el reconocimiento de SSVEP, a través del coeficiente de correlación (r) entre señales de EEG y un banco de señales de referencia con ciertas características frecuenciales [17], [21]. Para el entrenamiento y la evaluación del método propuesto se siguieron cinco (5) etapas, Fig. 3.

1) *Etapa I:* Para este estudio, el banco de señales de referencia corresponde al gran promediado (GA por sus siglas en inglés Grand Average) de todas las repeticiones de las señales objetivo (T) y las señales no objetivo (NT), para cada canal EEG del conjunto de datos de la sesión de entrenamiento. De acuerdo a lo anterior, se tienen dos bancos de señales: $\mathbf{X}_T \in \mathbb{R}^{n \times q}$ y $\mathbf{X}_{NT} \in \mathbb{R}^{n \times q}$, donde n es el número de muestras y q es el número de canales.

2) *Etapa II:* Posteriormente, la matriz $\mathbf{Y} \in \mathbb{R}^{n \times q}$ corresponde a las señales EEG adquiridas por cada canal para cada repetición, donde n es el número de muestras y q es el número de canales. Considerando estas dos variables multidimensionales, la técnica CCA se encuentra definida por:

$$r = \max_{\mathbf{w}_x, \mathbf{w}_y} \text{corr}(\mathbf{x}, \mathbf{y}) = \max_{\mathbf{w}_x, \mathbf{w}_y} \frac{\mathbf{w}_x^T \mathbf{S}_{xy} \mathbf{w}_y}{\sqrt{\mathbf{w}_x^T \mathbf{S}_{xx} \mathbf{w}_x \mathbf{w}_y^T \mathbf{S}_{yy} \mathbf{w}_y}} \quad (1)$$

Donde el objetivo es calcular las combinaciones lineales $\mathbf{x} = \mathbf{X} \cdot \mathbf{w}_x$ y $\mathbf{y} = \mathbf{Y} \cdot \mathbf{w}_y$, donde $\mathbf{w}_x \in \mathbb{R}^{q \times 1}$ y $\mathbf{w}_y \in \mathbb{R}^{q \times 1}$ representan los vectores de pesos que permiten maximizar la correlación r entre \mathbf{x} e \mathbf{y} y \mathbf{S} representa la matriz de covarianza. En el método de extracción propuesto, el CCA proporciona la correlación entre las señales EEG adquiridas y el conjunto de señales de referencia, donde cada señal GA incluye respuestas a objetivos y no-objetivos, de q 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 $i = 1, 2, 3, \dots, q$, definido en:

$$\rho_{Ti} = \max_{\mathbf{w}_x, \mathbf{w}_y} \text{corr}(\mathbf{X}_{Ti}, \mathbf{Y}_i) \quad (2a)$$

$$\rho_{NTi} = \max_{\mathbf{w}_x, \mathbf{w}_y} \text{corr}(\mathbf{X}_{NTi}, \mathbf{Y}_i) \quad (2b)$$

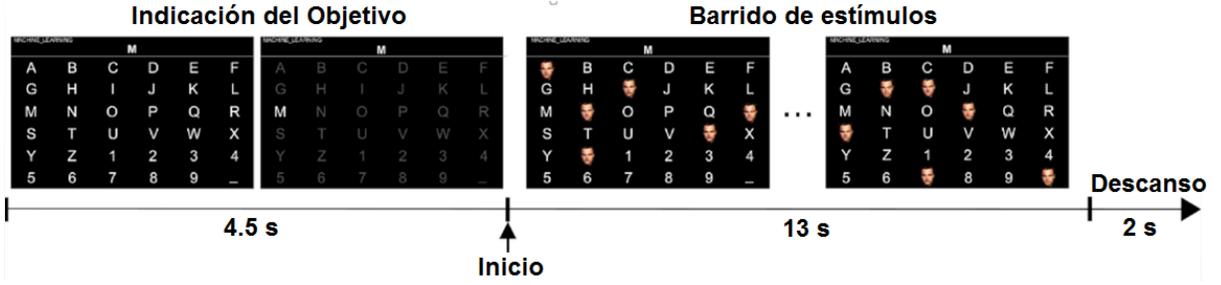


Fig. 1. Diseño experimental para el paradigma ERP-BCI basado en el deletreador 6x6 implementado en [16]. La fase de entrenamiento se divide en dos partes: a) Indicación del Objetivo, en donde se le indica al usuario el carácter a enfocarse; b) Barrido de estímulos, en donde el sujeto debe enfocarse en el carácter indicado mientras las filas y columnas comienzan a iluminarse alternativamente y de forma aleatoria.

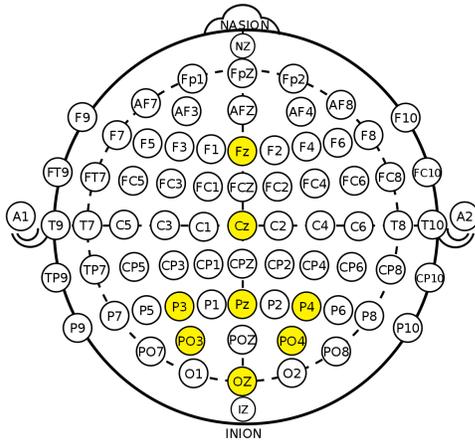


Fig. 2. Posición topográfica de los 8 canales EEG usados en el estudio, según el estándar internacional 10-20.

3) *Etapa III:* Después, la matriz ρ corresponde a la concatenación de las matrices ρ_{Ti} y ρ_{NTi} , obteniendo que $\rho \in \mathbb{R}^{m \times k}$, donde $k = 2q$ y m se encuentra relacionado al número de repeticiones totales sobre las repeticiones evaluadas: 1, 2, 3 y 4 repeticiones. Para el entrenamiento del modelo, se utilizó la matriz ρ obtenida del análisis CCA entre las señales EEG de la sesión de entrenamiento con las señales GA, como características de entrada y para la evaluación se usó la matriz ρ obtenida del análisis CCA entre las señales EEG de la sesión de evaluación con las señales GA.

4) *Etapa IV:* Para el entrenamiento del modelo RLR, es necesario encontrar los valores óptimos del vector θ , donde $\theta^T \rho \in \mathbb{R}^{m \times 1}$. El parámetro θ se modifica con el gradiente descendiente, inicializando su valor en cero. Después, el vector con los parámetros θ se multiplica por los coeficientes de correlación ρ de la sesión de entrenamiento, en un proceso de ponderación, cuyo resultado proporciona los valores de entrada para el modelo, definido en:

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

5) *Etapa V:* 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 son

los resultados obtenidos de (3).

$$h_\theta(\rho) = \frac{1}{1 + e^{-\theta^T \rho}} \quad (4)$$

La hipótesis se implementó en la función de costo, para este caso se hizo uso de la entropía cruzada binaria regularizada, representada por $J(\theta)$, con el objetivo de llevar a cabo el proceso, como se define en (5).

$$J(\theta) = - \left[\frac{1}{m} \sum_{l=1}^m \psi^{(l)} \log(h_\theta(\rho^{(l)})) + (1 - \psi^{(l)}) \log(1 - h_\theta(\rho^{(l)})) \right] + \frac{\lambda}{2m} \sum_{b=1}^k \theta_b^2 \quad (5)$$

donde λ corresponde al parámetro de regularización (en este caso regularización L2) que reduce la varianza en los parámetros de regresión estimados. Para este caso se evaluaron $\lambda = 0, 0.01, 0.04, 0.1, 0.4, 1, 4$ y 10, seleccionando $\lambda = 0.01$, cuyo desempeño redujo la función de costo a su valor óptimo. m es el número de muestras en el subconjunto generado con el promedio de las señales respecto al número de repeticiones (1, 2, 3 y 4) y ψ es la salida real: objetivo y no-objetivo (Clase binaria). Para minimizar la función de costo, fueron implementados diferentes valores de tasas de aprendizaje (α) y de número de iteraciones. Se obtuvo que con una tasa de aprendizaje de 0.001 y un número de 400 iteraciones, se alcanzaba una optimización en la función de costo y con ello, los valores θ óptimos, de acuerdo a (6).

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{l=1}^m (h_\theta(\rho^{(l)}) - \psi^{(l)}) \rho_0^{(l)} \quad (6a)$$

$$\theta_b := \theta_b - \frac{1}{m} \left[\alpha \sum_{l=1}^m (h_\theta(\rho^{(l)}) - \psi^{(l)}) \rho_b^{(l)} + \lambda \theta_b \right] \quad (6b)$$

Finalmente, usando la matriz ρ de la sesión de evaluación junto con los valores óptimos de θ (definida por (6)) se repiten los pasos de la etapa IV y etapa V, para evaluar el modelo con base en los índices de rendimiento.

D. Métodos de Referencia para la Detección de Potenciales P300

En este trabajo se emplearon dos métodos de detección de P300 ampliamente utilizados en la literatura, la amplitud

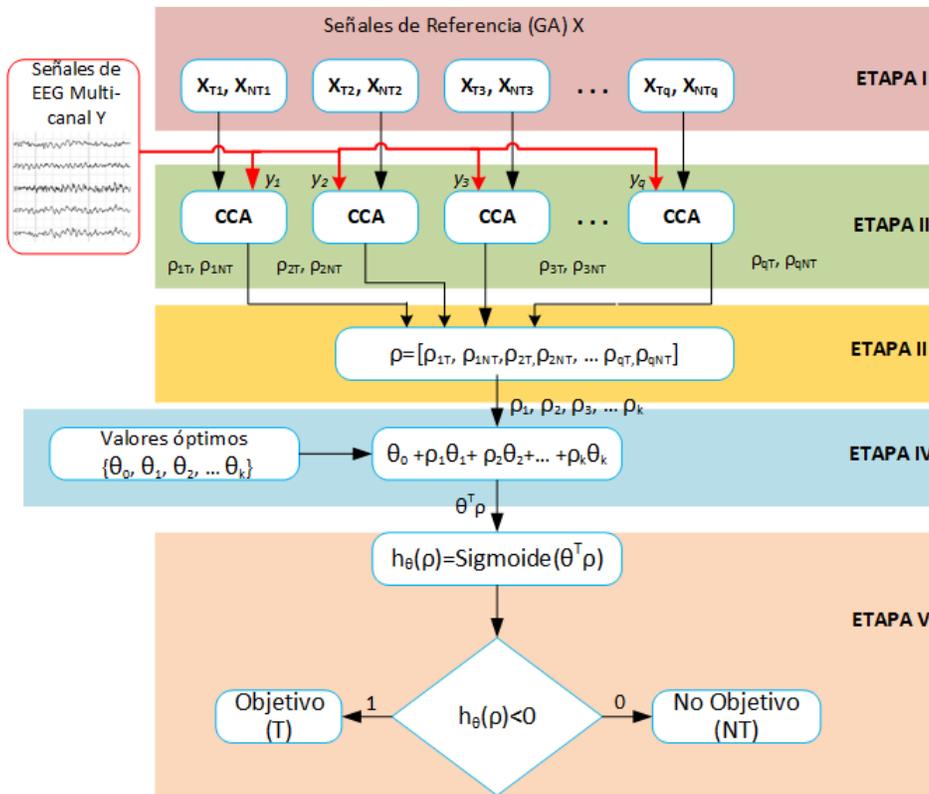


Fig. 3. Diagrama de flujo del método propuesto CCA-RLR para detección del potencial P300 usando los datos de evaluación.

media con LDA (MA-LDA) y LDA por pasos (SWLDA), como métodos de referencia y comparación para cuantificar el rendimiento del nuevo método de detección propuesto.

1) *MA-LDA*: Teniendo en cuenta que el P300 consiste en una desviación positiva a los 300 ms después de la presentación de los estímulos, el valor medio de las señales de EEG objetivo es mayor que el valor medio de las señales de EEG no objetivo [16], además, en este estudio la desviación estándar se implementó como característica con el objetivo de mejorar los criterios de clasificación. El Análisis Discriminante Lineal (LDA) fue entrenado con las características de las señales EEG de entrenamiento del conjunto de datos y fue evaluado con las características de las señales EEG de validación del conjunto de datos. El proceso se repitió con las señales promediadas correspondientes a 1, 2, 3 y 4 repeticiones.

2) *SWLDA*: El SWLDA consiste en una serie de pasos hacia adelante y hacia atrás con el objetivo de identificar las mejores características para implementar en el modelo a través un conjunto de valores de probabilidad (*p-value* en inglés). Se implementó la función "stepwisefit" de Matlab con un ajuste de $p < 0.1$ para la regresión hacia atrás y para eliminar las características con valores de $p > 0.15$, ejecutadas hasta que se agoten las características del modelo [26]. Las características resultantes se implementaron posteriormente para el entrenamiento del modelo LDA y se evaluaron con las características resultantes de los datos de validación. El pro-

ceso se repitió con las señales promediadas correspondientes a 1, 2, 3 y 4 repeticiones.

E. Índices de Rendimiento

Los índices seleccionados para evaluar el rendimiento de cada método fueron la tasa de clasificación (Acc por su significado en inglés accuracy), la sensibilidad (Sen por su significado en inglés Sensitivity) y la especificidad (Spe por su significado en inglés Specificity), definidos como [25]:

$$Acc = \frac{VP + VN}{NT} \quad (7)$$

$$Sen = \frac{VP}{FN + VP} \quad (8)$$

$$Spe = \frac{VN}{FP + VN} \quad (9)$$

Donde VP es el número de verdaderos positivos (señales objetivo correctamente clasificadas), VN es el número de verdaderos negativos (Señales no objetivos correctamente clasificadas), FP corresponde al número de falsos positivos y FN (Señales no objetivos incorrectamente clasificadas), FN son los falsos negativos (Señales objetivos incorrectamente clasificadas) y NT corresponde al número total de clases posibles. En el presente estudio también fue calculada el área bajo la curva ROC (Característica Operativa del Receptor), el cual es una métrica que permite cuantificar la capacidad discriminativa de un clasificador binario (diferenciar entre objetivo y no-objetivo), mediante la probabilidad del regresor logístico. El ROC es una representación gráfica de la sensibilidad frente

a la especificidad para un sistema clasificador binario según se varía el umbral de discriminación. De esta curva se halla el parámetro correspondiente AUC, ampliamente usado en análisis de reconocimiento de P300 [18], [20].

F. Validación

El estudio comparativo entre el método propuesto para el reconocimiento de P300 y los métodos estándar ya reportados en la literatura se llevó a cabo mediante los siguientes pasos:

1. Obtener los GA del subconjunto de datos de entrenamiento para cada uno de los ocho canales utilizados.
2. Usar una única repetición para clasificar la señal P300, usando el subconjunto de datos de evaluación.
3. Utilizar los índices de rendimiento, definidos por (7), (8) y (9), para el reconocimiento de señales objetivo y no-objetivo como parámetro de evaluación.
4. Evaluar el método versus los 2 métodos estándar.
5. Repetir los pasos del 2 al 4, usando 2, 3 y 4 repeticiones.

Se cuantificó la significancia estadística para comparar las diferencias en las métricas de desempeño obtenidas. Para esto, se realizó la prueba Kolmogorov-Smirnov para evaluar si los grupos poseen una distribución normal estándar con un Intervalo de confianza del 95% ($\alpha = 0.05$). Posteriormente, se utilizó un test-t con el objetivo de evaluar el rendimiento del método propuesto a través del número de repeticiones y compararlo con el comportamiento de los dos métodos estándar. Para determinar la significancia estadística se usó el valor de probabilidad p .

III. RESULTADOS

Los GA corresponden a las señales EEG de referencia para el método CCA las cuales se hallaron a partir del gran promediado de las señales objetivo y las señales no-objetivo para cada canal. Por ejemplo, para un sujeto de prueba se obtienen las señales de referencia correspondientes a las Fig. 4 y 5.

De otro lado, en la Fig. 6 se representa el comportamiento

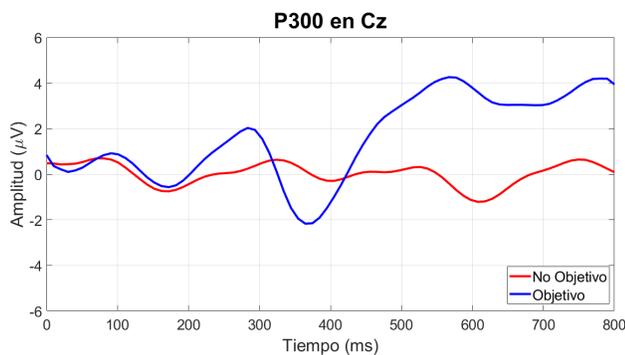


Fig. 4. Comportamiento de las Señales EEG de Referencia obtenidas de los datos de entrenamiento correspondientes a objetivos y no-objetivos en el canal C_z para un sujeto.

a nivel temporal y espacial, de los GA calculados, en una topografía de la corteza cerebral respecto a los segmentos de tiempo de interés en un sujeto de prueba. En la Fig. 7, se presentan los resultados promediados para los 10 sujetos

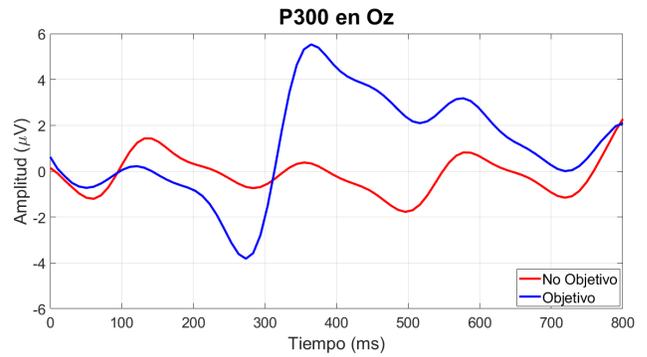


Fig. 5. Comportamiento de las Señales EEG de Referencia obtenidas de los datos de entrenamiento correspondientes a objetivos y no-objetivos en el canal O_z para un sujeto.

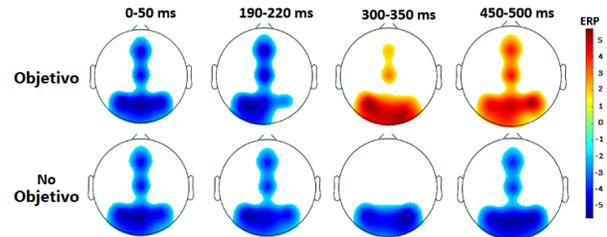


Fig. 6. Topografía del comportamiento de las señales de referencia (objetivo y no-objetivo) en diferentes segmentos de tiempo, para un sujeto.

correspondientes a la validación, teniendo en cuenta como índice de rendimiento la tasa de clasificación, descrito por (7).

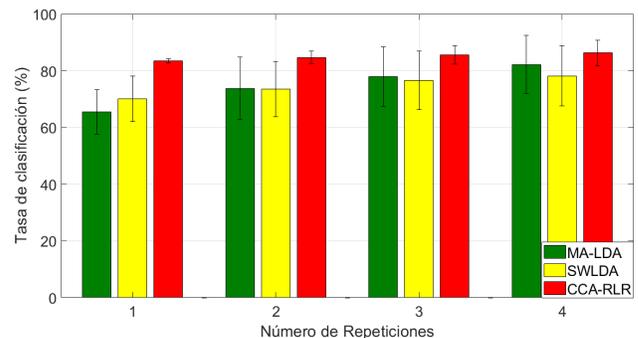


Fig. 7. Tasa de clasificación promedio usando 1, 2, 3 y 4 repeticiones para cada método evaluado.

En la Fig. 8, se presentan los resultados promediados para los 10 sujetos correspondientes a la validación, teniendo en cuenta el índice de rendimiento sensibilidad, definido por (8).

En la Fig. 9, se presentan los resultados promediados para los 10 sujetos correspondientes a la validación, teniendo en cuenta el índice de rendimiento especificidad, definido por (9).

Los valores promedio del parámetro AUC para cada método por repetición, se puede observar en la Tabla II.

Los análisis fueron realizados en un computador con procesador intel core i5-8250 CPU @ 1.80 GHz, 8 GB de memoria RAM y sistema operativo de 64 bits. Se utilizó la función *tic-toc* de Matlab para cuantificar el costo computacional de cada método, donde se tuvo en cuenta el proceso de extracción

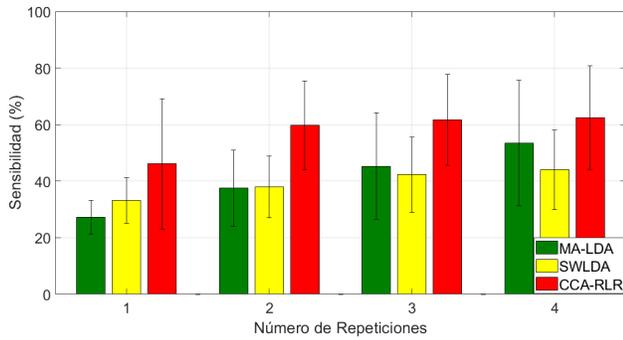


Fig. 8. Sensibilidad promedio usando 1, 2, 3 y 4 repeticiones para cada método evaluado.

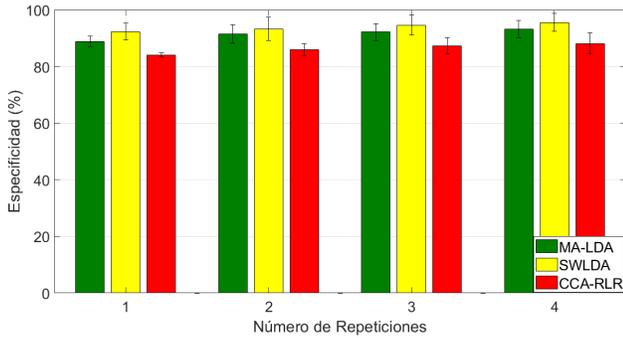


Fig. 9. Especificidad promedio usando 1, 2, 3 y 4 repeticiones para cada método evaluado.

TABLA II
AUC DE LA CURVA ROC PARA 1, 2, 3 Y 4 REPETICIONES POR CADA MÉTODO EVALUADO.

Método	1 Rep.	2 Rep.	3 Rep.	4 Rep.
MA-LDA	0.579	0.645	0.688	0.735
SWLDA	0.627	0.657	0.684	0.699
CCA-RLR	0.657	0.728	0.745	0.753

de características y clasificación de los modelos, y se obtuvieron tiempos promedio de ejecución de aproximadamente 0.336 s (MA-LDA), 1.2898 s (SWLDA) y 0.4228 s (CCA-RLR), para 4 repeticiones.

En términos de comparación con los dos métodos estándar evaluados, el método propuesto (CCA-RLR) para 1, 2, 3 y 4 repeticiones fue el que mejor tasa de clasificación obtuvo, con aproximadamente 83.5% ($p < 0.05$; $p < 0.05$), 84.7% ($p < 0.05$; $p < 0.05$), 85.6% ($p = 0.051$; $p < 0.05$) y 86.3% ($p = 0.267$; $p < 0.05$) respectivamente. Esto permite concluir, que el método propuesto, en su mayoría, es significativamente superior que los dos métodos evaluados según la tasa de clasificación, resaltando su desempeño con una única repetición.

Por otro lado, la sensibilidad se encontró en valores entre 0.272 y 0.624, donde sobresale el rendimiento del método CCA-RLR respecto a este índice, con un valor máximo de 62.4% usando 4 repeticiones a comparación de los dos métodos estándar, siendo significativo frente al SWLDA ($p < 0.05$) pero no frente al MA-LDA ($p = 0.339$). Sin embargo,

para una única repetición el método propuesto fue significativo frente al MA-LDA ($p < 0.05$) pero no frente al SWLDA ($p = 0.1249$), con una sensibilidad del 46.1%.

Respecto a la especificidad, los tres métodos tuvieron un buen rendimiento con porcentajes superiores al 80%, no obstante el método propuesto fue significativamente inferior que los dos métodos propuestos, con especificidad máxima para 4 repeticiones de 88.1% frente a un 93.2% ($p < 0.05$) del MA-LDA y un 95.6% ($p < 0.05$) del SWLDA.

IV. DISCUSIÓN Y CONCLUSIONES

El rendimiento mediante los índices de evaluación tasa de clasificación y sensibilidad, permite resaltar que el método propuesto obtuvo un buen desempeño en la clasificación de la variable positiva (Señales objetivo-P300), donde, a pesar de que la sensibilidad se encuentra en valores inferiores a los reportados en la literatura, como la sensibilidad de aproximadamente el 70% de Acevedo *et al.* (2019) [25], el método propuesto puede considerarse computacionalmente más liviano con un rendimiento aceptable, debido a que no es necesaria la implementación de análisis tiempo-frecuencia como la transformada wavelet o una selección específica de características. Esto supone una ventaja de la implementación del método propuesto en un sistema tiempo real, ya que, se puede mejorar la tasa de transferencia de datos (ITR) con un porcentaje de detección adecuado.

De acuerdo con los estudios reportados en la literatura para la detección del potencial P300 usando un único trial, las AUC de los métodos estándar se encuentran entre valores de 0.6 y 0.86 (ver tabla I), lo que proporciona un rendimiento adecuado del método propuesto para el reconocimiento del potencial P300, debido a que el CCA-RLR obtuvo un AUC promedio de aproximadamente 0.657 para una única repetición y utilizando 4 repeticiones demuestra un aumento hasta 0.753, manteniendo el análisis con un número reducido de repeticiones. No obstante, comparando estas variables con los métodos estándar, no se obtiene una diferencia significativa ($p = 0.715$ para MA-LDA y $p = 0.228$ para SWLDA).

En las Fig. 7, 8 y 9 se puede observar, que a medida de que se aumenta el número de repeticiones, se incrementa el rendimiento, cuantificado mediante los porcentajes de los índices de evaluación, debido a que promediar mayor cantidad de señales permite una reducción considerable del ruido aleatorio presente en la señal EEG. Comparando los valores obtenidos entre una única repetición y la máxima cantidad de repeticiones evaluadas (4), se obtiene un aumento de rendimiento de 46.1% a 62.4% ($p = 0.0971$) para la sensibilidad, un aumento de 84% a 88.1% ($p < 0.05$) para la especificidad, un aumento de 83.5% a 86.3% ($p = 0.0814$) para la tasa de clasificación y finalmente, un aumento de 0.65 a 0.753 ($p = 0.0599$) respecto al AUC.

Teniendo en cuenta los resultados anteriores, se puede observar que el método propuesto obtuvo un mejor rendimiento mediante los índices de sensibilidad, tasa de clasificación y AUC, donde, a pesar de que el rendimiento no es significativo, en una implementación en tiempo real, este aumento puede mejorar el reconocimiento del potencial relacionado a eventos

P300. Otra ventaja del método propuesto, radica en el bajo costo computacional de la técnica usada para la extracción de características que permitiría un menor tiempo de respuesta y con ello, una mejor ITR. Por otro lado, la especificidad se ve significativamente reducida en el método propuesto posiblemente por el comportamiento de las características seleccionadas para cada método, sin embargo se observa que este índice se incrementa al añadir mayor número de repeticiones, por lo que un aumento de esta variable o la combinación de métodos puede compensar el reconocimiento de la variable negativa y con ello, mejorar el rendimiento del método. No obstante, los resultados de especificidad que se obtienen en este estudio son aceptables.

Los resultados permiten concluir que el nuevo método basado en Regresión Logística Regularizada con Análisis de Correlación Canónica (CCA-RLR) es adecuado para el reconocimiento de P300 usando un reducido número de repeticiones, de forma que al implementarse en un deletreador BCI en tiempo real, se tendría una buena tasa de clasificación junto con un menor tiempo en el reconocimiento de los caracteres a comparación de algunos métodos estándar, y con ello, una mayor tasa de transferencia de datos (ITR).

Como estudio futuro se propone implementar esta técnica en un sistema deletreador BCI P300 en tiempo real.

AGRADECIMIENTOS

Los autores quieren agradecer a la Universidad Antonio Nariño por el apoyo en este estudio, mediante el proyecto "Neuroprótesis Motora basada en las Tecnologías Brain-Computer-Interface (BCI) y Estimulación Eléctrica Muscular para Rehabilitación Funcional - Fase I" con código 2018214.

REFERENCES

- [1] World Health Organization, *World Report on Disability*, WHO, Geneva, 2011, ISBN 9789241564182.
- [2] D.J McFarland and J.R Wolpaw, "Brain-computer interfaces for communication and control." *Communications of the ACM*, vol. 5, pp. 60–66, 2011.
- [3] A. Rezeika, M. Benda, P. Stawicki, F. Gemblar, A. Saboor, and I. Volosyak, "Brain-Computer Interface spellers: A review." *Brain Sciences*, vol. 8, pp. 1–38, 2018.
- [4] V. Patel and M. Patel, "Brain Computer Interface: Applications and P300 overview," in *the 10th ICCCNT International Conference on Computing, Communication and Networking Technologies*, Kanpur, India, 2019.
- [5] U. Chaudary, N. Birbaumer, and A. Ramos, "Brain-computer interfaces for communication and rehabilitation," *Nature Reviews Neurology*, vol. 12, pp. 513–525, 2016.
- [6] S. Abdulkader, A. Atia, S. Mostafa, and M. Mostafa, "Brain computer interfacing: Applications and challenges," *Egyptian Informatic Journal*, vol. 16, pp. 213–230, 2015.
- [7] A. F. Perez Vidal, M. A. Oliver Salazar, and G. Salas Lopez, "Development of a brain-computer interface based on visual stimuli for the movement of a robot joints," *IEEE Latin America Transactions*, vol. 14, no. 2, pp. 477–484, 2016.
- [8] J. Wolpaw and E. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*. New York (NY): Oxford University Press, 2012.
- [9] J. Hohne, M. Tangermann, and M. Towards, "User-friendly spelling with an auditory brain-computer interface: The charstreamer paradigm." *Plos ONE*, vol. 9, 2014.
- [10] A. Brouwer and J. Van Erp, "A tactile p300 brain-computer interface." *Frontier in Neuroscience*, vol. 4, pp. 1–19, 2010.
- [11] J. Li, R. Gu, H. Ji, Z. Pang, and M. Li, "Interaction study of SSVEP and P300 in electroencephalogram," in *The PIERS Progress In Electromagnetic Research Symposium*, Shanghai, China, 2016.
- [12] G. Baura, *Medical device technologies: a system-based overview using engineering standards*. San Diego(CA): Oxford Academic Press, 2011.
- [13] S. Karimi, M. T. A. Mijani, and S. Mirzakhachaki, "Comparison of the P300 detection accuracy related to the bci speller and image recognition scenario," *Arxiv*, vol. 1912.11371, 2019.
- [14] L. Farwell, "Talking off the top of your head: A mental prosthesis utilizing event-related brain potentials," *Electroencephalography Clinical Neurophysiology*, vol. 70, pp. 510–523, 01 1988.
- [15] E. Basar and A. Duzgun, "The CLAIR model: Extension of bronnmans areas based on brain oscillations and connectivity." *International Journal of Psychophysiology*, vol. 103, pp. 185–198, 2015.
- [16] H. Lee, Y. Kwon, Y. Kim, H. Kim, Y. Lee, J. Williamson, S. Fazli, and S. Lee, "EEG dataset and OpenBMI toolbox for three BCI paradigms: an investigation into BCI illiteracy." *Giga-Science*, vol. 8, pp. 1–16, 2019.
- [17] J. Hwang, M. Lee, and S. Lee, "A brain-computer interface speller using peripheral stimulus-based SSVEP and P300," in *The 5 th International Winter Conference on Brain-Computer Interface (BCI)*, Sabuk, South Korea, 2017.
- [18] X. Xiao, M. Xu, J. Jin, Y. Wang, T. Jung, and D. Ming, "Discriminative canonical pattern matching for single-trial classification of ERP components," *IEEE Transaction on Biomedical Engineering*, pp. 1–1, 2019.
- [19] K. A. Colwell, D. B. Ryan, C. S. Throckmorton, E. W. Sellers, and L. M. Collins, "Channel selection methods for the P300 speller," *Journal of Neuroscience Methods*, vol. 232, pp. 6–15, 2014.
- [20] K. Won, M. Kwon, S. Jang, M. Ahn, and S. C. Jun, "P300 speller performance predictor based on RSVP multi-feature," *Frontiers in Human Neuroscience*, vol. 13, no. 261, pp. 1–14, 2019.
- [21] Z. Lin, C. Zhang, W. Wu, and X. Gao, "Frequency recognition based on canonical correlation analysis for ssvep-based bcis," *IEEE Transactions on Biomedical Engineering*, vol. 54, no. 6, pp. 1172–1176, 2007.
- [22] M. Spuler, A. Walter, W. Rosenstie, and M. Bogdan, "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.*, vol. 22, pp. 1097–1103, 2014.
- [23] S. Viana, D. Batista, and D. Melges, "Logistic regression models: Feature selection for P300 detection improvement," in *XXIV Congresso Brasileiro de Engenharia Biomédica-CBEB*, Belo Horizonte, 2014.
- [24] E. Motlagh and F. Ibrahim, "Developing an optimized single-trial P300-based brain computer interface system," in *International Conference for Innovation in Biomedical Engineering and Life Sciences*, Putrajaya, Malaysia, 2015.
- [25] R. Acevedo, Y. Atum, I. Gareis, J. Biurrun Manresa, V. Medina Bañuelos, and L. Ruffner, "A comparison of feature extraction strategies using wavelet dictionaries and feature selection methods for single trial P300-based BCI," *Med Biol Eng Comput*, vol. 57, pp. 589–600, 2019.
- [26] M. Xu, C. Long, and F. He, "Incorporation of inter-subject information to improve the accuracy of subject-specified P300 classifiers," *International Journal of Neural Systems*, vol. 26, pp. 1–10, 2016.



Cristian Felipe Blanco C.F. Blanco-Díaz received the Biomedical Engineering degree from Antonio Nariño University. Member of the research group Bioengineering, dedicated to research lines related to the analysis of biomedical technologies, biomechanical information, signal processing, Brain-Computer Interfaces and Rehabilitation Engineering.



A.F. Ruiz-Olaya A.F. Ruiz-Olaya received the Electronic Engineering degree from University of Valle (Colombia) and his Ph.D. degree from Carlos III University of Madrid (Spain). He is an associate professor of the Faculty of Electronics and Biomedical Engineering at the Antonio Nariño University (Colombia). His research interests include rehabilitation engineering, multimodal human-robot interaction, and biomedical signal processing.