



Casa abierta al tiempo
UNIVERSIDAD AUTÓNOMA METROPOLITANA

**UNIVERSIDAD AUTÓNOMA METROPOLITANA
UNIDAD IZTAPALAPA**

DIVISIÓN DE CIENCIAS BÁSICAS E INGENIERÍA

**“ANÁLISIS DE REGISTROS DE EEG
UTILIZANDO CORRELACIÓN CANÓNICA PARA
OPTIMIZACIÓN DE TIEMPOS EN INTERFACES
CEREBRO-COMPUTADORA”**

TESIS

QUE PRESENTA

**FELIPE DE JESÚS GARCIDUEÑAS VARGAS
MATRÍCULA 2151801117**

PARA OBTENER EL GRADO DE
**MAESTRO EN CIENCIAS
(INGENIERÍA BIOMÉDICA)**

DIRECTOR:
M.EN IB. ÓSCAR YÁÑEZ SUÁREZ

JURADOS:
**DRA. VERONICA MEDINA BAÑUELOS
M. EN C. CLAUDIA IVETTE LEDESMA RAMIREZ**

Iztapalapa, Ciudad de México, agosto de 2021

Índice

1. Resumen	2
2. Introducción	2
2.1. Justificación	2
2.2. Antecedentes	3
2.2.1. Actividad eléctrica del cerebro y Electroencefalograma	4
2.2.2. Potenciales Provocados de Estado Estacionario y Potenciales Relacionados a Eventos	5
2.2.3. Interfaces Cerebro-Computadora (BCI)	6
2.2.4. Aprendizaje Maquinal en BCI	7
2.2.5. Optimización de tiempos en BCI basadas en P300	8
3. Hipótesis y Objetivos	10
4. Metodología	10
4.1. Descripción de la base de datos de P300	10
4.2. Etapa I. Preprocesamiento de las señales	13
4.2.1. Filtrado	13
4.2.2. Promediación coherente y selección de canales	13
4.3. Etapa II. Extracción de características	15
4.3.1. Análisis de correlación canónica (CCA). Teoría y su aplicación	15
4.3.2. Selección de vectores base mediante la prueba de Kruskal-Wallis	16
4.4. Etapa III. Clasificación	18
4.4.1. Máquinas de soporte vectorial	18
4.4.2. Entrenamiento de la máquina de soporte vectorial	24
4.5. Evaluación del desempeño del clasificador	26
5. Resultados	31
5.1. Discusión de resultados	36
6. Conclusiones	43
7. Referencias	46
8. Anexo de resultados por sujeto	51

1. Resumen

Las interfaces cerebro-computadora (BCI) son herramientas de gran utilidad para ayudar a personas que por algún motivo han perdido capacidades motrices y con ello la capacidad de interactuar con su entorno. Entre algunas de las aplicaciones en que pueden ser utilizadas las BCI se encuentran sistemas de rehabilitación, deletreadores, etc. El presente trabajo se enfoca en el deletreador basado en P300. Dado que el funcionamiento de esta BCI depende de la correcta detección de la onda P300, un enfoque muy utilizado es el de realizar una gran cantidad de estimulaciones a fin de que se pueda detectar mejor al realizar una promediación coherente. Sin embargo el enfoque de múltiples estimulaciones tiene la desventaja de hacer que sea muy extenso el tiempo de escritura de una palabra simple, por lo que varios abordajes se han hecho para hacer más eficiente este proceso de detección. Uno de los acercamientos al problema es la proyección en subespacios. El método de análisis de correlación canónica (CCA) utilizado en este trabajo pertenece a dicho enfoque y ya ha sido utilizado con buenos resultados en otras BCI basadas en otros paradigmas como el de potenciales provocados de estado estable, por lo cual se exploran en este trabajo los alcances del CCA en el paradigma P300, buscando obtener tasas de reconocimiento de ondas P300 mayores al 70 % con el menor número de épocas posible.

2. Introducción

2.1. Justificación

Los sujetos con trastornos neurológicos severos, incluso aquellos que están completamente paralizados (como en el síndrome de enclaustramiento), podrían beneficiarse de las interfaces cerebro-computadora (BCI por sus siglas en inglés), que ofrecen habilidades de comunicación básica mediante las cuales pueden expresarse, por ejemplo, controlando un programa deletreador u operando una neuroprótesis. Las BCI permiten a un sujeto comunicarse y controlar el mundo externo sin utilizar las salidas normales del cerebro a través de nervios periféricos y músculos. Los mensajes se envían mediante señales eléctricas del cerebro provocadas o espontáneas en vez de contracciones musculares como las usadas para la comunicación a través del habla o la escritura.

Dado que las BCI deben funcionar en tiempo real, es importante que el procesamiento de señal no introduzca tiempos de retardo inaceptables. Adicionalmente, la fase de entrenamiento de una BCI no es un procedimiento que se haga una única vez y que produzca un clasificador con parámetros fijos, sino que debe ser repetida a menudo. Dado que las señales eléctricas del cerebro muestran una variabilidad considerable debido a factores como la hora del día, nivel hormonal y fatiga, es necesario ajustar el clasificador para mantener un desempeño aceptable.

Tanto el procesamiento de la señal como el entrenamiento del clasificador de la BCI están directamente asociados con la “extracción de rasgos o extracción de características”, elemento crucial para la operación de estas interfaces. Buenos rasgos implican clasificación robusta, y requieren métodos bien diseñados de extracción por tratamiento de las señales. Mediante el análisis de correlación canónica se puede maximizar la correlación entre variables aleatorias en un contexto de proyecciones en subespacios, por lo que se pretende explorar la técnica para mejorar el rendimiento de las BCI.

Las BCI operadas con P300 utilizan por lo general rasgos temporales de las señales de EEG, tanto latencias como amplitudes a esas latencias. También se suele incorporar un procedimiento de selección de canales de EEG útiles para la detección en cada paciente. Sin embargo no se conocen soluciones que indaguen relaciones temporales de actividad entre canales, que pueden reflejar actividad cognitiva más allá de la observación independiente de los canales como se hace actualmente. La correlación canónica puede ser un instrumento para indagar esas relaciones multicanal y por lo tanto se espera que pueda reflejar la ocurrencia de los potenciales relacionados a evento (PRE) sin las restricciones temporales (número de repeticiones necesarias) de la promediación coherente.

2.2. Antecedentes

En esta sección se abordarán temas de utilidad para el desarrollo de este proyecto, como los potenciales provocados relacionados a eventos, potenciales provocados de estado estable, las BCI, además de algunos de los avances actuales en la mejora de los tiempos involucrados en la aplicación de una BCI.

2.2.1. Actividad eléctrica del cerebro y Electroencefalograma

El registro de la actividad eléctrica de la superficie expuesta del cerebro o de la superficie externa de la cabeza demuestra una continua actividad eléctrica oscilante dentro del cerebro. Tanto la intensidad como los patrones de esta actividad eléctrica son determinados por la excitación general del cerebro. Las ondulaciones en los potenciales eléctricos registrados son llamadas ondas cerebrales y al registro completo de ellas sobre el cuero cabelludo, se le conoce como Electroencefalograma (EEG). La intensidad de las ondas cerebrales en la corteza cerebral puede tener una magnitud de hasta 10mV, mientras que aquellas registradas en el cuero cabelludo tienen una amplitud menor, de aproximadamente $100\mu\text{V}$. Las frecuencias de estas ondas cerebrales tienen un rango aproximado desde 0.5 hasta 100Hz y su carácter es altamente dependiente del grado de actividad de la corteza cerebral [1].

Las señales son registros espacio temporales que pueden tener una o múltiples variables dependientes e independientes que muestrean algún aspecto de un evento o eventos biológicos. En el caso más simple, una señal puede ser una serie de tiempo (variable independiente) de alguna cantidad medida por un cambio de voltaje (variable dependiente).

Las series de tiempo, espacio y espacio-tiempo pueden ser procesadas con técnicas de análisis de patrones [2, 3]. Las señales biológicas pueden ser categorizadas como aleatorias, determinadas por el grado de autocorrelación de la señal, dada por la ecuación (1)[4]:

$$r(k) = \sum_{n=0}^{n-1} x(n)x(n+k) \quad (1)$$

Muchas **señales aleatorias** están altamente autocorrelacionadas únicamente en el retardo $k \approx 0$. Aquellas que no son aleatorias se denominan **señales deterministas** y están altamente autocorrelacionadas en fases que se extienden más allá de cero. Si la señal determinista es periódica, la función de autocorrelación también será periódica y corresponderá a la periodicidad de la serie de tiempo [5].

Los mecanismos del sistema nervioso central para el ritmo de despolarización de las células dependen no solo de un umbral para la transmisión de célula a célula, sino también del número y peso de todas las entradas excitatorias e inhibitorias en una célula dada. De esta forma, las células adyacentes en el cerebro tienden a no despolarizarse secuencialmente, dando al EEG

señales de menor correlación. En contraste, muy pocas células cardiacas y de tejido liso están inervadas por el cerebro. En cambio son mecanismos de despolarización local los que producen una secuencia o frente de onda para el proceso de conducción [5].

2.2.2. Potenciales Provocados de Estado Estacionario y Potenciales Relacionados a Eventos

Los potenciales provocados de estado estacionario (PPEE) son respuestas eléctricas del cerebro a estímulos visuales o auditivos modulados a una frecuencia superior a los 6 Hz. Estos potenciales poseen la misma frecuencia fundamental del estímulo así como sus armónicos. Los PPEE visuales y auditivos se pueden registrar en el cuero cabelludo en el área de la corteza occipital y temporal respectivamente [6].

En las BCI basadas en PPEE, se codifican los estímulos visuales con diferentes frecuencias. Se pueden producir distintos PPEE cuando el sujeto cambia su atención de un estímulo hacia otro estímulo codificado en otra frecuencia. Dentro de las ventajas de estos sistemas se encuentra una alta relación señal a ruido y alta tasa de transferencia de información, además, como se trata de una respuesta inherente del cerebro, se requiere poco entrenamiento del usuario de la BCI [7]. La desventaja de este paradigma de estimulación es que no pueden utilizarse muchos estímulos diferentes, ya que las frecuencias que pueden usarse para codificar son limitadas, tanto por la percepción del ojo humano, como también por el hecho de que los armónicos de cada frecuencia de estimulación se perciben por el sujeto como si fuera el mismo estímulo, por lo que hay que cuidar que los armónicos de un estímulo no interfieran con otra frecuencia de estimulación.

Un potencial relacionado a eventos (PRE) es una respuesta específica del cerebro a un evento como un estímulo, un error, un evento motor, etc. En teoría, estas respuestas del cerebro son, dependiendo del evento, una deflexión positiva o negativa de los potenciales registrados sobre el cuero cabelludo. Hay un retraso fijo entre el evento y el potencial provocado por él, es decir que ciertos estímulos generan respuestas específicas en tiempos conocidos. Sin embargo, puede haber algo de variabilidad entre diferentes sujetos e incluso entre diferentes mediciones del mismo tipo de PRE del mismo sujeto. Un par de ejemplos de este tipo de potenciales son el potencial N170 y la onda P300 [8].

La respuesta N170 está asociada con el procesamiento de caras y consiste

en una deflexión negativa en el EEG 170ms después del estímulo. La onda P300 es una deflexión positiva que ocurre 300ms después del estímulo y puede ser generada por eventos infrecuentes. Para generar P300, el sujeto debe enfocar su atención en un estímulo objetivo poco frecuente que se encuentra embebido en una serie de estímulos no objetivo más frecuentes [8].

Cuando el estímulo objetivo se presenta, se genera una respuesta P300; así cuando la computadora detecta esta respuesta, puede ejecutar una acción elegida por el usuario asociada a este estímulo objetivo. Desafortunadamente, no es posible aún detectar una respuesta P300 con una sola presentación de cada estímulo, por lo tanto es necesario presentar varias veces el estímulo para asegurar que el sistema detecte esta respuesta [8], luego de realizar promediaciones coherentes en el tiempo que incrementen la relación señal a ruido.

2.2.3. Interfaces Cerebro-Computadora (BCI)

El concepto de Interfaz Cerebro-Computadora se refiere en términos generales a un dispositivo para controlar algún actuador específico utilizando únicamente señales cerebrales, concepto introducido por Vidal a principios de la década de 1970 [8].

Las BCI se basan en la detección de señales cerebrales específicas. Estas señales pueden ser la modulación voluntaria de ritmos cerebrales como en la imaginación de movimiento u otros potenciales como los PRE, o los PPEE.

Existen varias aplicaciones de BCI, entre las cuales se encuentran las basadas en potenciales relacionados a evento, introducidas por Farwell y Donchin [9], y las que están basadas en potenciales provocados de estado estable como la propuesta por Cheng et al [10].

El enfoque de este proyecto estará en las BCI basadas en PRE, específicamente en potenciales P300; sin embargo en la literatura se encuentran gran cantidad de referencias de aplicaciones de la correlación canónica aplicada a BCI basadas en PPEE, por mencionar algunas están el trabajo de Gao et al. [7] en que se utilizan seis estímulos objetivo en un monitor y se utilizan 9 canales de EEG para 12 sujetos, obteniendo una certeza promedio de 95.3%.

Waytowich et al. [11] realizaron estímulos visuales con una matriz de LED a 22 pacientes utilizando frecuencias entre los 5.5 y los 34.5 Hz y registrando 9 canales de EEG. Mediante el análisis de correlación canónica se encontraron las frecuencias de estimulación óptimas para cada sujeto, lo cual permitió obtener una mejora en la precisión del clasificador utilizado en la BCI, de un

72 % de precisión original a un 83.7 % [11].

Wei et al. [12] aplicaron el análisis de correlación canónica en registros de cuatro canales para 12 sujetos, empleando un monitor con un solo marcador que parpadeaba de 9 a 13 Hz, obteniendo una certeza promedio de 67.85 %. Lin et al. [13] recurrieron a un teclado virtual en un monitor en que cada tecla parpadeaba a una frecuencia diferente entre los 27 y 43 Hz, se analizaron 11 sujetos y se utilizaron 8 canales de EEG, obteniendo certezas promedio de 75 %.

Chang et al. [14] presentan un sistema híbrido de SSVEP y P300, obteniendo desempeños de certeza mayores 80 %, utilizando un mínimo de 5 canales y CCA para la clasificación de SSVEP. Por otro lado, Kaongoen et al. [15] utilizan potenciales evocados auditivos de estado estacionario y P300, para clasificarlos aplica CCA y SWLDA, obteniendo desempeños mayores al 85 %. Lotte et al. [16] analizaron registros de deletreo P300 de 8 canales y utilizando aproximadamente 60 épocas para el análisis con CCA, reportando desempeños mayores a 80 %, lo que abre la posibilidad a reducir la cantidad de canales y épocas.

2.2.4. Aprendizaje Maquinal en BCI

El funcionamiento de una BCI depende de que el sistema sea capaz de reconocer las señales cerebrales generadas por el sujeto, sin embargo sería muy inconveniente tomar un largo tiempo para entrenar al sujeto en cómo modular de la forma más eficiente sus señales cerebrales para ser reconocidas por la computadora, por ello se utiliza el enfoque del aprendizaje maquinal o reconocimiento de patrones, donde se considera el desarrollo de algoritmos que permiten a una computadora aprender a partir de los datos [17], en este caso obtenidos de las señales de EEG.

De acuerdo con [5], el análisis de patrones en señales biológicas puede describirse como una serie de pasos:

1. Sensado de uno o varios sitios.
2. Preprocesamiento de los datos (filtrado analógico, conversión de analógico a digital, etc.) y normalización de los datos.
3. Extracción de características. Características estructurales, descripciones o gráficas estructurales, etc.

4. Selección de las mejores características. Para la formación de propiedades, clusters, clasificación o interpretación
5. Combinación de características.
6. Clustering de características y propiedades en grupos basados en medidas de similitud cuando sea apropiado.
7. Uso de características a fin de hacer una detección de parámetros, discriminación o clasificación. Interpretación de los resultados obtenidos.

Este enfoque de aprendizaje maquina es necesario debido a que problemas complejos como la decodificación de señales cerebrales no pueden resolverse mediante algoritmos estándar, puesto que existe una enorme variabilidad en los datos del electroencefalograma y no es posible tener una serie de instrucciones fijas para analizar señales cerebrales de distintos pacientes o incluso del mismo paciente pero en distintas sesiones de estudio.

Estos algoritmos de aprendizaje maquina se entrenan con datos obtenidos en una sesión de calibración o entrenamiento, en la cual se le pide al usuario que lleve a cabo una tarea específica en un momento específico. De esta forma, el desarrollador de la BCI puede etiquetar los datos del EEG con las acciones del sujeto. Este conjunto de datos etiquetados se pasa al algoritmo de aprendizaje maquina, el cual analiza los datos y aprende cómo decodificar estas señales cerebrales específicas del usuario. Una vez realizada esta sesión de calibración es cuando puede realmente ponerse en marcha el sistema para decodificar las señales cerebrales y el usuario puede comenzar a utilizar el sistema para la aplicación para la que se diseñó. Estas sesiones de calibración pueden reducir significativamente el tiempo disponible para el uso de la BCI. Por ello un gran desafío es reducir o incluso remover la dependencia de esta sesión de calibración [8].

2.2.5. Optimización de tiempos en BCI basadas en P300

En el Laboratorio de Investigación en Neuroimagenología (LINI) se ha trabajado en un abordaje para acelerar el proceso de clasificación en una BCI controlada mediante potenciales de respuesta al estímulo infrecuente o P300. Este trabajo fue presentado por C. Lindig y O. Yáñez[18], en donde se utiliza un enfoque bayesiano para calcular la probabilidad posterior de la clase de cada target. Es decir, el sistema detiene la estimulación cuando

encuentra suficiente evidencia para poder discriminar si ya se ha detectado la onda P300 sin depender de un número fijo de estimulaciones, reduciendo así el tiempo de clasificación y a la vez obteniendo un buen rendimiento en la precisión.

En este proyecto se busca reducir el número de repeticiones del estímulo buscando la información de la onda P300 utilizando la correlación canónica en canales de EEG con información similar. Esta reducción de repeticiones puede impactar directamente en varios aspectos:

- Hacer más fluida la comunicación del paciente con su entorno, pues entre más veces tenga que mostrarse un estímulo para poder expresar parte de su mensaje o de ejecutar una orden, se hace más lento el proceso de comunicación del propio paciente.
- Evitar cansancio del paciente de varias formas, en un inicio por el tiempo de preparación, pues la colocación de un arreglo de 16, 32 o 64 electrodos consume bastante tiempo para hacerse bien y una vez terminada esta colocación, resulta bastante incómoda para usarse durante periodos prolongados y además dificulta movilizar al sujeto o repositonarlo.
- Como se ha mencionado, el tiempo de preparación puede impactar en el cansancio del paciente pero también impacta directamente en la comunicación del paciente, puesto que un arreglo de muchos electrodos requerirá de una mayor inversión de tiempo para ponerse en marcha, lo cual es tiempo de espera para poder comunicar al paciente con su entorno.
- Hacer más accesible un sistema comercial al disminuir la cantidad de electrodos necesarios para su funcionamiento o también al lograr disminuir los requisitos de procesamiento del equipo de cómputo y por ende el costo del sistema en conjunto.

Por último, la comodidad del paciente también depende del tiempo de preparación, de la cantidad de electrodos necesarios para el funcionamiento del sistema y la cantidad de estímulos que necesita para poder comunicarse por lo que finalmente estos factores también terminarán generando una preferencia de los pacientes y usuarios por los sistemas que les permitan realizar las funciones que requieren en el menor tiempo, menor costo y mayor grado de comodidad.

3. Hipótesis y Objetivos

Hipótesis

El análisis de correlación canónica puede servir como extractor de características para permitir una clasificación por encima del 70 % con un número reducido de épocas para clasificar registros de EEG con P300 de registros sin P300 en una tarea de delecteo.

Objetivos

- Aplicar el análisis de correlación canónica en registros de EEG multi-canal para acelerar el proceso de entrenamiento y recalibración de un clasificador de potenciales P300 para una BCI.
- Usar un abordaje de proyección en subespacios para la extracción de rasgos útiles para la clasificación.
- Diseñar un procedimiento de clasificación con máquinas de soporte vectorial una vez extraídos los rasgos necesarios, realizando su correspondiente validación estadística.

4. Metodología

El proyecto se dividió en tres etapas principales: una etapa de preprocesamiento de la señal a fin de acondicionarla para la etapa de procesamiento siguiente; una etapa de extracción de características en la cual se realizó el análisis de correlación canónica y finalmente una etapa de clasificación donde se diseñó y entrenó una máquina de soporte vectorial como clasificador de las señales. En la figura 1 se muestra un diagrama de bloques de la metodología utilizada para después describirla etapa por etapa con más detalle.

4.1. Descripción de la base de datos de P300

Para probar esta técnica se hizo uso de la base de datos pública de P300 del LINI [19]. Esta base de datos contiene registros de EEG de 30 alumnos sanos de la UAM-I, 18 hombres y 12 mujeres, en un rango de edades entre 19 y 25 años de edad con condiciones controladas como horas de sueño de la noche anterior, consumo de drogas, etc. Los registros son de una serie de delecteos utilizando la aplicación P300_speller (delecteador de Donchin) del software BCI2000.

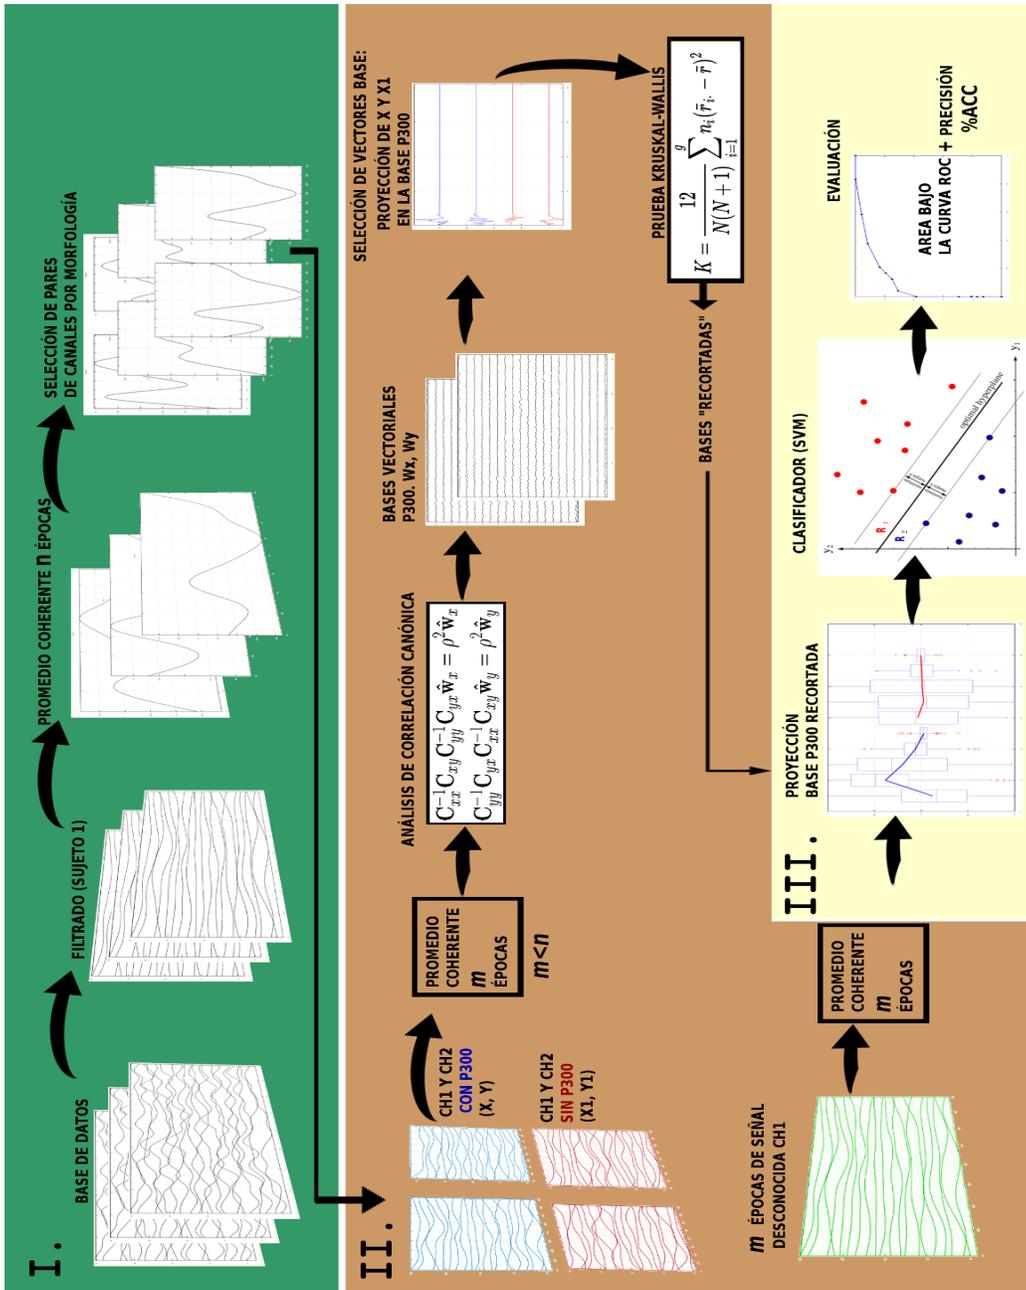


Figura 1: Diagrama a bloques de la metodología utilizada.

Cada sujeto participó en 4 sesiones de 15 secuencias:

1. Tres corridas de deletreo dirigido.
2. Una corrida de deletreo dirigido con retroalimentación de un clasificador entrenado con datos de la sesión 1.
3. Tres corridas de deletreo libre (palabras elegidas por el usuario, 15 caracteres por sujeto).
4. Corridas variables de deletreo libre con un número reducido de secuencias.

Los registros fueron obtenidos de 10 canales siguiendo el sistema 10-20 (Fz, C3, Cz, C4, P3, Pz, P4, PO7, PO8, Oz) como se muestra en la figura 2.

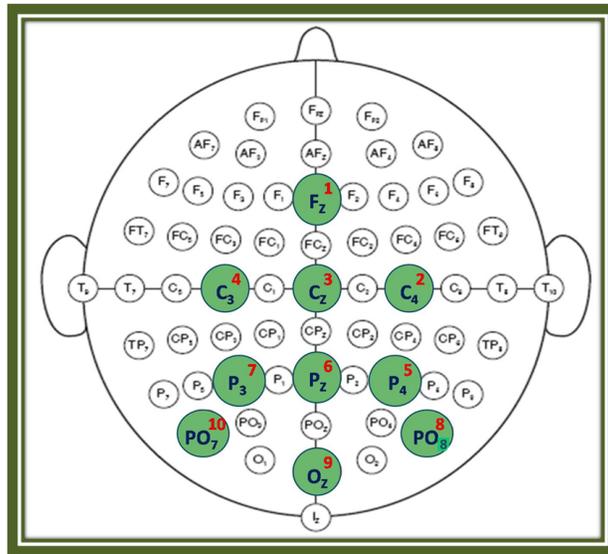


Figura 2: Canales utilizados para el registro en la base de datos de P300. Obtenido de [19].

La adquisición se hizo a 256 muestras por segundo usando un amplificador gUSBamp de g.tec utilizando como características de adquisición un filtro rechaza banda Chebyshev de cuarto orden de 58 a 62 Hz y un filtro pasa banda Chebyshev de octavo orden con frecuencias de 0.1 a 60 Hz [19].

El análisis se realizó sobre los registros de EEG de todos los sujetos de la base de datos. Para ejemplificar los pasos de la metodología se muestran

las gráficas obtenidas para el primer sujeto analizado: GCE. Este sujeto fue elegido aleatoriamente. En la sección de resultados se da un panorama de los resultados obtenidos para todos los sujetos y finalmente en la sección de anexos se muestran los resultados finales para cada sujeto.

4.2. Etapa I. Preprocesamiento de las señales

4.2.1. Filtrado

Una vez elegidos los registros del sujeto, se procedió a hacer un filtrado FIR pasa bajas de orden 60, usando una ventana de Hamming y con frecuencia de corte a 3 Hertz en todos los canales a fin de eliminar los elementos de mayor frecuencia que para nuestro análisis son considerados como ruido. Se eligió la frecuencia de corte pasabajas de 3 Hz debido a que la información del P300 se encuentra alrededor de los 3.3 Hz [20], sin embargo debido a la caída no tan pronunciada del filtro FIR, se consideró que no causaría una pérdida significativa de la información.

Una vez realizado el filtrado se procedió a normalizar los datos dejándolos con media cero y varianza unitaria, pues es el requerimiento que deben cumplir los datos para ser procesados mediante el análisis de correlación canónica que se llevó a cabo más adelante.

4.2.2. Promediación coherente y selección de canales

La promediación coherente es una técnica que permite mejorar la relación señal a ruido haciendo promediaciones de señales con información contaminada por ruido de media cero. En el contexto de la señal de P300, se asume que la actividad cerebral de fondo tiende a comportarse como un proceso de ruido de media cero, por lo que al hacer promediaciones de varias señales de actividad cerebral de fondo, ésta tiende a reducir su amplitud a cero, mientras que la señal de P300 mantiene su amplitud, pues es una señal con media distinta a cero y una morfología bastante similar una con otra, por lo que al promediarse una onda P300 con otra se mantiene la morfología, cosa que no sucede con el ruido aleatorio.

Esta técnica es muy útil y provee buenos resultados para poder rescatar la información de la onda P300, sin embargo para lograr una promediación que otorgue buenos resultados por sí misma, es necesario hacer promedios de muchas señales (épocas) con P300, como se muestra en la figura 3.

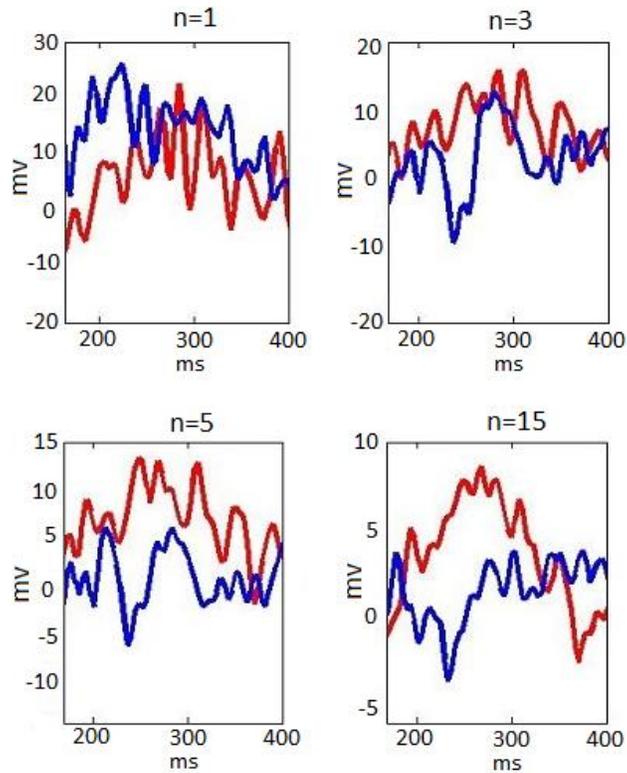


Figura 3: Resultados de ir aumentando el número de épocas con P300 en la promediación coherente. El trazo en azul representa el promedio de épocas sin P300, mientras que el trazo en rojo muestra el promedio de épocas con P300. Obtenido de [18].

Una vez filtrados y normalizados los datos, se procedió a obtener los promedios coherentes de todas las n épocas correspondientes a P300 para cada canal de la primera corrida del registro para observar la morfología de la señal de P300 en cada uno de los canales y poder seleccionar un par de electrodos en los que la morfología de la señal sea más parecida. Cabe mencionar que la n es de 480 épocas para el sujeto de ejemplo GCE y que la comparación de morfologías se realizó de manera visual sin utilizar ninguna métrica.

Esta selección del par de canales se realizó para poder realizar el análisis de correlación canónica sobre ellos y proceder a hacer la extracción de características.

Sobre el par de canales elegido se realizó el análisis de la señal de EEG sin promediar con la finalidad de observar el resultado de la correlación canónica en registros sin mayor preprocesamiento para poder contrastar contra el desempeño obtenido al aplicarla sobre registros con promediación coherente de 2, 3, 4 y 5 épocas.

4.3. Etapa II. Extracción de características

4.3.1. Análisis de correlación canónica (CCA). Teoría y su aplicación

El análisis de correlación canónica (CCA) es una manera de medir la dependencia lineal entre dos variables multidimensionales. Mediante este análisis se encuentran dos bases, una para cada variable, que son óptimas respecto a las correlaciones, y al mismo tiempo, encuentra las correlaciones correspondientes.

Al proyectar las variables sobre estas bases se obtiene una matriz de correlación diagonal y las correlaciones en la diagonal están maximizadas.

Es decir, dado un par de variables aleatorias X y Y, mediante la correlación canónica se obtiene un par de bases vectoriales W_x y W_y para cada variable aleatoria respectivamente. Al proyectar X en W_x y Y en W_y se obtienen las **dimensiones canónicas** (*cannonical variates*). La correlación entre dimensiones canónicas será mutuamente maximizada.

El cálculo de la correlación canónica se lleva a cabo de la siguiente manera [21]:

Consideremos las variables aleatorias X y Y con media cero. La matriz de covarianza total es:

$$C = \begin{bmatrix} C_{xx} & C_{xy} \\ C_{yx} & C_{yy} \end{bmatrix} = E \left[\begin{pmatrix} X \\ Y \end{pmatrix} \begin{pmatrix} X \\ Y \end{pmatrix}^T \right] \quad (2)$$

Esta es una matriz por bloques donde C_{xx} y C_{yy} son las matrices de autocovarianza de X y Y respectivamente y $C_{xy} = C_{yx}^T$ es la matriz de covarianza cruzada.

Las correlaciones canónicas entre X y Y se pueden encontrar resolviendo las ecuaciones de eigenvalores:

$$C_{xx}^{-1}C_{xy}C_{yy}^{-1}C_{yx} = \rho^2 W_x \quad (3)$$

$$C_{yy}^{-1}C_{yx}C_{xx}^{-1}C_{xy} = \rho^2 W_y \quad (4)$$

Donde los eigenvalores ρ^2 son las correlaciones canónicas al cuadrado y los eigenvectores W_x y W_y son los vectores base normalizados de la correlación canónica.

El número de soluciones diferentes de cero a estas ecuaciones está limitado a la menor dimensión entre X y Y. Por ejemplo, si la dimensión de X es 8 y la de Y es 5 el máximo número de correlaciones canónicas es 5.

De esta forma las dimensiones canónicas se obtienen mediante la proyección:

$$\mathbf{x} = X^T W_x \quad (5)$$

$$\mathbf{y} = Y^T W_y \quad (6)$$

En el presente trabajo, el análisis de correlación canónica se realizó entre las señales con P300 del par de canales con morfologías similares en la onda P300, seleccionados después de una promediación coherente de un número reducido de épocas.

Las épocas del par de canales seleccionados se utilizan como las variables multidimensionales X y Y sobre las cuales se busca encontrar una correlación alta pues ambas variables contienen la información de las señales de P300 similares y por ello las bases vectoriales W_x y W_y que se obtengan de ellas dos, serán bases con componentes que describan la morfología de la señal P300 que se busca identificar al proyectar en ellas las épocas de EEG.

4.3.2. Selección de vectores base mediante la prueba de Kruskal-Wallis

A fin de poder encontrar diferencias significativas entre las proyecciones de las épocas con y sin P300 para saber qué tan útiles podrían ser estas proyecciones en una tarea de clasificación, se buscó un método que permitiera conocer diferencias significativas entre dos grupos.

Así que se procedió a hacer un análisis de varianza y al observar que la distribución de los datos no seguía una distribución normal o alguna función de distribución de probabilidad conocida, se optó por los métodos no

paramétricos de análisis de varianza. En este caso el método elegido fue la prueba de Kruskal-Wallis.

La prueba de Kruskal-Wallis es un análisis de varianza para probar la hipótesis nula de que las medias de varios grupos son iguales. Esta prueba se utiliza cuando las poblaciones de las cuales se extraen las muestras no están distribuidas normalmente con varianzas iguales, o cuando los datos para el análisis constan sólo de rangos.

La aplicación de esta prueba comprende los siguientes pasos [22]:

1. Las n_1, n_2, \dots, n_k observaciones de los k grupos, se combinan en una sola serie de tamaño n y se disponen en orden de magnitud desde la más pequeña hasta la más grande. Las observaciones se sustituyen entonces por rangos desde 1, que es el asignado a la observación menor, hasta n , que se asigna a la observación mayor. Cuando dos o más observaciones tienen el mismo valor, a cada una de ellas se le da la media de los rangos con los cuales está relacionada.
2. Los rangos asignados a las observaciones en cada uno de los k grupos se suman por separado para dar k sumas de rangos.
3. Se calcula el estadístico de prueba:

$$H = \frac{12}{n(n+1)} \sum_{j=1}^k \frac{R_j^2}{n_j} - 3(n+1) \quad (7)$$

donde: \mathbf{k} = número de grupos, \mathbf{n}_j = el número de observaciones en el j -ésimo grupo, \mathbf{n} = el número de observaciones en todos los grupos combinados y \mathbf{R}_j = la suma de los rangos en el j -ésimo grupo.

4. Cuando se tienen tres grupos y cinco o menos observaciones en cada grupo, la significación de la H calculada se determina consultando una tabla de valores críticos para esta prueba. Cuando hay más de cinco observaciones en uno o más de los grupos, H se compara con los valores tabulados de la χ^2 con $k-1$ grados de libertad.

De esta forma, si $H < \chi^2$ se acepta la hipótesis nula de que las muestras (en este caso las componentes de las proyecciones de las épocas P300 y no P300 sobre las bases vectoriales W_x y W_y) vienen de la misma población, es decir que no hay diferencia significativa entre las proyecciones sobre esas

componentes. En caso de que $H > \chi^2$ se rechaza la hipótesis nula y se asume que sí hay diferencias significativas en las proyecciones de las épocas P300 y no P300 sobre estas componentes.

4.4. Etapa III. Clasificación

Una vez extraídas las características de las señales de EEG, se puede dividir la información en matrices de características o rasgos para la clase P300 y la clase no P300, con la que se puede diseñar un algoritmo de clasificación que nos permita identificar automáticamente entre una clase y otra. El algoritmo elegido fue la máquina de soporte vectorial (SVM por sus siglas en inglés).

4.4.1. Máquinas de soporte vectorial

Las máquinas de soporte vectorial son clasificadores binarios, es decir pensados para la separación de dos clases, lo cual es el objetivo de este proyecto, ya que sólo buscamos separar entre la clase P300 y la clase no P300.

Para abordar la teoría de las máquinas de soporte vectorial, se abordará el escenario de clasificación de dos clases usando modelos lineales con la ecuación del hiperplano de la forma [17]:

$$y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + \mathbf{b} \quad (8)$$

Donde $\phi(\mathbf{x})$ denota una transformación del espacio de características que puede o no hacerse, dependiendo de la separabilidad de los datos. El conjunto de datos de entrenamiento está compuesto de N vectores de entrada $\mathbf{x}_1, \dots, \mathbf{x}_n$ con sus correspondientes etiquetas de clase t_1, \dots, t_n donde $t_n \in \{-1, 1\}$, -1 para la clase 1 y 1 para la clase 2, b es una constante que indica la separación del hiperplano al origen, y los nuevos datos \mathbf{x} son clasificados de acuerdo al signo de $y(\mathbf{x})$ [17].

Es decir, la regla de decisión de la SVM es:

Si

$$y = \text{sgn}(w^T \phi(x_i) + b) > 0 \quad (9)$$

Entonces se asigna el patrón x_i a la clase 2, en caso contrario se asignará a la clase 1.

En el caso en que las clases son linealmente separables, puede llegar a haber múltiples soluciones para la ecuación (8), sin embargo nos interesa conocer la solución que nos otorgue el menor error de generalización.

Las máquinas de soporte vectorial abordan este problema con el concepto de margen. El margen se define como la distancia entre la frontera de decisión y los puntos más cercanos a ella. La localización de esta frontera está determinada por un subconjunto de los puntos, conocido como los vectores de soporte.

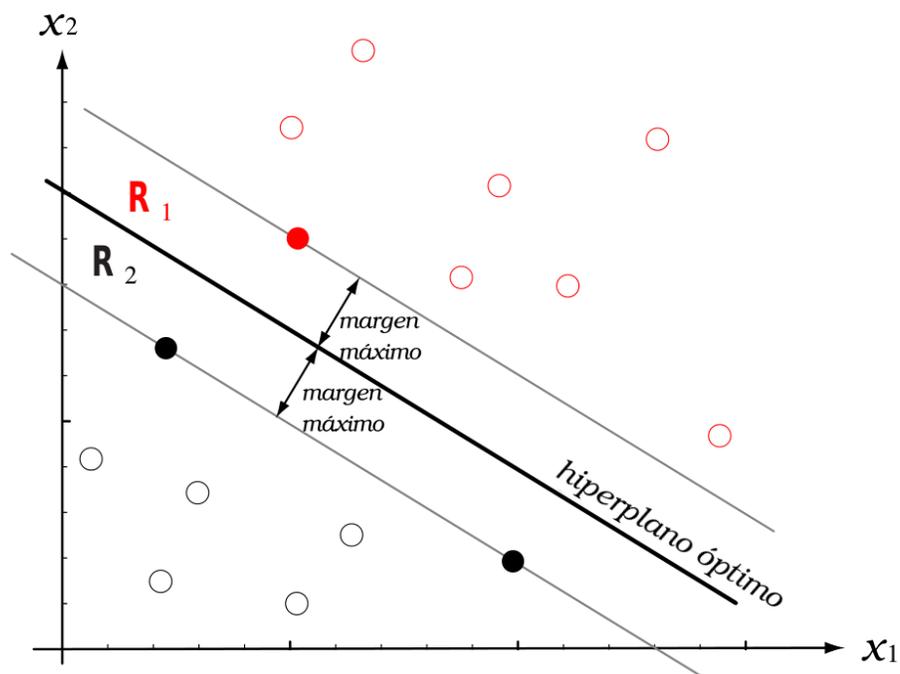


Figura 4: Hiperplano óptimo para la separación de clases obtenido maximizando el margen en una SVM. *Obtenido de [23].*

En las máquinas de soporte vectorial se elige la frontera de decisión en la cual el margen es máximo. Encontrar este margen máximo es la tarea que se lleva a cabo mediante el proceso de diseño o entrenamiento de la SVM, dicho margen se encuentra al maximizar $\|w\|^{-1}$, pero como el margen que queremos obtener es aquél en que los datos están bien clasificados, esta maximización está restringida a la condición:

$$t_n(w^T \phi(x_n) + b) \geq 1, \quad n = 1, \dots, N. \quad (10)$$

Además, la maximización de $\|w\|^{-1}$ es equivalente a minimizar $\|w\|^2$, de tal forma que el margen óptimo se obtiene mediante [17]:

$$\underset{w,b}{\operatorname{argmin}} \frac{1}{2} \|w\|^2 \quad (11)$$

A fin de facilitar el proceso de optimización se utiliza el método de multiplicadores de Lagrange, obteniendo la función:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{n=1}^N \alpha_n [t_n(w^T \phi(x_n) + b) - 1] \quad (12)$$

Derivando $L(w, b, \alpha)$ e igualando a cero se obtiene, con respecto a w :

$$\begin{aligned} L'_w &= w - \sum_{n=1}^N \alpha_n t_n \phi(x_n) \\ 0 &= w - \sum_{n=1}^N \alpha_n t_n \phi(x_n) \\ w &= \sum_{n=1}^N \alpha_n t_n \phi(x_n) \end{aligned} \quad (13)$$

Con respecto a b :

$$\begin{aligned} L'_b &= \sum_{n=1}^N \alpha_n t_n \\ 0 &= \sum_{n=1}^N \alpha_n t_n \end{aligned} \quad (14)$$

Eliminando w y b de la ecuación (12), sustituyendo estos resultados de las ecuaciones (13) y (14), se obtiene la representación dual del problema del margen máximo, en el cual se maximiza α en la ecuación:

$$\tilde{L}(\alpha) = \sum_{n=1}^N \alpha_n - \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N \alpha_n \alpha_m t_n t_m \phi(x_n)^T \cdot \phi(x_m) \quad (15)$$

Sujeto a las restricciones:

$$\alpha_n \geq 0, \quad n = 1, \dots, N. \quad (16)$$

$$\sum_{n=1}^N \alpha_n t_n = 0 \quad (17)$$

De esta forma, puede expresarse la ecuación (8) en términos de α_n y para clasificar nuevos datos usando el modelo entrenado, se evalúa el signo de $y(x)$ usando la siguiente ecuación [17]:

$$y(x) = \sum_{n=1}^N \alpha_n t_n \phi(x_n)^T \cdot \phi(x_m) + b \quad (18)$$

Sin embargo estas ecuaciones describen el hiperplano que separa conjuntos de datos linealmente separables, por lo que necesitamos agregar una tolerancia al error para conjuntos de datos en que las clases están traslapadas como ocurre en muchas ocasiones como en el caso de esta investigación. Esta tolerancia la denotaremos como ξ_i de acuerdo al escenario de la figura 5 [23]:

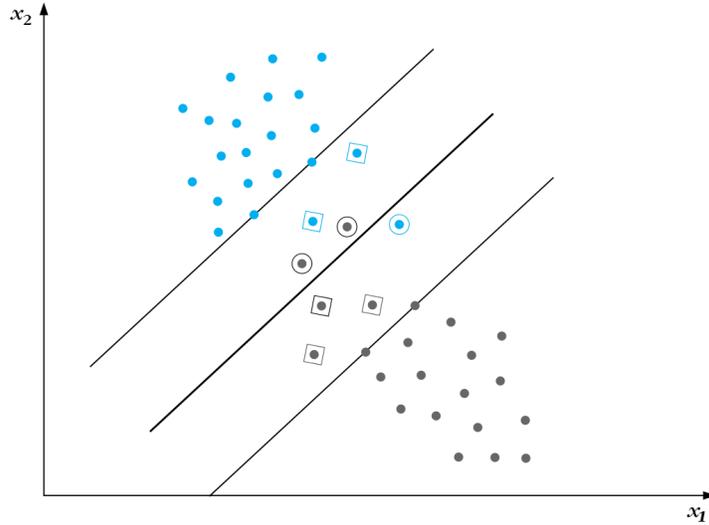


Figura 5: Caso de clases no linealmente separables. Los puntos caen dentro del margen de separación de clases. Obtenido de [24].

En la figura 5 se observa que los vectores del conjunto de entrenamiento pertenecen a una de las tres categorías [24]:

- Los vectores que caen fuera de la frontera de decisión y del margen, y están bien clasificados. Cumplen con la condición de la relación (11).
- Vectores que caen dentro del margen de separación de clases y están bien clasificados, denotados con cuadrados en la figura 5. Estos satisfacen la relación:

$$0 \leq t_n(w^T \phi(x_n) + b) < 1 \quad (19)$$

- Vectores que están mal clasificados. Marcados con un círculo en la figura 5 y cumplen la relación:

$$t_n(w^T \phi(x_n) + b) < 0 \quad (20)$$

Estos tres casos se pueden tratar dentro de un tipo de restricción introduciendo las variables de tolerancia ξ_i mencionadas anteriormente, usando la condición:

$$t_n(w^T \phi(x_n) + b) \geq 1 - \xi_i \quad (21)$$

La primera categoría de los datos corresponden a $\xi_i = 0$, la segunda categoría corresponde a $0 < \xi_i \leq 1$, y la tercera corresponde a $\xi_i > 1$. Las variables ξ_i son variables de tolerancia (*slack variables* en inglés).

De esta forma el problema de optimización de la SVM es similar pero ahora tiene como objetivo hacer el margen lo más grande posible pero al mismo tiempo mantener el número de puntos con $\xi > 0$ tan pequeño como sea posible. Esto es equivalente a minimizar la función de costo [24]:

$$J(w, b, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N I(\xi_i) \quad (22)$$

Donde ξ es un vector con los parámetros ξ_i y

$$I(\xi_i) = \begin{cases} 1 & \xi_i > 0 \\ 0 & \xi_i = 0 \end{cases} \quad (23)$$

El parámetro C es una constante positiva, conocida como *costo*, que controla la influencia relativa de los dos términos a optimizar.

Esta variable costo permite cargar el valor del error hacia un sentido o hacia otro. Así si hay más riesgo en equivocarse en un sentido que en otro, esta variable hace que la decisión se cargue hacia el sentido de menor riesgo.

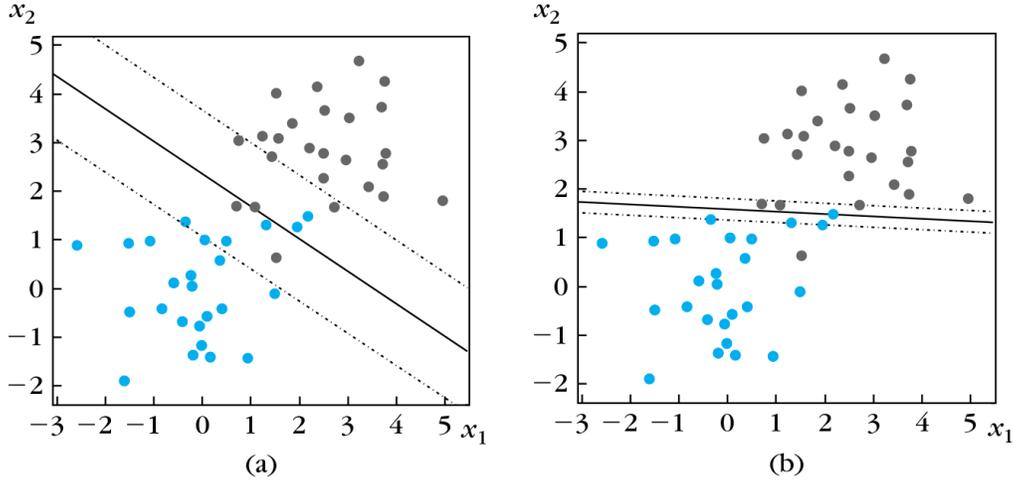


Figura 6: Se muestra un ejemplo de dos clases no separables linealmente y el hiperplano obtenido con la SVM. En (a) se observa la frontera obtenida con $C = 0.2$ y en (b) $C = 1000$. En (b) la localización y dirección del clasificador, así como el ancho de su margen han cambiado con tal de incluir un menor número de puntos dentro del margen. Obtenido de [24].

En la figura 6 se puede observar el efecto que tiene el *costo* en la elección del hiperplano de separación.

Sin embargo, a fin de no utilizar la función discontinua $I(\xi_i)$ de la ecuación (22), se elige optimizar la función de costo relacionada [24]:

Minimizar:

$$J(w, b, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (24)$$

Sujeta a:

$$t_i(w^T \phi(x_n) + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N \quad (25)$$

$$\xi_i \geq 0, \quad i = 1, 2, \dots, N \quad (26)$$

De esta forma, utilizando los multiplicadores de Lagrange, obtenemos la ecuación:

$$L(w, b, \xi, \alpha, \mu) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \mu_i \xi_i - \sum_{i=1}^N \alpha_i [t_i(w^T \phi(x_i) + b) - 1 + \xi_i] \quad (27)$$

Además de poder encontrar clases superpuestas, también es posible que las clases no sean separables de manera óptima con un hiperplano, por lo que se puede utilizar una función para realizar una transformación del espacio de los datos (rasgos) para buscar un espacio en el que los datos sean linealmente separables o se obtenga el hiperplano óptimo para la separación de las clases. Esta transformación se lleva a cabo con la función kernel (o núcleo).

Esta función kernel, expresada como $K(x)$, es además resultado de un producto interno $K(x, y) = \phi(x)^T \phi(y)$, algunos ejemplos de este tipo de funciones son:

$$k(x, y) = (x \cdot y + b)^p \quad (28)$$

$$k(x, y) = \tanh(kx \cdot y - \delta) \quad (29)$$

$$k(x, y) = e^{-\frac{\|x-y\|^2}{2\gamma^2}} \quad (30)$$

El kernel (28) se conoce como kernel polinomial, el kernel (29) es un kernel de sigmoide logística, y finalmente el kernel (30) fue el elegido para este proyecto y es conocido como kernel de función de base radial (RBF por sus siglas en inglés).

Una ventaja más del uso de kernels es que la dificultad de procesamiento no aumenta debido a que la transformación del espacio está incluida ya en el producto interno, por lo que las ecuaciones para encontrar el hiperplano de la SVM sólo cambian en el uso de dicha función. En la figura 7 se muestra la frontera de decisión obtenida al utilizar una función kernel para la SVM.

Otro tema importante sobre estas funciones es que no existe una forma analítica de elegir el kernel óptimo para la aplicación deseada, por lo que suele probarse el desempeño obtenido tras usar distintas funciones y se elige aquella que mejores resultados permita obtener.

4.4.2. Entrenamiento de la máquina de soporte vectorial

Como mencionamos en párrafos anteriores, el entrenamiento de una máquina de soporte vectorial consiste en encontrar el hiperplano con margen máximo que permita dividir a las distintas clases con el menor error posible.

En el caso de este proyecto, en los canales analizados (canales 1 y 2), se contó con \mathbf{n} épocas de señales con P300 y \mathbf{p} sin P300 ($\mathbf{n} = 480$ y $\mathbf{p} = 2400$ para el sujeto de ejemplo, GCE), así que para el primer paso de entrenamiento de la SVM, se seleccionaron al azar \mathbf{n} épocas de la clase sin P300 para tener

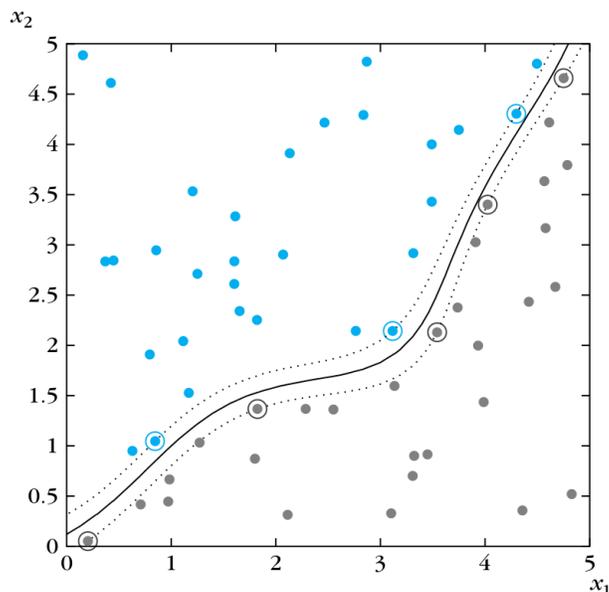


Figura 7: Ejemplo de un clasificador con SVM no lineal para el caso de dos clases no separables linealmente. El kernel utilizado fue una función de base radial (RBF). Las líneas punteadas marcan el margen y los puntos encerrados en círculo son los vectores de soporte. Obtenido de [24].

la misma cantidad de datos de cada clase y con ello un conjunto de datos balanceado.

Cabe mencionar que este conjunto de datos seleccionados aleatoriamente de la clase no P300 se utilizó desde el inicio hasta el final de las pruebas.

Como también se mencionó en párrafos anteriores, al utilizar una función Kernel también es necesario buscar los valores óptimos para los hiperparámetros de dicha función además del costo, por lo que antes de entrenar y evaluar el clasificador final es necesario hacer pruebas para encontrar los valores de estos hiperparámetros.

Como la función kernel elegida fue la función de base radial (ecuación (30)), los hiperparámetros que hay que encontrar son *gamma* (γ) para el kernel y *costo*(C) para el margen de la SVM.

El procedimiento para encontrar estos valores es hacer un barrido de valores para estos dos hiperparámetros, observar el desempeño de la clasificación y elegir los valores que permitan la mejor clasificación. Para realizar los cálculos de optimización de la SVM se utilizó la biblioteca *libsvm* para

GNU Octave [25], la cual puede descargarse de [26].

En esta biblioteca los autores sugieren un barrido inicial de valores para estas variables en los rangos $2^{-5} \leq C \leq 2^{15}$ y de $2^{-15} \leq \gamma \leq 2^3$ [27] y una vez que se obtiene un primer par de valores máximos, se hace un barrido más fino alrededor de esos valores para obtener un par de valores que permitan obtener un mejor desempeño. La métrica elegida para el desempeño fue el área bajo la curva ROC.

4.5. Evaluación del desempeño del clasificador

Una vez equilibradas las clases y seleccionados los hiperparámetros de la SVM, se eligió el 80 % de los datos como conjunto de entrenamiento del clasificador y un 20 % como conjunto de prueba no usados durante la etapa de entrenamiento.

Se realizó también una validación cruzada de 5 vías para observar el comportamiento promedio del desempeño del clasificador y poder obtener también un margen de confianza para dicho desempeño, a fin de tener una mejor idea de cómo se comportará ante distintas distribuciones de los datos, es decir probar el error de generalización del clasificador diseñado.

Así pues se tomó aleatoriamente un 20 % de los datos de cada clase para el conjunto de prueba y el 80 % restante se utilizó para realizar el entrenamiento de la SVM, tras lo cual se observó y registró el desempeño. Este procedimiento se realizó 5 veces con un remuestreo aleatorio con repetición de los datos para prueba en cada iteración y con ello se obtuvieron métricas de desempeño promedio con su respectiva desviación estándar (figura 8).

Además se realizó esta validación cruzada con los datos sin promediar las épocas (single trial) y también en el caso de promediaciones de 2 épocas. Las métricas de desempeño utilizadas fueron la precisión (%acc) y el área bajo la curva ROC (también conocida como AUROC por sus siglas en inglés).

Para calcular estas métricas de desempeño se hizo uso de la matriz de confusión, la cual es una tabla donde se contrasta la diferencia entre las predicciones hechas por el clasificador y los valores reales de los datos, en el caso de tener dos clases, arbitrariamente denominada una como positiva y otra como negativa, como se muestra en la figura 9.

Las medidas asentadas en la matriz de confusión son:

- TP: Verdaderos positivos, este es el conjunto de datos que fueron predichos como pertenecientes a la clase positiva y que realmente pertenecen

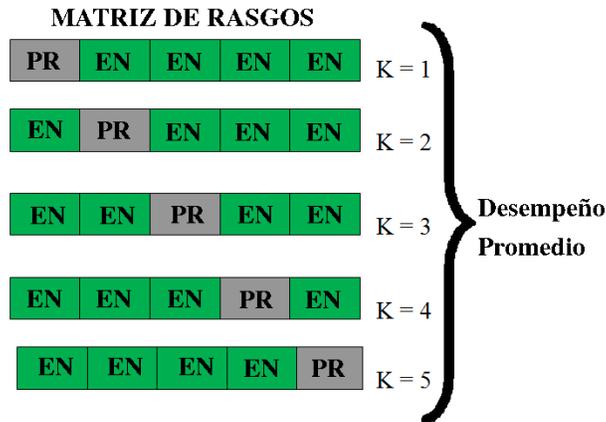


Figura 8: Estructura de la validación cruzada de 5 vías. **PR** es el 20% de datos elegidos para prueba y **EN** es el restante 80% utilizado para el entrenamiento. En cada K se obtiene un valor de desempeño del clasificador y una vez completadas las 5 iteraciones se calcula con ellos el desempeño promedio y su respectiva desviación estándar.

		<i>Predicción</i>	
		<i>Positivo</i>	<i>Negativo</i>
<i>Realidad</i>	<i>Negativo Positivo</i>	TP	FN
	<i>Negativo Negativo</i>	FP	TN

Figura 9: Matriz de confusión. Se resalta la diagonal con los valores verdaderos de la matriz, verdaderos positivos y verdaderos negativos.

a ella.

- **TN:** Verdaderos negativos, es el conjunto de datos que fueron predichos como pertenecientes a la clase negativa y que realmente lo son.

- FN: Falsos negativos, es el conjunto de datos que fueron predichos como parte de la clase negativa pero realmente son de la clase positiva.
- FP: Falsos positivos, es el conjunto de datos predichos como positivos que en realidad pertenecen a la clase negativa.

Tanto los TP como los TN son aciertos en la clasificación, mientras los FP y FN son errores en la clasificación y con base en esta información de la matriz de confusión se pueden inferir las métricas utilizadas en este proyecto, para lo cual es necesario introducir algunos conceptos más.

Sensibilidad o razón de verdaderos positivos (TPR): es una métrica en la cual se muestra qué proporción de verdaderos positivos se identificaron en relación a cuántos datos positivos existían realmente, es decir nos dice cuántos positivos fueron bien clasificados como tal y se calcula mediante la ecuación:

$$TPR = \frac{TP}{TP + FN} \quad (31)$$

Razón de falsos positivos (FPR o razón de falsas alarmas [28]): en esta se establece la proporción de falsos positivos respecto a todos los datos que en realidad eran negativos. Se obtiene con la siguiente ecuación:

$$FPR = \frac{FP}{FP + TN} \quad (32)$$

Especificidad: es similar a la sensibilidad pero para la clase negativa, es decir la relación de verdaderos negativos respecto a la cantidad de datos que realmente pertenecen a la clase negativa. Se calcula con la ecuación:

$$Especificidad = \frac{TN}{TN + FP} = 1 - FPR \quad (33)$$

Certeza (accuracy o %acc): esta métrica nos indica el porcentaje de datos bien clasificados respecto al total de datos. Sin embargo esta medida de desempeño puede resultar engañosa en varios casos puesto que al ser relativa a la cantidad de los datos, es necesario conocer el tamaño de las clases, cosa que no siempre se reporta en la literatura junto con esta métrica, además para darle mayor robustez suele realizarse también un procedimiento de validación cruzada a fin de poder conocer el valor promedio del desempeño así como su respectivo intervalo de confianza. Se calcula con la ecuación:

$$\%Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (34)$$

Área bajo la curva ROC: la curva ROC es una gráfica bidimensional en donde la métrica TPR es usada como el eje y y la métrica FPR es utilizada como el eje x . Hacer este contraste permite ilustrar el balance entre los aciertos (verdaderos positivos) y los errores (falsos positivos). Al ser los ejes relaciones que se encuentran en un rango de 0 a 1, el espacio de la gráfica de la curva ROC es un cuadrado unitario, como se observa en la figura10.

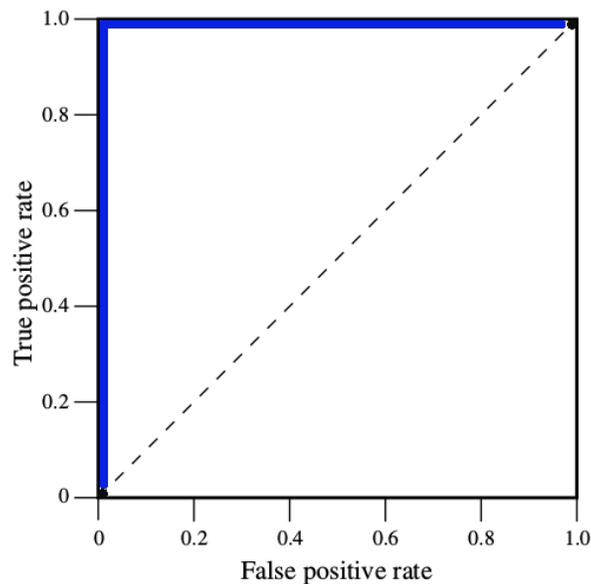


Figura 10: Espacio de la curva ROC, relación de verdaderos positivos (TPR) contra relación de falsos positivos (FPR).

En la figura se muestra el espacio en el cual se grafica una curva ROC y tiene varios puntos importantes a resaltar. El origen o el punto $(0,0)$ es el punto en el que nunca se obtiene una clasificación positiva, el punto $(1,1)$ representa clasificar todos los puntos como positivos indiscriminadamente.

El punto $(0,1)$ representa la clasificación perfecta, mientras que la diagonal $y = x$ ó $TPR = FPR$ representa el peor escenario de clasificación, que es una clasificación donde la decisión es tomada aleatoriamente, es decir, con 50% de probabilidad de elegir una clase o la otra.

Cabe mencionar que una vez obtenida una matriz de confusión, se obtiene un sólo valor para FPR y para TPR y por ende un sólo punto en el espacio ROC, por lo cual para trazar la curva ROC el procedimiento es que a partir de los valores de probabilidad de pertenencia a una clase obtenidos por el

clasificador, se hace un barrido de los valores de probabilidad usando un umbral variable para que un dato sea considerado perteneciente a una clase, de tal forma que en el extremo $(0,0)$ estamos usando un umbral tan alto de probabilidad que ninguno de los datos cae dentro de la clase: por tanto se obtiene un $\text{TPR}=0$ y un $\text{FPR}=0$. Este umbral se va disminuyendo hasta el punto en que el umbral es tan pequeño que todos los puntos se consideran dentro de la clase y por ende obtenemos un $\text{TPR}=1$ y un $\text{FPR}=1$, por lo tanto llegamos al punto $(1,1)$ de la gráfica. La curva obtenida al hacer este barrido es lo que se denomina curva ROC. La línea azul en la figura 10 representa la curva ROC ideal, pues es la que pasa por el punto $(0,1)$ donde se tiene la clasificación perfecta.

Finalmente, para condensar toda la información de la curva ROC en un escalar, se suele medir el área bajo la curva ROC (AUROC). Dado que el espacio de la curva ROC es el cuadrado unitario, los valores del AUROC están en el rango de 0.5 a 1 y como sabemos que la diagonal de $(0,0)$ a $(1,1)$ es el peor escenario de clasificación, el peor valor de AUROC es 0.5 (valores más bajos de 0.5 se pueden interpretar como mejores que una decisión aleatoria, pero donde la regla de decisión se encuentra invertida).

Una propiedad estadística importante del área bajo la curva ROC de un clasificador es que es un escalar equivalente a la probabilidad de que el clasificador otorgue un rango más alto a un patrón de la clase positiva elegido aleatoriamente que a un patrón de la clase negativa elegido aleatoriamente, lo cual es equivalente a la prueba de rangos de Wilcoxon [28].

5. Resultados

Después de la promediación coherente, la mayoría de los canales en que se observaron morfologías similares fue en canales cercanos, como en el caso de los canales Fz, Cz y C4, o en Pz y P4, como se muestra en la figura 11.

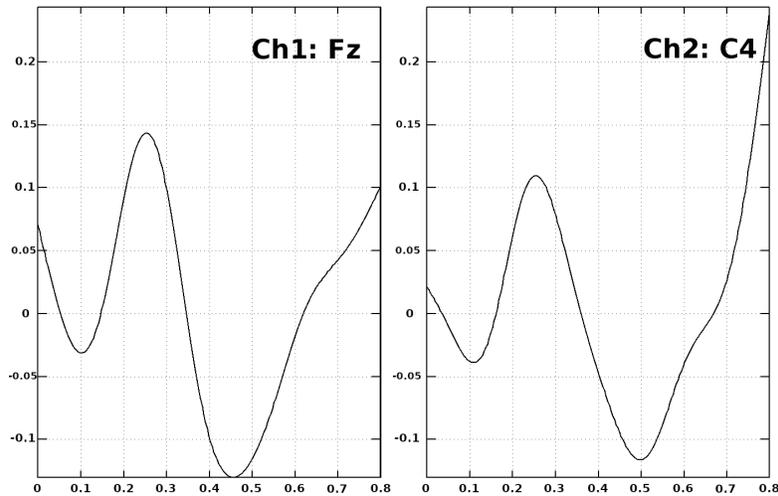


Figura 11: Promediación coherente de las 480 épocas con P300 en los canales Fz y C4 del sujeto GCE.

El par de canales seleccionados para ser analizados con la correlación canónica fueron los canales Fz y C4 (canales 1 y 2) debido a que tenían una morfología de P300 muy similar. Este par de canales se mantuvo constante para todos los sujetos con el fin de observar el comportamiento que tendría una BCI que contara únicamente con dos electrodos.

Una vez que el análisis de correlación canónica nos ha arrojado las bases vectoriales para describir las señales con P300 y las señales sin P300, se realizó la proyección de las épocas con y sin P300 sobre la base vectorial correspondiente a su canal. Es decir, las épocas con y sin P300 del canal 1 se proyectaron sobre la base W_x para observar una diferencia entre las proyecciones de cada clase a fin de analizar si eran de utilidad para poder identificar una clase de la otra, al menos de manera visual en un primer acercamiento, previo a los algoritmos de aprendizaje maquina. Se procedió de manera análoga con las épocas y base del canal 2. Las proyecciones pueden observarse en la figura 12.

La proyección de cada época sobre cada componente de la base generó como resultado, por canal, matrices de proyecciones de \mathbf{n} épocas por \mathbf{q} componentes ($n= 480$, $q = 206$ para el sujeto de ejemplo, GCE) en el caso de las que contenían P300 y de igual tamaño para las que no lo contenían. Además las proyecciones fueron de baja amplitud, por lo cual la comparación visual no fue viable, así que se utilizó la prueba estadística de Kruskal-Wallis para ayudar a encontrar diferencias significativas entre las proyecciones.

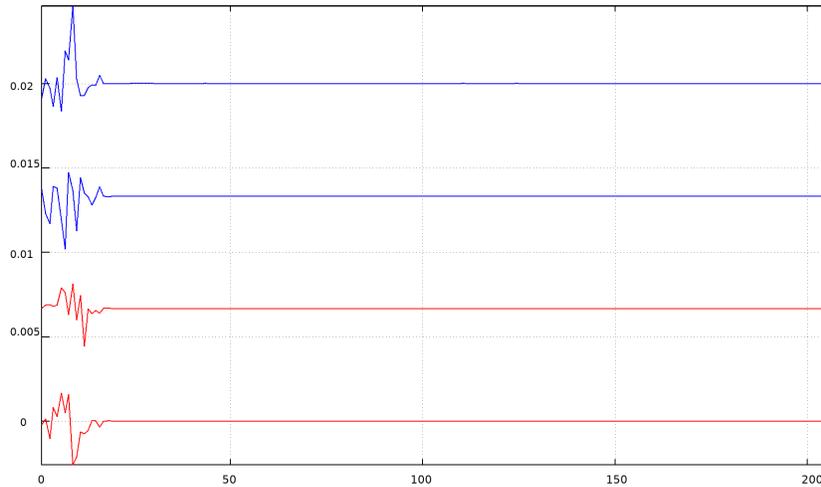


Figura 12: Ejemplo de proyecciones en la base P300 (W_x). En azul dos señales con P300, en rojo dos señales sin P300.

De esta forma, en el análisis con Kruskal-Wallis, el número de grupos a comparar es $k = 2$, y por ello se tuvo un grado de libertad y se utilizó un nivel de significancia de 0.005 para elegir el valor de χ^2 contra el cual comparar el estadístico H de la prueba, este valor fue $\chi^2 = 7.879$, como puede observarse en la figura 13.

Con este análisis de las componentes se pudo reducir la dimensionalidad de las bases W_x y W_y , como en el caso del sujeto GCE de 206 a 157 componentes, sin embargo se observó que había varias componentes cuyo estadístico rebasaba por mucho el umbral de diferencia significativa, por lo cual se eligieron las 5 componentes con el mayor nivel de significancia, disminuyendo dramáticamente la dimensionalidad de las proyecciones.

Al tener este reducido número de componentes, se hizo una observación de las proyecciones en cada clase, tanto en épocas con y sin P300 a fin de

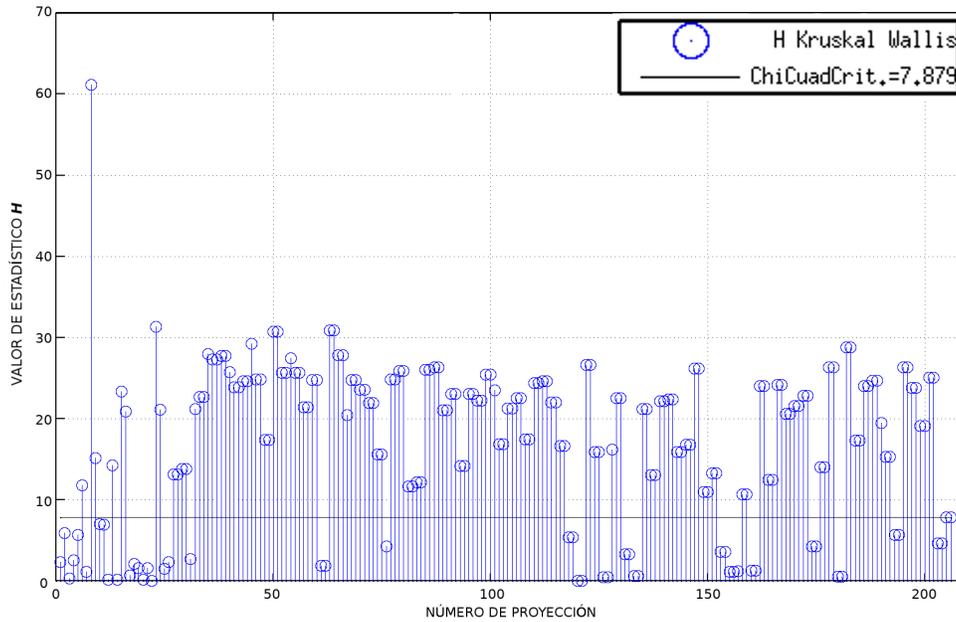


Figura 13: Resultados de la prueba Kruskal-Wallis para el canal 1 del sujeto GCE. La línea negra horizontal señala el umbral de diferencia significativa de $\chi^2 = 7.879$.

evaluar su potencial para hacer una separación útil entre una clase de épocas P300 y una sin P300. En la figura 14 se muestra una gráfica de cajas junto con el promedio coherente de estas proyecciones a fin de describir mejor la distribución de los datos obtenidos al proyectar señales con P300 en la base P300 y proyectar una señal no P300 en su respectiva base no P300.

Como puede observarse en la figura 14, las proyecciones de las épocas P300 tienden a ser similares al trazo en azul, mientras que las no P300 tienden a semejarse al trazo en rojo.

A pesar de la dispersión que causa un traslape en los datos de cada clase, se observaron tendencias en los datos que pueden ser utilizadas como rasgos para poder clasificar señales P300 de no P300.

Una vez seleccionadas las componentes útiles de las bases para P300 y sin P300, se realizó el barrido de valores de costo y gamma para encontrar en qué combinación de ellos se da el mejor desempeño de la SVM.

Este procedimiento genera una superficie de hiper parámetros contra desempeño en la cual se puede observar qué pareja (C, γ) genera mejores

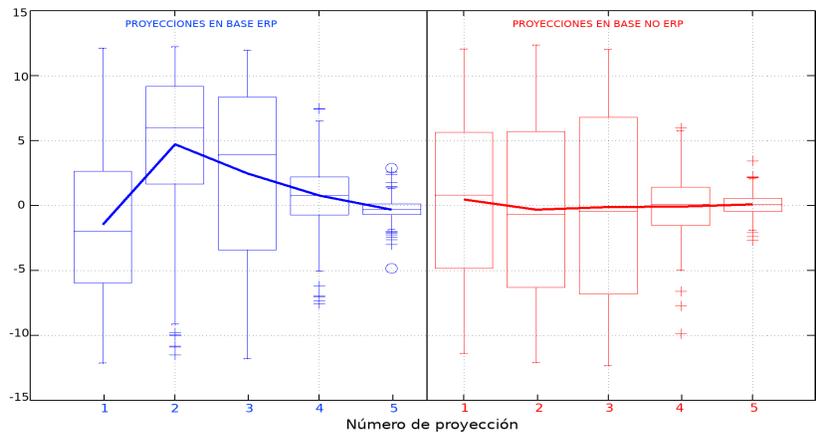


Figura 14: Se muestra el promedio de las 5 proyecciones de épocas con P300 y no P300 en sus respectivas bases.

resultados, como se ve en la figura 15. El par de valores elegidos para cada sujeto se muestra en las tablas del anexo de resultados.

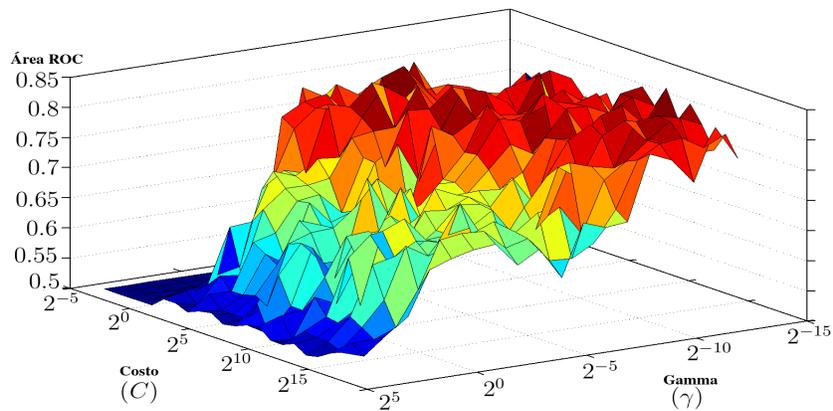


Figura 15: Superficie de valores de desempeño del clasificador para distintos valores de los parámetros costo y gamma para el sujeto GCE.

Como se mencionó en el apartado de evaluación del desempeño de la clasificación, una vez diseñado el clasificador, se realizó una validación cruzada de 5 vías para observar el comportamiento promedio del área bajo la curva ROC (AUROC) y la certeza. Ambas métricas se calcularon para todos los sujetos una vez que se les hubo aplicado toda la metodología anteriormente

descrita.

En la figura 16 se muestra en un gráfico de cajas, la distribución de los resultados promedio del desempeño al analizar con una sola época y al promediar 2, 3, 4 y 5 épocas. Los resultados individuales por sujeto se muestran en las tablas y figuras del anexo de resultados.

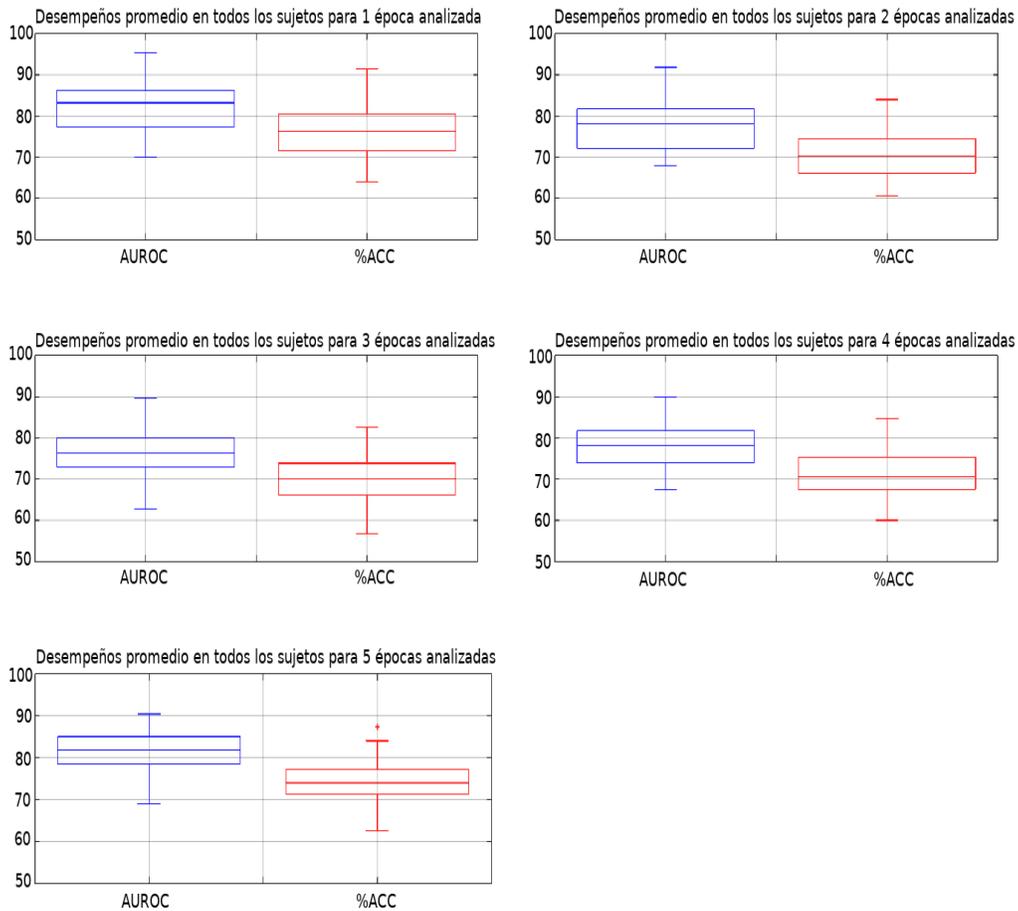


Figura 16: Distribución de los desempeños obtenidos para el análisis de 1 a 5 épocas analizadas

Se comparó el desempeño al utilizar una sola época contra los promedios coherentes de 2, 3, 4 y 5 épocas sucesivamente, antes de aplicarles CCA a fin de ver la tendencia de cada sujeto al ir añadiendo cada nueva época de manera sucesiva, así como el desempeño promedio de los 5 diferentes momentos.

El desempeño promedio para todos los sujetos alcanzó valores mayores al 70 % para ambas métricas en los escenarios promediados que se muestran en la tabla 1.

Resultados de desempeño promedio para todos los sujetos		
Épocas utilizadas	AUROC	Certeza
1	82.35 % \pm 6.16 %	76.47 % \pm 6.64 %
2	77.35 % \pm 6.0 %	70.6 % \pm 5.69 %
3	76.52 % \pm 6.09 %	70.2 % \pm 6.17 %
4	78.06 % \pm 5.67 %	71.24 % \pm 5.54 %
5	81.61 % \pm 5.46 %	74.56 % \pm 5.59 %

Tabla 1: Comparativa de área bajo la curva ROC con distintos abordajes para la aplicación de CCA.

A nivel de resultados individuales por épocas promediadas, se obtuvieron 6 AUROC mayores al 90 %, siendo 95.378 % \pm 4.5 el máximo desempeño obtenido, correspondiente al sujeto JCR y utilizando únicamente una época para su preprocesamiento con CCA y posterior diseño de clasificador. Los resultados completos para este sujeto se muestran en el anexo de resultados.

Para el resto de las clasificaciones, 65 fueron obtenidas con una AUROC entre 80 y 90 %; 66 clasificaciones se encontraron entre el 70 y 79.9 % y únicamente 13 se encontraron debajo del 70 % de AUROC teniendo como mínimo desempeño un 62.8 % \pm 4.78 de AUROC para el sujeto MoMR tras promediar tres épocas previo a su análisis con CCA y diseño de clasificador.

En los resultados individuales de certeza por épocas promediadas, el único resultado mayor al 90 %, fue un 91.33 % \pm 7.3 correspondiente al sujeto JCR con época única, como sucedió en el caso del área ROC.

Para el resto de las clasificaciones se obtuvieron 20 con certezas entre el 80 y 90 %, 82 tuvieron certezas entre el 79.9 y el 70 % y 47 tuvieron desempeños menores al 70 % siendo el mínimo un 56.66 % \pm 5.27, también para el sujeto MoMR al hacer el promedio coherente de tres épocas.

5.1. Discusión de resultados

Como sabemos, el desempeño obtenido por el clasificador depende de una buena extracción de características, en el caso de este proyecto, la máquina de soporte vectorial con una función de base radial como núcleo logró llegar a un máximo desempeño de área ROC de 95.38 % \pm 4.5 % para el sujeto JCR,

como se mencionó en la sección de resultados, pero aún teniendo el máximo desempeño de todos los registros analizados, su desempeño promedio se vio afectado por un bajo desempeño al momento de agregar una cuarta época al promedio coherente en la etapa de preprocesamiento. Posiblemente, ese bajo desempeño pudo deberse a una distracción o cansancio de parte del sujeto al momento de hacer la tarea de deletreo, ya que en general sus resultados de área ROC se encuentran arriba del 80 % para las otras cuatro épocas promediadas que se analizaron.

Este desempeño máximo de área ROC del sujeto JCR tras una sola época puede contrastarse con el trabajo expuesto en [29], donde se analizaron 10 sujetos en un experimento de deletreo P300 con época única, utilizando como extractor de características y como clasificador un par de ensambles ponderados de redes neuronales convolucionales, obteniendo un desempeño promedio de $92.64\% \pm 5.73$ para los 10 sujetos, utilizando una sola época. El mejor resultado que obtuvieron fue de 99.07% para su sujeto 5, igualmente con época única. Se puede observar que si bien su desempeño individual es mayor al del presente trabajo, cabe mencionar que el enfoque utilizado en [29] requiere del uso de información de una configuración de 16 electrodos para la extracción de características, mientras que en el presente trabajo los resultados se obtuvieron analizando únicamente dos electrodos. Además, dada la dispersión que poseen, pueden encontrarse en un rango cercano ambos resultados de época única. Esta brecha podría acortarse mejorando el proceso de selección de canales en el presente trabajo ya que, como se mencionó en la metodología, esta selección se llevó a cabo de manera empírica mediante la observación de la morfología de los promedios de cada canal.

En cuanto al menor desempeño de área ROC del presente trabajo, corresponde al sujeto MoMR, y al igual que con el sujeto JCR su desempeño se encuentra arriba del 80 % a excepción del momento en que se analizó promediando 3 épocas. Es posible que también fuera afectado por distracción o cansancio al llevar a cabo la tarea.

Respecto al comportamiento de peor caso (sujeto MoMR), en [30], se analiza a 21 sujetos de esta misma base de datos, pero utilizando una técnica de comparación entre los potenciales y un templete del P300 del sujeto, obtenido luego de una promediación coherente de n épocas, donde n es el mínimo de épocas necesarias para obtener un buen templete. En el caso del sujeto JCR obtuvieron un desempeño de $59\% \pm 10$ también utilizando una SVM y fue necesario utilizar 15 épocas para obtener su promedio coherente y su templete. Los autores mencionan también que ese bajo desempeño puede

deberse a fatiga, distracción, falta de motivación o hambre.

El cansancio y la distracción se mencionan también en [29, 31, 30, 32, 33, 34, 35] como una posible causa de errores y bajas de desempeño en las interfaces cerebro computadora, aunque no reportan un tiempo promedio adecuado para evitar dichas distracciones o cansancio, así como tampoco se sugiere alguna duración que reduzca esas condiciones desfavorables. Los autores de los trabajos consultados se centran en una modificación del estímulo, las probabilidades de aparición de un estímulo objetivo y el tiempo inter estímulo como se reporta en [36, 37]. En [36] se reporta que los tiempos inter estímulo reducidos pueden dar lugar a una superposición de épocas P300 y NOP300 más que a distracción o cansancio. El caso más cercano a una propuesta de tiempos para la realización del registro se encuentra en [38], donde se reporta una relación entre la amplitud y latencia de la onda P300 y los ciclos ultradianos del sujeto, por lo que menciona posibles variaciones significativas del EEG en periodos de aproximadamente 90 minutos en los que se puede ver un aumento en la amplitud y disminución de la latencia de la onda P300 (o el caso contrario, una disminución de la amplitud y un aumento en la latencia) dependiendo del sujeto.

Otra posible causa de bajos desempeños es mencionada en el trabajo de Bojorges [31]: el etiquetado de las épocas. El etiquetado de las épocas es lo que permite entrenar de manera correcta al clasificador, sin embargo, la forma de etiquetar simplemente consiste en asumir que en el periodo de tiempo en que se presenta un estímulo debe de haber un potencial P300, cosa que desafortunadamente no siempre sucede. El asumir que todas las señales que se presentan durante la aparición de un estímulo son señales P300, puede acarrear el error que consiste en que al momento de hacer los promedios coherentes, si alguna de las señales promediadas no contenía P300, la base obtenida no estará representando tan fielmente el comportamiento del potencial provocado que nos interesa.

Una vez que se compararon los resultados de mejor y peor caso con trabajos de época única o mínimo número de épocas, ahora se comparan los resultados con otros que tienen el enfoque de sub espacios, como PCA, ICA y finalmente con el propio CCA.

Se encontró que en el trabajo de Selim et al. [39] se realizó un estudio de delecteo P300 para dos sujetos en el que se utilizó PCA para ordenar por importancia los electrodos con mejores características de la onda P300 extraídas previamente mediante ICA y se reporta un desempeño máximo de certeza de 70 % y mínimo de 54 % al utilizar 5 épocas de estimulación. En

el trabajo de Elsayy et al. [40] se realizó un deletreador para un dispositivo móvil de android y probado en seis sujetos; se utilizó PCA para extraer los rasgos de la onda P300 para cada uno de los 14 canales utilizados, se reporta una certeza máxima promedio de $93.75\% \pm 8.1\%$ para un sujeto y de $78.37\% \pm 16.09\%$ en promedio para todos los sujetos.

En [41], Chiou et al. analizaron el conjunto de datos de la competencia BCI III de deletreador P300 y otro conjunto de datos de deletreo P300 de 10 sujetos, en ambos casos utilizando PCA para la extracción de características, se reporta un desempeño de $94.4\% \pm 0.55\%$ para este método y utilizando una máquina de soporte vectorial como clasificador y 10 épocas. En este mismo trabajo se realizó otro análisis de los registros pero utilizando ICA, obteniendo un desempeño de $93.1\% \pm 2.11$ para el mismo número de canales, épocas y mismo clasificador.

En el trabajo de Nashed et al. [42] se realizó un estudio de deletreo P300 a dos sujetos sanos utilizando 4 electrodos y utilizando PCA como extractor de características y LDA como clasificador, se reporta una certeza máxima promedio de $82.92\% \pm 12.3\%$ al utilizar 5 épocas y una certeza máxima promedio de $46.63\% \pm 16.63\%$ al utilizar 1 época.

Lee et al. [43] utilizaron ICA en una variante llamada ICA-R, en la cual se da al algoritmo una señal de referencia con algunas características del P300 para poder extraerla de los registros de EEG con ruido de la actividad cerebral de fondo y así facilitar y agilizar la clasificación. Su análisis se realizó utilizando 5 épocas de estímulo, 64 canales y una máquina de soporte vectorial como clasificador, obteniendo 84% de certeza como desempeño promedio.

Kanoga et al. [44] compararon tres métodos de eliminación de artefactos en el EEG, entre ellos ICA, y se utilizaron para imaginación de movimiento, P300 y SSVEP. En el caso del P300 se utilizaron 12 épocas de estimulación, 32 canales y LDA como clasificador para obtener un desempeño promedio de 96% y aunque no reportan su desviación estándar, sí reportan los resultados para cada uno de sus sujetos, con lo que se puede calcular que la desviación estándar para su conjunto de datos es del 8% .

En [45], se analizaron registros de un deletreador P300 utilizando CCA y se reportan certezas promedio de hasta 82.04% utilizando promedios de 7 épocas y 16 electrodos, mientras que en el caso de promedios de 5 épocas reportan una certeza promedio de 80.77% , mientras que para época única reportan 49.63% .

Chailloux et al. [46] realizaron un estudio para mejorar el reconocimiento

de la onda P300 utilizando una sola época y por medio de CCA. Utilizaron 5 símbolos objetivo en una pantalla, haciéndolos parpadear aleatoriamente y pidiendo al sujeto concentrarse en el símbolo que se le indicara, proceso similar al seguido con el deletreador P300. Los autores reportan un desempeño de certeza promedio de $75.9\% \pm 6.9\%$ utilizando información de 8 canales y una máquina de soporte vectorial como clasificador.

En [47] se buscó mejorar la tasa de transferencia de información de una BCI basada en P300 utilizando un número limitado de épocas, extrayendo características de los registros mediante CCA y utilizando un método de clasificación basado en la regresión logística regularizada (RLR). Los autores reportan un desempeño máximo promedio de 86.3% al utilizar 4 épocas de estimulación y la información de 8 canales.

Estas comparaciones entre técnicas de preprocesamiento por subespacios, número de épocas y número de canales se resume en las tablas 2, 3 y 4.

Las tablas 2, 3 están acomodadas con respecto al método de subespacio utilizado por los autores y en varios casos se presentan los resultados para diferente cantidad de épocas utilizadas para el procesamiento.

La tabla 4 permite comparar de manera un poco más sencilla la cantidad de épocas analizadas así como la cantidad de canales usados para obtener los desempeños reportados por cada autor.

Comparación de métodos por subespacios					
Método	Certeza promedio	Épocas utilizadas	#Canales	Clasificador	Referencia
PCA	78.37 %±16.09 %	10	14	Least Squares	Elsawy [40]
PCA	82.92 %±12.3 %	5	4	LDA	Nashed [42]
	46.63 %±16.63 %	1			
PCA	94.4 %±0.55 %	8	15	SVM	Chiou [41]
ICA	93.1 %±2.11 %				
ICA	84 %	5	64	SVM	Lee [43]
ICA	96 %±8 % *	12	32	LDA	Kanoga [44]
ICA-PCA	62 %±11.31 % *	5	32	SVM	Selim [39]
CCA	75.9 %±6.9 %	1	8	LDA	Chailloux [46]
CCA	86.3 %	4	8	RLR	Díaz [47]
	83.5 %	1			
CCA	80.77 %	5	16	SWLDA	Spüler [45]
	78.81 %	4			
	49.63 %	1			
CCA	74.56 %±5.6 %	5	2	SVM	Este trabajo
	71.24 %±5.54 %	4			
	76.47 %±6.64 %	1			

Tabla 2: La certeza promedio se refiere al promedio para todos los sujetos de su respectivo estudio (* la desviación estándar se calculó utilizando los datos reportados por los autores). En negrita se resalta el desempeño más alto.

Comparación de métodos por subespacios					
Método	AUROC	Épocas utilizadas	#Canales	Clasificador	Referencia
CCA	65.7 %	1	8	RLR	Díaz [47]
	72.8 %	2			
	74.5 %	3			
	75.3 %	4			
CCA	82.35 %±6.16 %	1	2	SVM	Este trabajo
	77.35 %±6.0 %	2			
	76.52 %±6.09 %	3			
	78.06 %±5.67 %	4			
	81.61 %±5.46 %	5			

Tabla 3: Comparativa de área bajo la curva ROC con distintos abordajes para la aplicación de CCA. En negrita se resaltan los desempeños más altos.

Comparación de métodos por número de épocas utilizadas				
Épocas	#Canales	Certeza promedio	Método-Clasificador	Referencia
1	8	83.5 %	RLR	Díaz [47]
	2	76.46 %±6.64 %	CCA-SVM	Este trabajo
	8	75.9 %±6.9 %	LDA	Chailloux [46]
	16	49.63 %	CCA-LDA	Spuller [45]
	4	46.63 %±16.63 %	LDA	Nashed [42]
4	8	86.3 %	RLR	Díaz [47]
	16	78.81 %	CCA-LDA	Spüler [45]
	2	71.24 %±5.54 %	CCA-SVM	Este trabajo
5	64	84 %	ICA-SVM	Lee [43]
	4	82.92 %±12.3 %	PCA-LDA	Nashed [42]
	16	80.77 %	CCA-LDA	Spuller [45]
	2	74.56 %±5.6 %	CCA-SVM	Este trabajo
	4	62 %±11.31 %	ICA-PCA-SVM	Selim [39]

Tabla 4: Tabla comparativa de certeza promedio por número de épocas utilizadas. En negrita se resalta el mayor desempeño para el número de épocas utilizadas.

6. Conclusiones

Como resultado de esta investigación se generó un sistema de detección de potenciales P300 mediante el uso de épocas mínimas y un número muy reducido de canales obteniendo un desempeño suficiente para ser considerado útil para una BCI.

La hipótesis de este trabajo fue usar el análisis de correlación canónica para permitir una clasificación de registros con P300 con una tasa de clasificación superior al 70 % utilizando un número reducido de épocas, hipótesis que se cumplió con la metodología desarrollada.

Así mismo, se alcanzaron con los objetivos de aplicar el análisis de correlación canónica a registros de EEG multicanal y utilizarlo como método de obtención de subespacios. Estos subespacios obtenidos fueron las bases vectoriales arrojadas por el CCA, con las cuales se pudo realizar una proyección de las señales de EEG a fin de poder clasificarlas como P300 o no P300.

Para realizar esta clasificación se diseñó un procedimiento de clasificación con máquinas de soporte vectorial, entrenado con las características extraídas mediante la proyección en las bases vectoriales obtenidas. Una vez diseñado y entrenado, se llevó a cabo su respectiva validación estadística calculando sus desempeños de certeza y área bajo la curva ROC.

Como se aprecia en la sección de resultados y en el anexo de resultados, se logró alcanzar tasas de desempeño promedio mayores al 75 % de AUROC y mayores al 70 % de certeza para el promedio de todos los sujetos al usar 1, 2, 3, 4 y 5 épocas. Y por encima del 80 % y 70 % para ambas métricas en la mayoría de los casos en los resultados individuales, aún utilizando pocas épocas (5 épocas como máximo) para obtener la base vectorial mediante el análisis de correlación canónica.

Además de tener los desempeños aceptables esperados, otra ventaja de las bases vectoriales obtenidas con CCA fue la reducción de dimensionalidad por ejemplo de 480 en el espacio original a sólo 5 componentes, las cuales podrían llegar a reducirse al buscar un mínimo óptimo. Esta reducción de dimensiones puede ayudar de gran manera a reducir tiempos de procesamiento, dado que la carga computacional requerida para analizar por ejemplo 480 épocas se reduce de manera importante, con lo cual se puede ganar tiempo valioso para evitar cansancio o mayores tiempos de distracción del sujeto entre cada época y cada caracter, permitiéndole una comunicación más fluida.

La disminución de épocas y canales obtenida da pie a reducir el tiempo de preparación del sistema para su uso, generando a su vez la posibilidad

de desarrollar un sistema más cómodo y accesible para los pacientes y usuarios que puedan verse beneficiados con un desarrollo tecnológico como son los delectreadores P300 o alguna otra BCI con base en este paradigma de estimulación.

Al mismo tiempo, la disminución de canales genera una disminución en el número de electrodos necesarios para el sistema y una disminución del poder de cómputo requerido para el correcto funcionamiento de una interfaz cerebro-computadora y por ende, disminuyendo los costos finales para la puesta en marcha de dicha interfaz, pues podría hablarse de sistemas que dependan de cuatro, tres o dos electrodos con un desempeño adecuado al mejorar la selección de canales más adecuados para cada sujeto. Esta reducción de canales también da pie a cambiar el uso de una gorra completa o casco de electrodos por una diadema de menores dimensiones e incluso de menor costo, aumentando de esta forma la comodidad del sujeto durante el uso de la BCI.

Con respecto a la disminución de costos para generar un sistema accesible para pacientes y usuarios en general, en este trabajo se presenta un desarrollo llevado a cabo completamente en plataformas de desarrollo de software abierto, que sin dificultad pueden replicarse y buscar su adaptación a funcionar con hardware abierto, permitiendo una mayor posibilidad de un desarrollo de bajo costo y desempeño adecuado en comparación a los sistemas que dependen de software o hardware privativo.

Retomando el aporte en la disminución de épocas y canales, también se abre la posibilidad de una mejora en los tiempos de entrenamiento y procesamiento en línea del sistema al buscar los mínimos óptimos de épocas y canales para tener menos información que procesar, pues se requieren vectores de características más pequeños gracias a la reducción de dimensiones del CCA, favoreciendo principalmente al usuario de la BCI.

Dentro de estas áreas de mejora, se encuentra la selección automática del par de canales para realizar el análisis de correlación canónica pues, a pesar de haber obtenido resultados útiles, el método manual que se reporta en este trabajo no resulta práctico para una interfaz cerebro-computadora ya que se requeriría hacer ese mismo proceso para cada sujeto cada vez que se quiera utilizar el sistema o usar siempre el par de canales elegidos manualmente desde el principio. Además, esta selección manual reduce la posibilidad de obtener un mejor desempeño del sistema propuesto, ya que como se pudo observar en la discusión de resultados, aún puede mejorarse para obtener certezas promedio mayores al 80% y áreas bajo la curva ROC promedio

mayores al 90 % de manera consistente.

Uno de los caminos que podría tomar el presente trabajo para mejorar en la selección de canales sería aplicando la metodología propuesta, por ejemplo, a la mitad de los electrodos utilizados para los sujetos de la base de datos y agregar algún método de selección automática de canales basándose en métodos como la información mutua o el índice de correlación canónica, seleccionando aquellos que compartan la mayor similitud y con ello dejar de lado el análisis empírico de las morfologías de P300, así como también para poder tener una métrica de las relaciones que existen entre distintos canales en el tiempo.

Otra área de oportunidad del presente trabajo es su aplicación para el reconocimiento de caracteres para el deletreador de Donchin ya que es la finalidad última de este tipo de sistemas y eso permitiría dar una mejor idea del desempeño que podría tener en una aplicación en línea para los posibles usuarios, pues tanto la exactitud como la rapidez con la que se representan las palabras e ideas que intenta expresar un sujeto es parte esencial de este tipo de interfaces cerebro computadora para permitirle tener una experiencia de uso agradable y adecuada para aportar a mejorar su calidad de vida.

Otra posible mejora al sistema sería la aplicación de un predictor de texto para facilitar y agilizar la escritura en el deletreador, cosa que podría llevarse a cabo con una BCI híbrida P300-SSVEP en la que las palabras sugeridas por el predictor de texto se mostrarán como estímulos para la generación de potenciales desde estado estable ya que no se necesitaría una gran cantidad de objetivos al mismo tiempo y permitiría la escritura completa de una palabra con el uso de un solo estímulo y un número de épocas mínimo.

Referencias

- [1] J. G. Webster, *Medical instrumentation: application and design*. John Wiley & Sons, 2009.
- [2] R. Lux, A. Evans, M. Burgess, R. Wyatt, and J. Abildskov, “Redundancy reduction for improved display and analysis of body surface potential maps. i. spatial compression.,” *Circulation Research*, vol. 49, no. 1, pp. 186–196, 1981.
- [3] A. Evans, R. Lux, M. Burgess, R. Wyatt, and J. Abildskov, “Redundancy reduction for improved display and analysis of body surface potential maps. ii. temporal compression.,” *Circulation Research*, vol. 49, no. 1, pp. 197–203, 1981.
- [4] M. Akay, *Biomedical signal processing*. Academic press, 2012.
- [5] E. Ciaccio, S. Dunn, and M. Akay, “Biosignal pattern recognition and interpretation systems: Part 1 of 4: Fundamental concepts,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 12, no. 3, pp. 89–89, 1993.
- [6] Y. Wang, R. Wang, X. Gao, B. Hong, and S. Gao, “A practical vep-based brain-computer interface,” *IEEE Transactions on neural systems and rehabilitation engineering*, vol. 14, no. 2, pp. 234–240, 2006.
- [7] G. Bin, X. Gao, Z. Yan, B. Hong, and S. Gao, “An online multi-channel ssv-ep-based brain-computer interface using a canonical correlation analysis method,” *Journal of neural engineering*, vol. 6, no. 4, p. 046002, 2009.
- [8] P.-J. Kindermans, *A Bayesian machine learning framework for true zero-training brain-computer interfaces*. PhD thesis, Ghent University, 2014.
- [9] L. A. Farwell and E. Donchin, “Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials,” *Electroencephalography and clinical Neurophysiology*, vol. 70, no. 6, pp. 510–523, 1988.

- [10] M. Cheng, X. Gao, S. Gao, and D. Xu, “Design and implementation of a brain-computer interface with high transfer rates,” *IEEE transactions on biomedical engineering*, vol. 49, no. 10, pp. 1181–1186, 2002.
- [11] N. R. Waytowich and D. J. Krusienski, “Novel characterization of the steady-state visual evoked potential spectrum of eeg,” in *Proceedings of ACM SIGKDD: Brain KDD Workshop*, 2014.
- [12] C.-S. Wei, Y.-P. Lin, Y. Wang, Y.-T. Wang, and T.-P. Jung, “Detection of steady-state visual-evoked potential using differential canonical correlation analysis,” in *2013 6th International IEEE/EMBS Conference on Neural Engineering (NER)*, pp. 57–60, IEEE, 2013.
- [13] 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. 53, no. 12, pp. 2610–2614, 2006.
- [14] M. H. Chang, J. S. Lee, J. Heo, and K. S. Park, “Eliciting dual-frequency ssvep using a hybrid ssvep-p300 bci,” *Journal of neuroscience methods*, vol. 258, pp. 104–113, 2016.
- [15] N. Kaongoen and S. Jo, “A novel hybrid auditory bci paradigm combining assr and p300,” *Journal of neuroscience methods*, vol. 279, pp. 44–51, 2017.
- [16] F. Lotte and C. Guan, “An efficient p300-based brain-computer interface with minimal calibration time,” in *Assistive Machine Learning for People with Disabilities symposium (NIPS’09 Symposium)*, 2009.
- [17] C. M. Bishop, *Pattern recognition and machine learning*. springer, 2006.
- [18] C. Lindig-León and O. Yáñez-Suárez, “Optimized detection of the infrequent response in p300-based brain-computer interfaces,” *Revista mexicana de ingeniería biomédica*, vol. 34, no. 1, pp. 53–69, 2013.
- [19] C. Ledesma-Ramirez, E. Bojorges-Valdez, O. Yáñez-Suarez, C. Saavedra, L. Bougrain, and G. G. Gentiletti, “An Open-Access P300 Speller Database.” Fourth International Brain-Computer Interface Meeting, May 2010. Poster.

- [20] C. Başar-Eroglu, E. Başar, T. Demiralp, and M. Schürmann, “P300-response: possible psychophysiological correlates in delta and theta frequency channels. a review,” *International journal of psychophysiology*, vol. 13, no. 2, pp. 161–179, 1992.
- [21] M. Borga, “Canonical correlation: a tutorial,” *On line tutorial*, vol. 4, no. 5, 2001.
- [22] W. W. Daniel and F. L. Hernández, *Bioestadística: Base para el análisis de las ciencias de la salud*. No. 570.15195 570.15195 DAN 2002 D3B5 2002 RA409 D3B5 2002, Limusa México, 2002.
- [23] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*. John Wiley & Sons, 2012.
- [24] S. Theodoridis and K. Koutroumbas, “Pattern recognition, edition,” 2009.
- [25] J. W. Eaton, D. Bateman, S. Hauberg, and R. Wehbring, *GNU Octave version 4.2.1 manual: a high-level interactive language for numerical computations*, 2017.
- [26] C.-C. Chang and C.-J. Lin, “LIBSVM: A library for support vector machines,” *ACM Transactions on Intelligent Systems and Technology*, vol. 2, pp. 27:1–27:27, 2011. Software available at.
- [27] C.-W. Hsu, C.-C. Chang, C.-J. Lin, *et al.*, “A practical guide to support vector classification,” 2003.
- [28] T. Fawcett, “An introduction to roc analysis,” *Pattern recognition letters*, vol. 27, no. 8, pp. 861–874, 2006.
- [29] G. Kshirsagar and N. Londhe, “Weighted ensemble of deep convolution neural networks for a single trial character detection in devanagari script based p300 speller,” *IEEE Transactions on Cognitive and Developmental Systems*, 2019.
- [30] M. Alvarado-González, E. Garduño, E. Bribiesca, O. Yáñez-Suárez, and V. Medina-Bañuelos, “P300 detection based on eeg shape features,” *Computational and mathematical methods in medicine*, vol. 2016, 2016.

- [31] E. Bojorges, “Detección de potenciales relacionados a eventos, una solución con subespacios,” Master’s thesis, Universidad Autónoma Metropolitana, 2008.
- [32] M. W. Geisler and J. Polich, “P300 and time of day: circadian rhythms, food intake, and body temperature,” *Biological Psychology*, vol. 31, no. 2, pp. 117–136, 1990.
- [33] R. K. Chaurasiya, N. D. Londhe, and S. Ghosh, “Binary de-based channel selection and weighted ensemble of svm classification for novel brain–computer interface using devanagari script-based p300 speller paradigm,” *International Journal of Human–Computer Interaction*, vol. 32, no. 11, pp. 861–877, 2016.
- [34] S. Halder, A. Pinegger, I. Käthner, S. C. Wriessnegger, J. Faller, J. B. P. Antunes, G. R. Müller-Putz, and A. Kübler, “Brain-controlled applications using dynamic p300 speller matrices,” *Artificial intelligence in medicine*, vol. 63, no. 1, pp. 7–17, 2015.
- [35] I. Käthner, S. C. Wriessnegger, G. R. Müller-Putz, A. Kübler, and S. Halder, “Effects of mental workload and fatigue on the p300, alpha and theta band power during operation of an erp (p300) brain–computer interface,” *Biological psychology*, vol. 102, pp. 118–129, 2014.
- [36] B. Z. Allison and J. A. Pineda, “Effects of soa and flash pattern manipulations on erps, performance, and preference: implications for a bci system,” *International journal of psychophysiology*, vol. 59, no. 2, pp. 127–140, 2006.
- [37] S. Martens, N. Hill, J. Farquhar, and B. Schölkopf, “Overlap and refractory effects in a brain–computer interface speller based on the visual p300 event-related potential,” *Journal of neural engineering*, vol. 6, no. 2, p. 026003, 2009.
- [38] E. Lin and J. Polich, “P300 habituation patterns: individual differences from ultradian rhythms,” *Perceptual and motor skills*, vol. 88, no. 3_suppl, pp. 1111–1125, 1999.
- [39] A. E. Selim, M. A. Wahed, and Y. M. Kadah, “Electrode reduction using ica and pca in p300 visual speller brain-computer interface system,” in

- 2nd Middle East Conference on Biomedical Engineering*, pp. 357–360, IEEE, 2014.
- [40] A. S. Elsawy, S. Eldawlatly, M. Taher, and G. M. Aly, “Mindedit: A p300-based text editor for mobile devices,” *Computers in biology and medicine*, vol. 80, pp. 97–106, 2017.
- [41] E. Chiou and S. Puthusserypady, “Spatial filter feature extraction methods for p300 bci speller: A comparison,” in *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 003859–003863, IEEE, 2016.
- [42] N. N. Nashed, S. Eldawlatly, and G. M. Aly, “A deep learning approach to single-trial classification for p300 spellers,” in *2018 IEEE 4th Middle East Conference on Biomedical Engineering (MECBME)*, pp. 11–16, IEEE, 2018.
- [43] W. L. Lee, T. Tan, and Y. H. Leung, “An improved p300 extraction using ica-r for p300-bci speller,” in *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 7064–7067, IEEE, 2013.
- [44] S. Kanoga, T. Hoshino, and H. Asoh, “Independent low-rank matrix analysis-based automatic artifact reduction technique applied to three bci paradigms,” *Frontiers in Human Neuroscience*, vol. 14, 2020.
- [45] M. Spüler, A. Walter, W. Rosenstiel, 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, no. 6, pp. 1097–1103, 2013.
- [46] J. D. Chailloux Peguero, O. Mendoza-Montoya, and J. M. Antelis, “Single-option p300-bci performance is affected by visual stimulation conditions,” *Sensors*, vol. 20, no. 24, p. 7198, 2020.
- [47] C. F. B. Díaz and A. F. R. Olaya, “A novel method based on regularized logistic regression and cca for p300 detection using a reduced number of eeg trials,” *IEEE Latin America Transactions*, vol. 18, no. 12, pp. 2147–2154, 2020.

Anexo de resultados por sujeto

En esta sección se muestran los resultados individuales de desempeño por sujeto así como los valores de costo y gama utilizados. El número de la figura corresponde con el número de sujeto como se muestra en el índice de figuras de este anexo.

Las líneas en magenta representan una disminución en el desempeño al agregar una época más al análisis. Las líneas verdes representan un aumento en el desempeño al agregar una época.

Las épocas utilizadas fueron elegidas de manera aleatoria de la sesión 1 de registro para cada sujeto de la base de datos P300 del LINI dado que no todos los sujetos tenían registros completos en el resto de las sesiones.

Índice de figuras

A.1. Desempeño del clasificador para el sujeto ACS.	54
A.2. Desempeño del clasificador para el sujeto APM.	55
A.3. Desempeño del clasificador para el sujeto ASG.	56
A.4. Desempeño del clasificador para el sujeto ASR.	57
A.5. Desempeño del clasificador para el sujeto CLL.	58
A.6. Desempeño del clasificador para el sujeto CLR.	59
A.7. Desempeño del clasificador para el sujeto DCM.	60
A.8. Desempeño del clasificador para el sujeto DLP.	61
A.9. Desempeño del clasificador para el sujeto DMA.	62
A.10. Desempeño del clasificador para el sujeto ELC.	63
A.11. Desempeño del clasificador para el sujeto FSZ.	64
A.12. Desempeño del clasificador para el sujeto GCE.	65
A.13. Desempeño del clasificador para el sujeto ICE.	66
A.14. Desempeño del clasificador para el sujeto IZH.	67
A.15. Desempeño del clasificador para el sujeto JCR.	68
A.16. Desempeño del clasificador para el sujeto JLD.	69
A.17. Desempeño del clasificador para el sujeto JLP.	70
A.18. Desempeño del clasificador para el sujeto JMR.	71
A.19. Desempeño del clasificador para el sujeto JSC.	72
A.20. Desempeño del clasificador para el sujeto JST.	73
A.21. Desempeño del clasificador para el sujeto LAC.	74
A.22. Desempeño del clasificador para el sujeto LAG.	75
A.23. Desempeño del clasificador para el sujeto LGP.	76
A.24. Desempeño del clasificador para el sujeto LPS.	77
A.25. Desempeño del clasificador para el sujeto MLR.	78
A.26. Desempeño del clasificador para el sujeto MoMR.	79
A.27. Desempeño del clasificador para el sujeto PGA.	80
A.28. Desempeño del clasificador para el sujeto RHA.	81
A.29. Desempeño del clasificador para el sujeto WFG.	82
A.30. Desempeño del clasificador para el sujeto XCL.	83

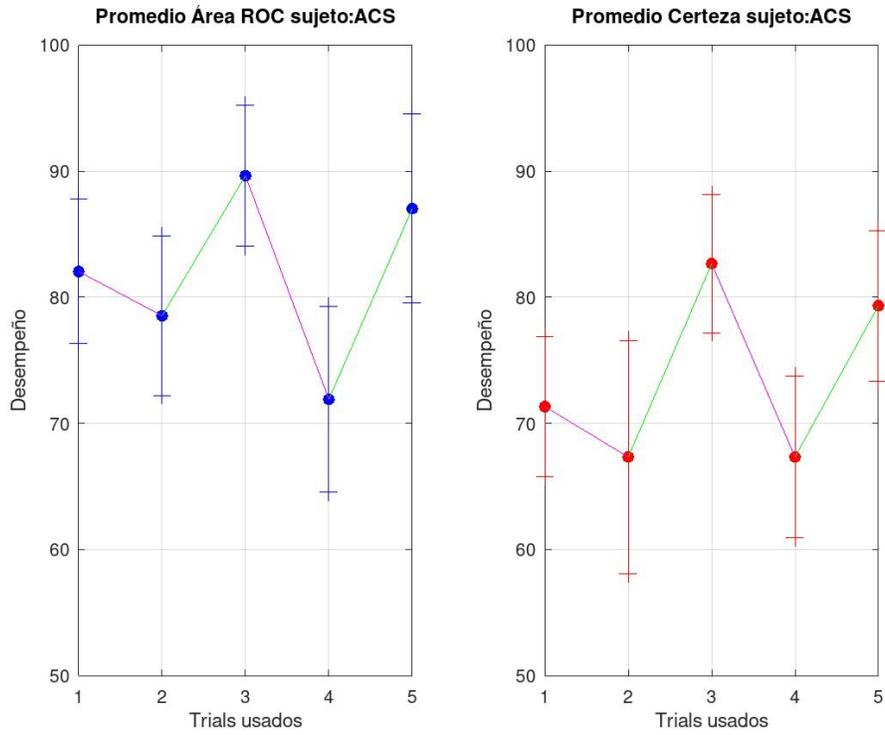


Figura A.1: Desempeño del clasificador para el sujeto ACS.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
ACS	1	82.04 % \pm 5.72	71.33 % \pm 5.58	0.33	14
	2	78.53 % \pm 6.31	67.33 % \pm 9.25	0.22	0.29
	3	89.64 % \pm 5.61	82.67 % \pm 5.48	1.9e+04	0.01
	4	71.91 % \pm 7.35	67.33 % \pm 6.41	1.9e+02	0.009
	5	87.02 % \pm 7.50	79.33 % \pm 5.96	42	0.76

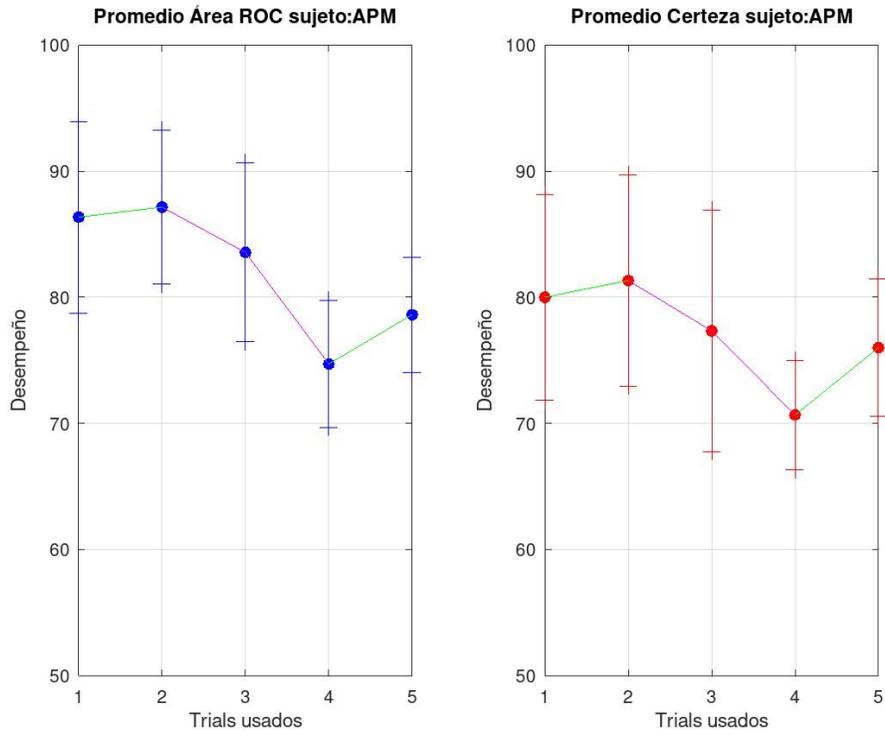


Figura A.2: Desempeño del clasificador para el sujeto APM.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
APM	1	86.36 % \pm 7.61	80.00 % \pm 8.16	37	5.3
	2	87.16 % \pm 6.09	81.33 % \pm 8.37	2.2e+04	0.0068
	3	83.56 % \pm 7.09	77.33 % \pm 9.55	1.1e+02	0.0026
	4	74.71 % \pm 5.02	70.67 % \pm 4.35	1.9e+04	5.3e-05
	5	78.62 % \pm 4.56	76.00 % \pm 5.48	5.7e+04	3.5e-05

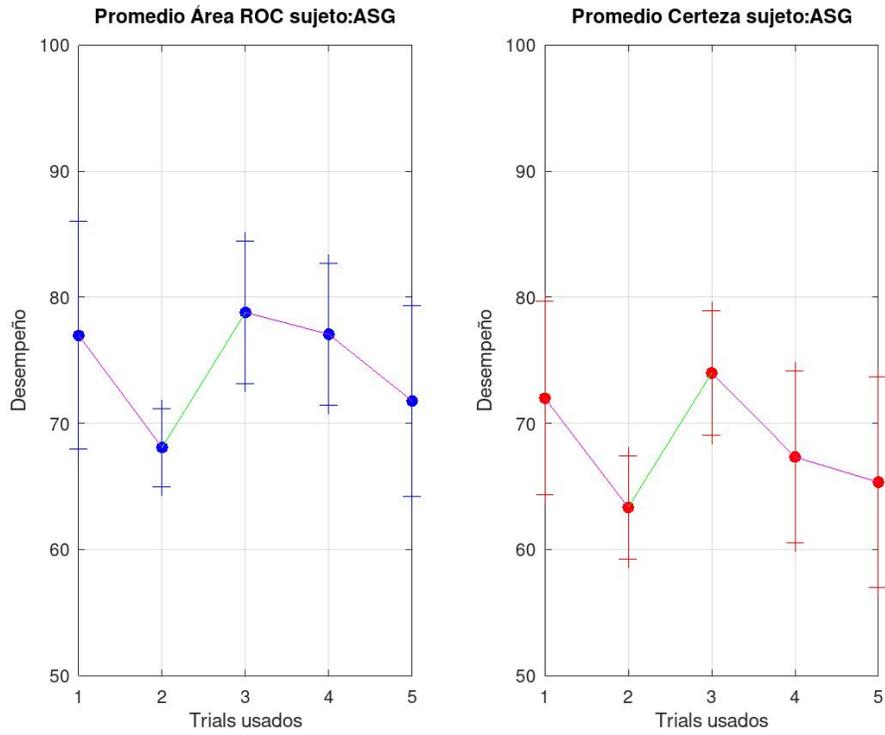


Figura A.3: Desempeño del clasificador para el sujeto ASG.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
ASG	1	76.98 % \pm 9.03	72.00 % \pm 7.67	14	1.5
	2	68.09 % \pm 3.10	63.33 % \pm 4.08	21	0.054
	3	78.80 % \pm 5.63	74.00 % \pm 4.94	8.2e+03	0.063
	4	77.07 % \pm 5.62	67.33 % \pm 6.83	2.7e+03	3.5e-05
	5	71.78 % \pm 7.59	65.33 % \pm 8.37	1.3e+02	0.00021

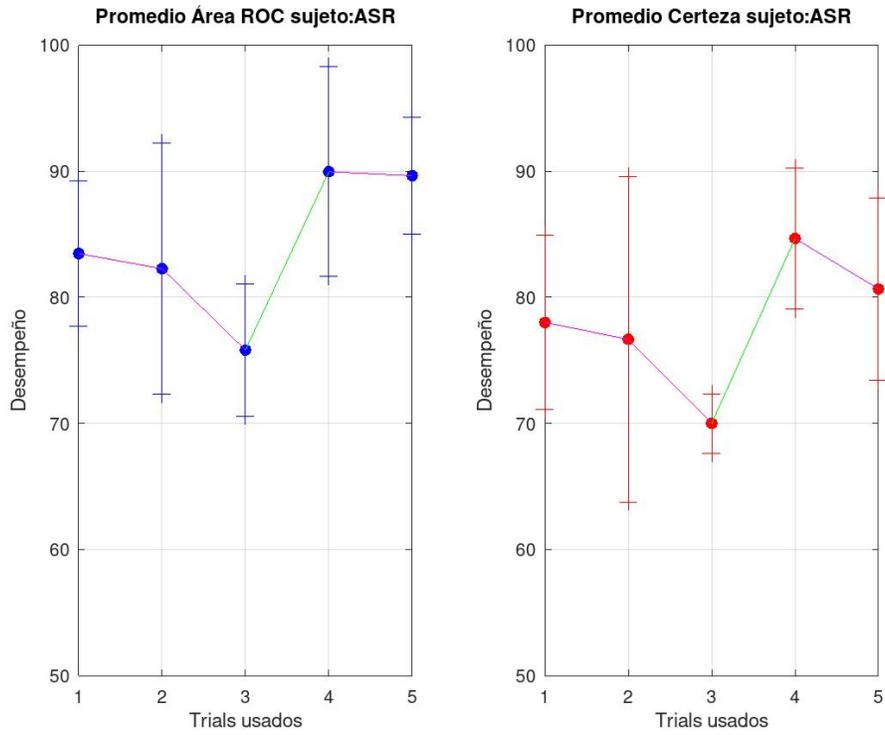


Figura A.4: Desempeño del clasificador para el sujeto ASR.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
ASR	1	83.47 % \pm 5.77	78.00 % \pm 6.91	97	1
	2	82.27 % \pm 9.95	76.67 % \pm 12.91	5.7e+04	0.0011
	3	75.82 % \pm 5.24	70.00 % \pm 2.36	14	1
	4	89.96 % \pm 8.33	84.67 % \pm 5.58	4.7e+03	0.027
	5	89.64 % \pm 4.62	80.67 % \pm 7.23	3.5	0.38

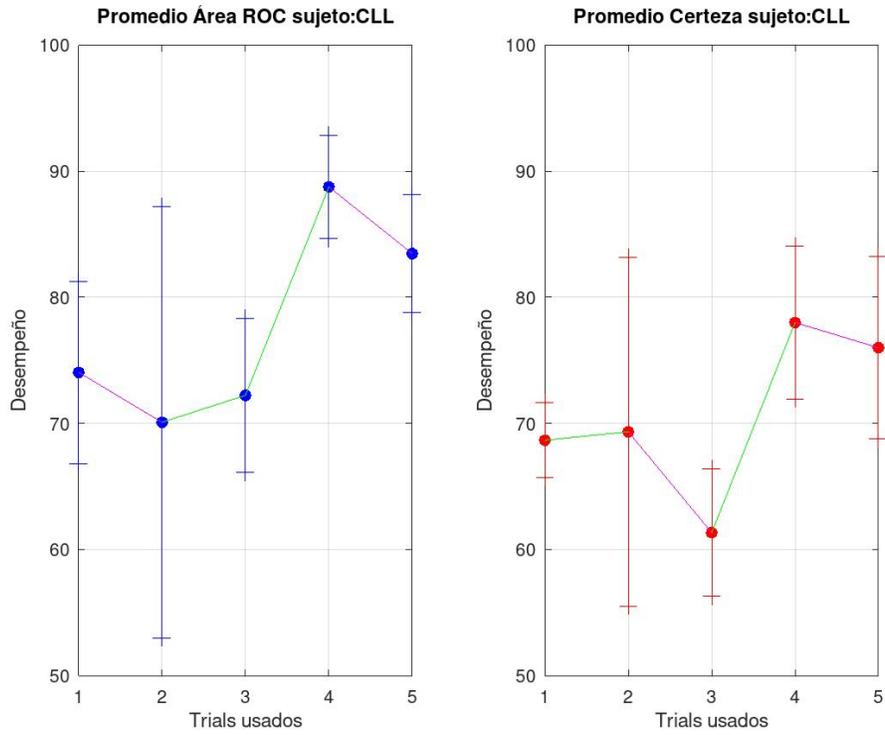


Figura A.5: Desempeño del clasificador para el sujeto CLL.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
CLL	1	74.04 % \pm 7.21	68.67 % \pm 2.98	56	7
	2	70.09 % \pm 17.10	69.33 % \pm 13.82	37	2.6
	3	72.22 % \pm 6.12	61.33 % \pm 5.06	0.095	0.14
	4	88.76 % \pm 4.11	78.00 % \pm 6.06	37	0.33
	5	83.47 % \pm 4.64	76.00 % \pm 7.23	2.5e+04	0.00011

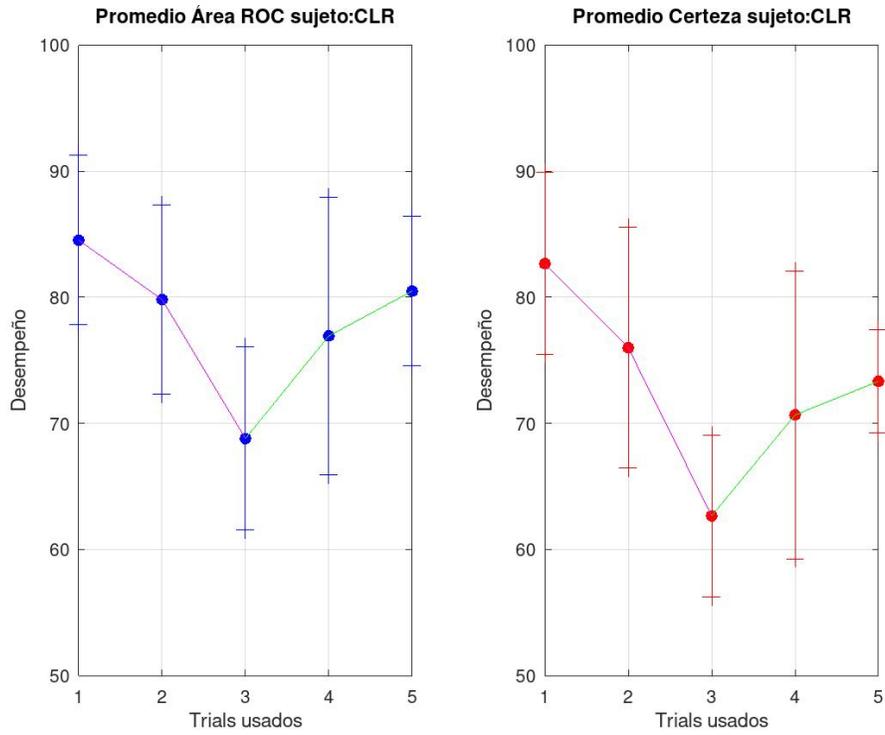


Figura A.6: Desempeño del clasificador para el sujeto CLR.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
CLR	1	84.53 % ± 6.72	82.67 % ± 7.23	2.4e+03	0.19
	2	79.82 % ± 7.49	76.00 % ± 9.55	1.3	0.87
	3	68.80 % ± 7.25	62.67 % ± 6.41	18	0.29
	4	76.93 % ± 11.03	70.67 % ± 11.40	0.76	8
	5	80.49 % ± 5.93	73.33 % ± 4.08	0.041	2

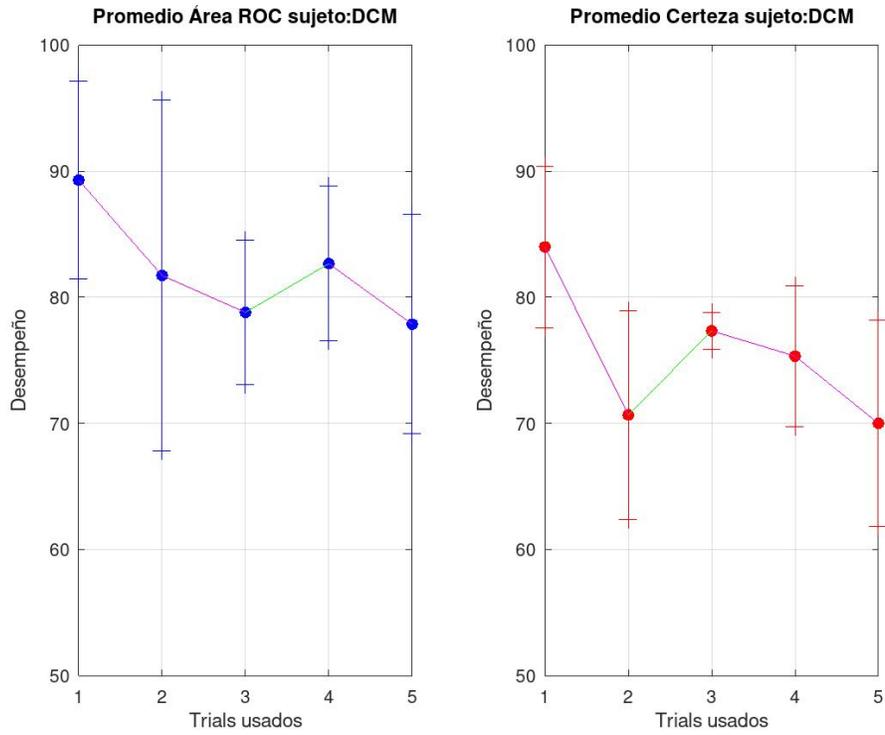


Figura A.7: Desempeño del clasificador para el sujeto DCM.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
DCM	1	89.29 % \pm 7.85	84.00 % \pm 6.41	4.3e+04	0.012
	2	81.73 % \pm 13.93	70.67 % \pm 8.30	0.22	6.1
	3	78.80 % \pm 5.73	77.33 % \pm 1.49	0.082	2.6
	4	82.67 % \pm 6.14	75.33 % \pm 5.58	1e+03	0.0022
	5	77.87 % \pm 8.70	70.00 % \pm 8.16	6.1	0.33

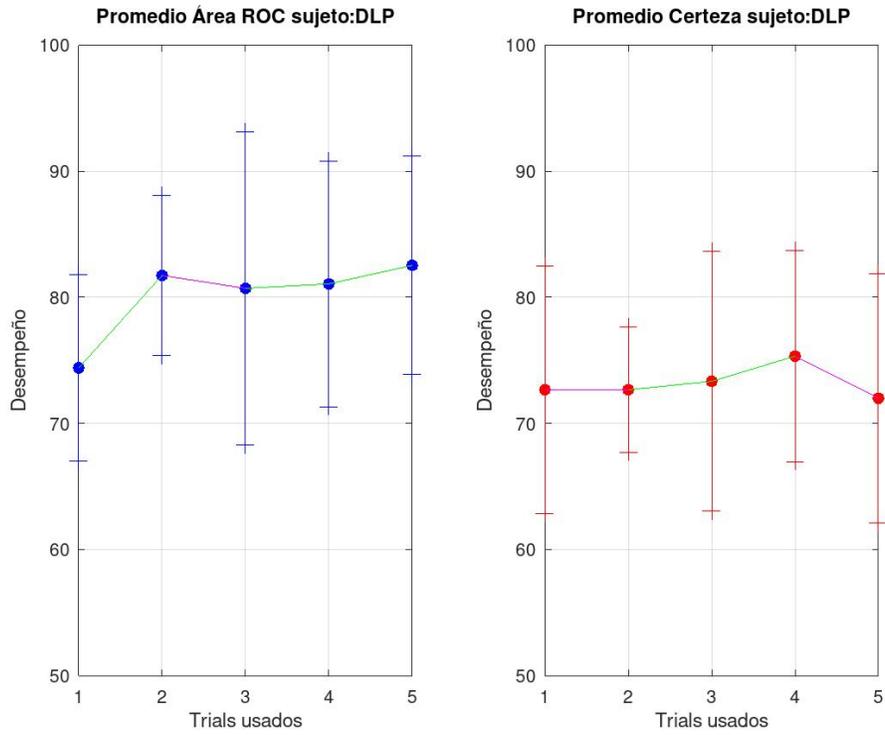


Figura A.8: Desempeño del clasificador para el sujeto DLP.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
DLP	1	74.40 % \pm 7.42	72.67 % \pm 9.83	74	4
	2	81.73 % \pm 6.33	72.67 % \pm 4.94	1.9e+04	0.082
	3	80.71 % \pm 12.40	73.33 % \pm 10.27	0.57	5.3
	4	81.07 % \pm 9.74	75.33 % \pm 8.37	7	0.027
	5	82.53 % \pm 8.65	72.00 % \pm 9.89	3.9e+02	0.0045

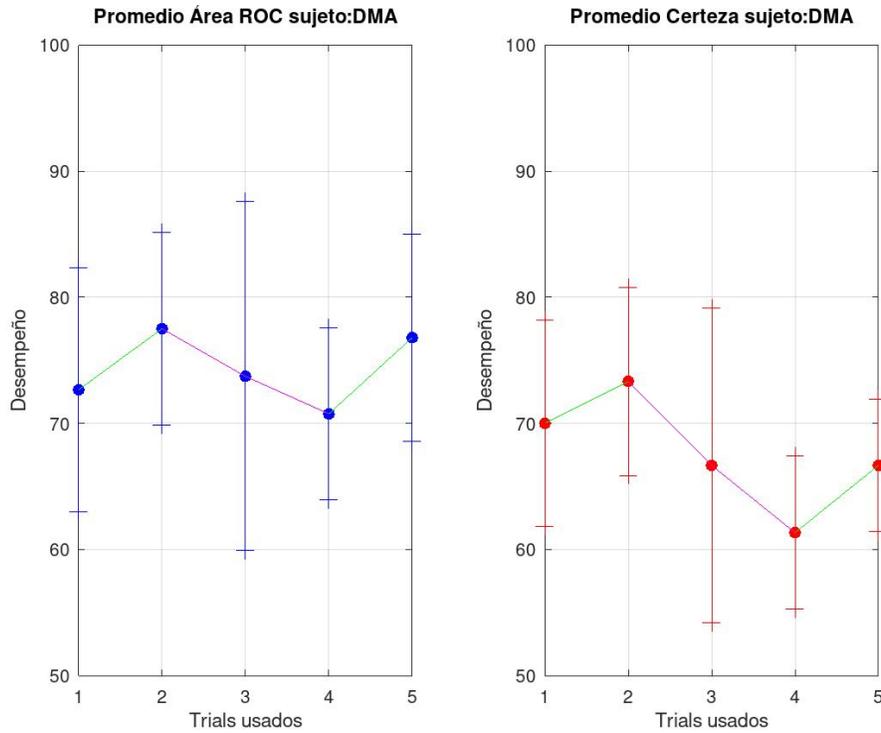


Figura A.9: Desempeño del clasificador para el sujeto DMA.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
DMA	1	72.67 % ± 9.70	70.00 % ± 8.16	1.6e+03	2.6
	2	77.51 % ± 7.62	73.33 % ± 7.45	2.6e+02	0.054
	3	73.73 % ± 13.84	66.67 % ± 12.47	3.1e+03	0.024
	4	70.76 % ± 6.82	61.33 % ± 6.06	4.5e+02	0.021
	5	76.80 % ± 8.22	66.67 % ± 5.27	3.6e+03	0.014

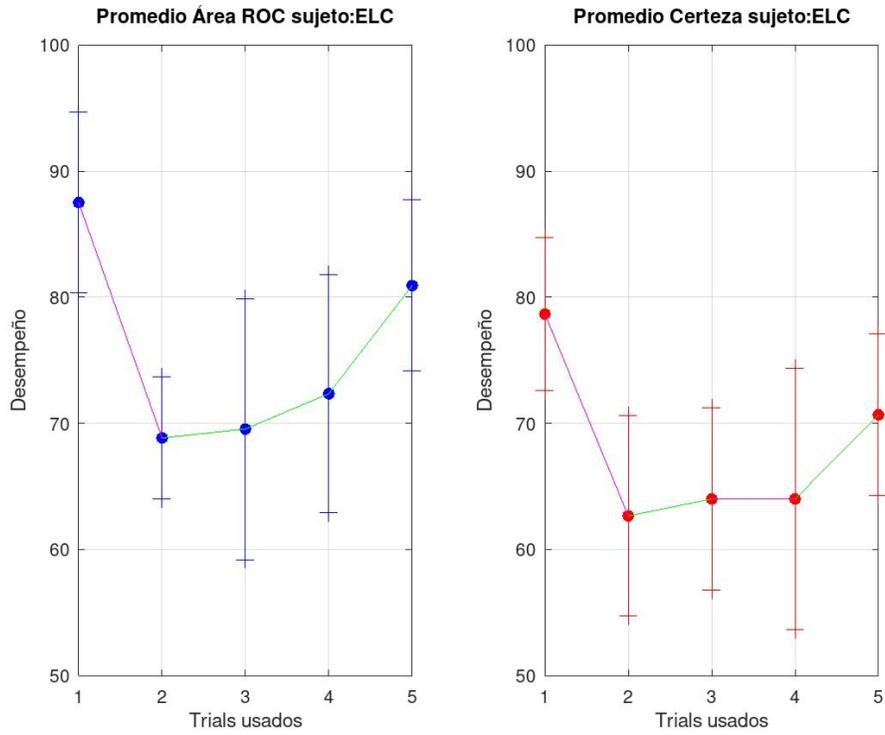


Figura A.10: Desempeño del clasificador para el sujeto ELC.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
ELC	1	87.51 % \pm 7.18	78.67 % \pm 6.06	1.7e+02	12
	2	68.84 % \pm 4.86	62.67 % \pm 7.96	2.6	0.016
	3	69.56 % \pm 10.36	64.00 % \pm 7.23	1.3	1.3
	4	72.36 % \pm 9.44	64.00 % \pm 10.38	4	0.072
	5	80.93 % \pm 6.77	70.67 % \pm 6.41	2	0.22

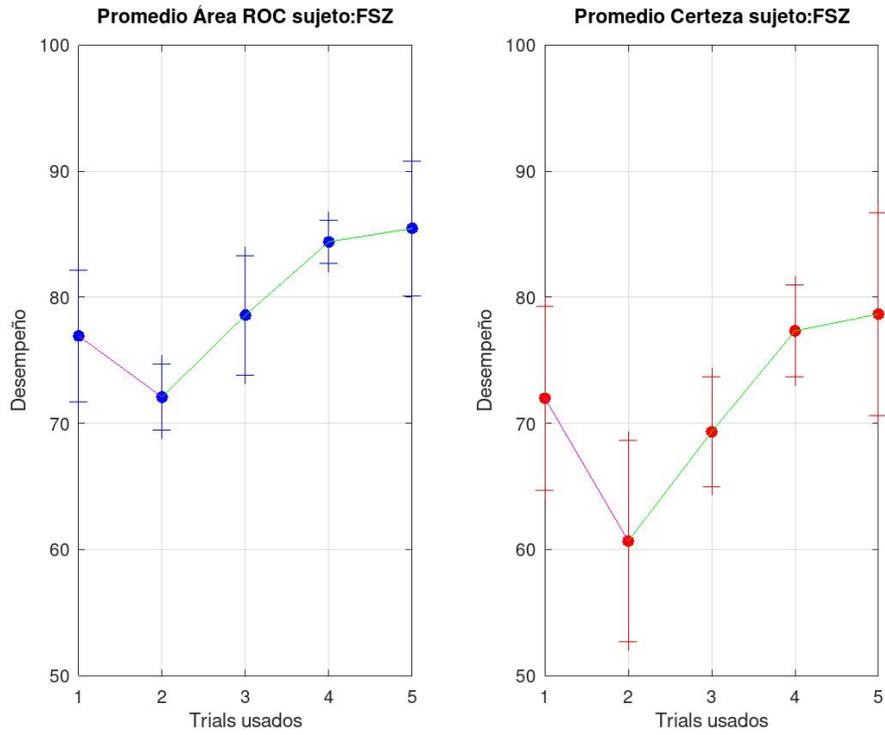


Figura A.11: Desempeño del clasificador para el sujeto FSZ.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
FSZ	1	76.93 % ±5.22	72.00 % ±7.30	0.57	3.5
	2	72.09 % ±2.62	60.67 % ±7.96	74	0.00098
	3	78.58 % ±4.74	69.33 % ±4.35	1.9e+04	0.0078
	4	84.40 % ±1.70	77.33 % ±3.65	4.1e+03	0.00037
	5	85.47 % ±5.34	78.67 % ±8.03	8.9e+02	6.1e-05

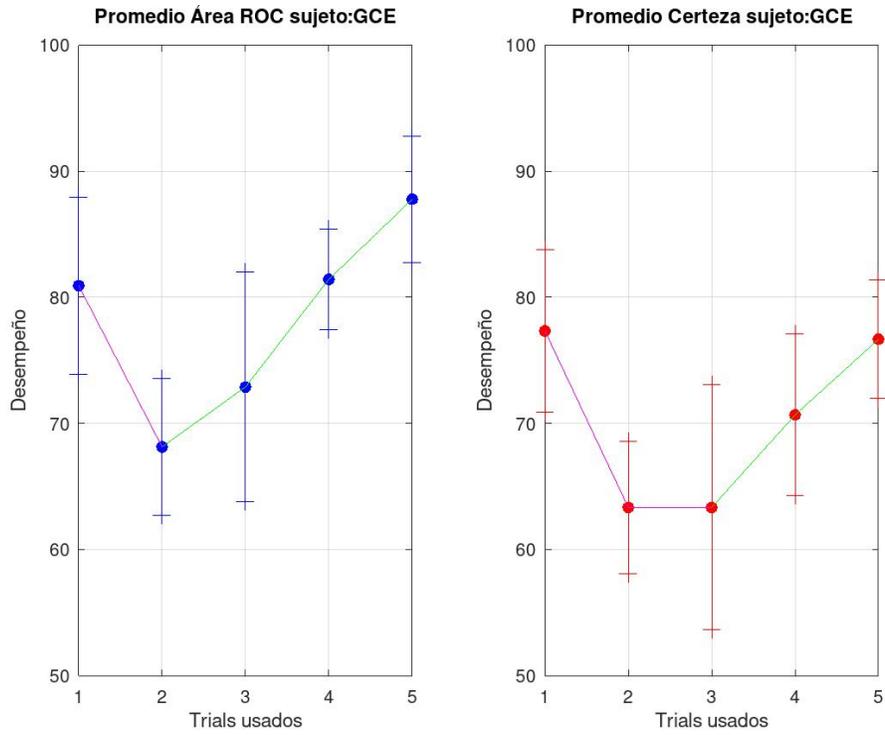


Figura A.12: Desempeño del clasificador para el sujeto GCE.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
GCE	1	80.93 % \pm 7.03	77.33 % \pm 6.41	3.1e+03	8
	2	68.13 % \pm 5.43	63.33 % \pm 5.27	0.22	1.1
	3	72.89 % \pm 9.09	63.33 % \pm 9.72	8	0.021
	4	81.42 % \pm 4.01	70.67 % \pm 6.41	0.024	1
	5	87.78 % \pm 5.00	76.67 % \pm 4.71	42	0.0011

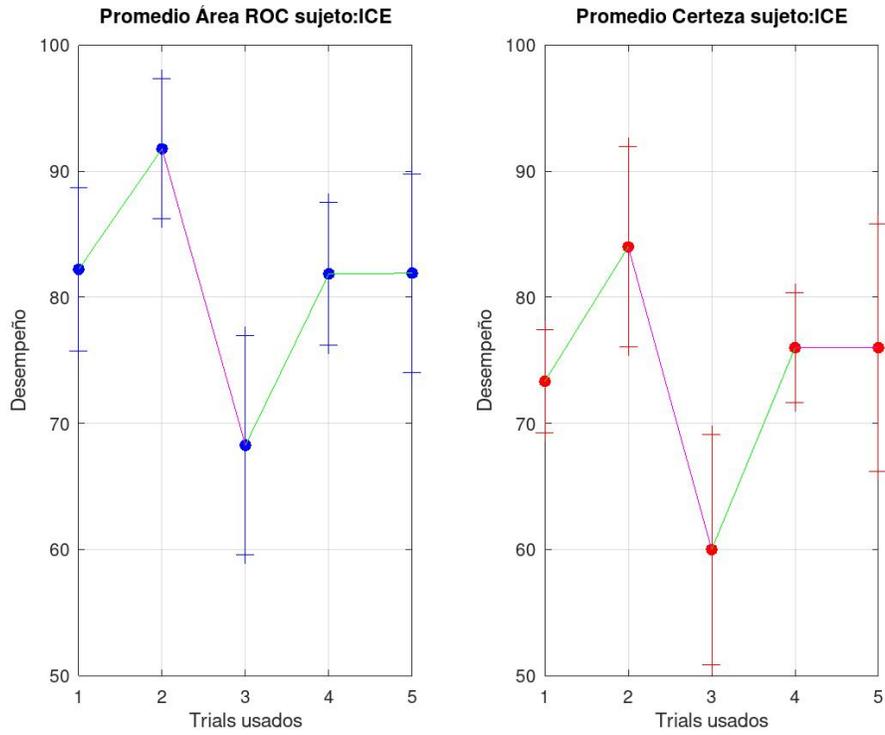


Figura A.13: Desempeño del clasificador para el sujeto ICE.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
ICE	1	82.22 % \pm 6.49	73.33 % \pm 4.08	97	16
	2	91.78 % \pm 5.58	84.00 % \pm 7.96	37	1.3
	3	68.27 % \pm 8.67	60.00 % \pm 9.13	2.2e+02	0.0034
	4	81.87 % \pm 5.68	76.00 % \pm 4.35	1.3e+02	0.22
	5	81.91 % \pm 7.89	76.00 % \pm 9.83	2.2e+04	0.0078

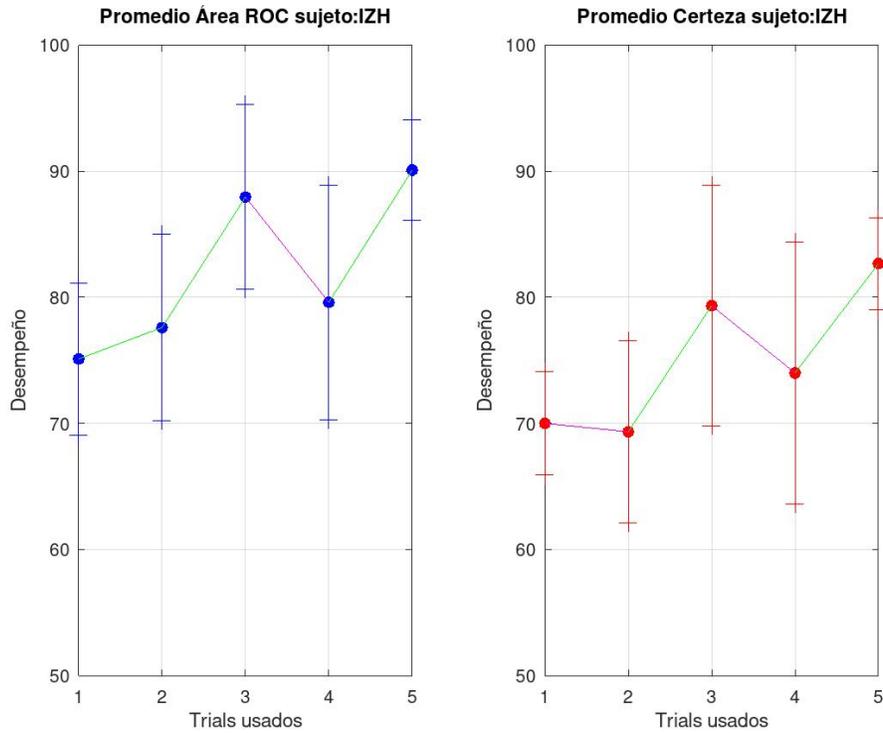


Figura A.14: Desempeño del clasificador para el sujeto IZH.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
IZH	1	75.11 % \pm 6.04	70.00 % \pm 4.08	2.5e+04	4.6
	2	77.60 % \pm 7.39	69.33 % \pm 7.23	1.3	0.22
	3	87.96 % \pm 7.31	79.33 % \pm 9.55	3.8e+04	0.0034
	4	79.60 % \pm 9.32	74.00 % \pm 10.38	5.1e+02	0.25
	5	90.09 % \pm 3.97	82.67 % \pm 3.65	4.5e+02	0.19

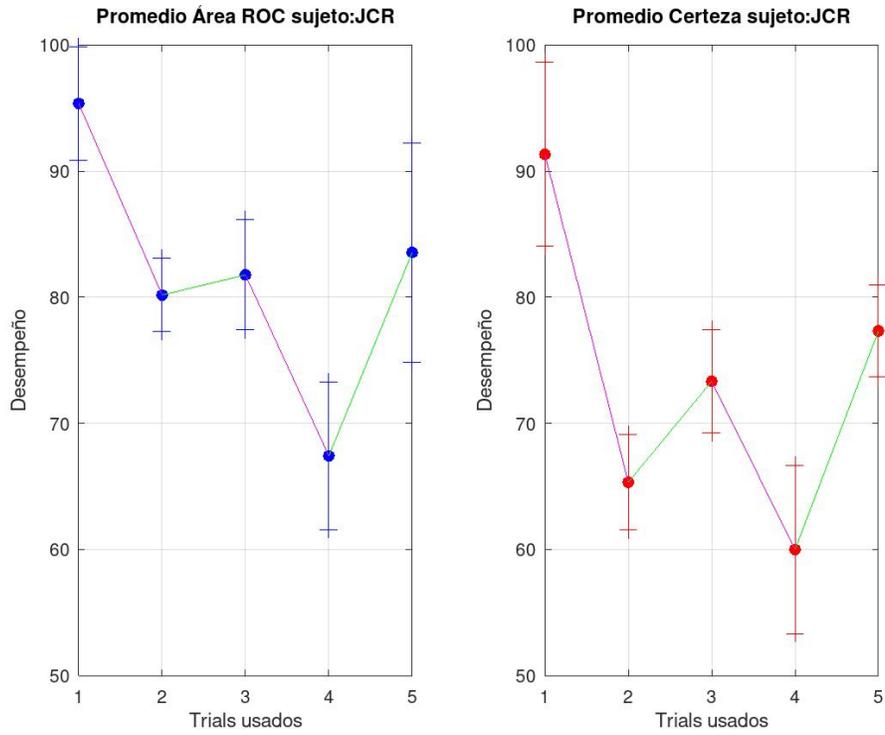


Figura A.15: Desempeño del clasificador para el sujeto JCR.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
JCR	1	95.38 % \pm 4.50	91.33 % \pm 7.30	6.6e+04	0.041
	2	80.18 % \pm 2.90	65.33 % \pm 3.80	2.3	0.33
	3	81.78 % \pm 4.37	73.33 % \pm 4.08	7.1e+03	0.0052
	4	67.42 % \pm 5.83	60.00 % \pm 6.67	11	0.0017
	5	83.56 % \pm 8.70	77.33 % \pm 3.65	2.7e+03	0.00019

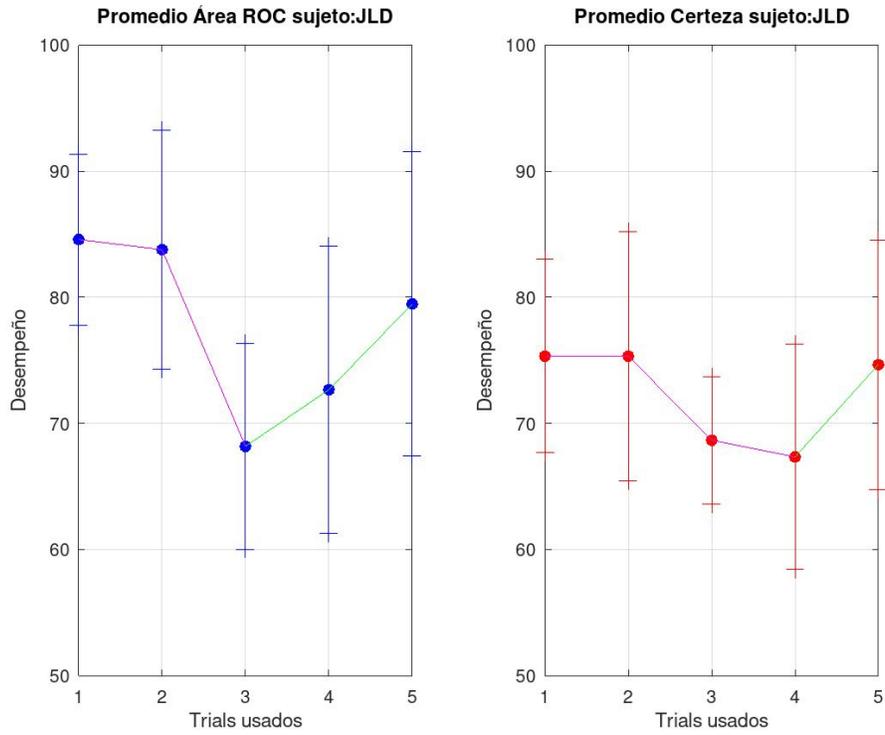


Figura A.16: Desempeño del clasificador para el sujeto JLD.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
JLD	1	84.58 % \pm 6.77	75.33 % \pm 7.67	7	7
	2	83.78 % \pm 9.47	75.33 % \pm 9.89	3.1e+03	0.027
	3	68.18 % \pm 8.16	68.67 % \pm 5.06	7.1e+03	0.0022
	4	72.67 % \pm 11.37	67.33 % \pm 8.94	1.5e+02	0.00024
	5	79.47 % \pm 12.07	74.67 % \pm 9.89	3.3e+04	0.0078

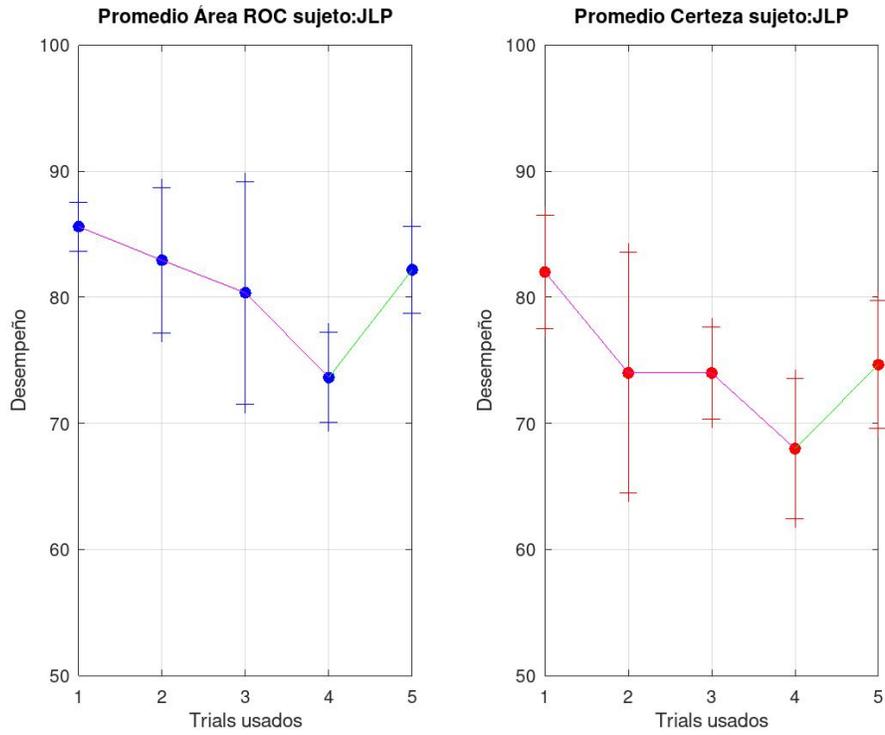


Figura A.17: Desempeño del clasificador para el sujeto JLP.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
JLP	1	85.60 % \pm 1.94	82.00 % \pm 4.47	1.9e+04	0.072
	2	82.93 % \pm 5.76	74.00 % \pm 9.55	32	0.082
	3	80.36 % \pm 8.83	74.00 % \pm 3.65	0.87	3.5
	4	73.64 % \pm 3.56	68.00 % \pm 5.58	1.3e+02	0.054
	5	82.18 % \pm 3.47	74.67 % \pm 5.06	1.3	9.2

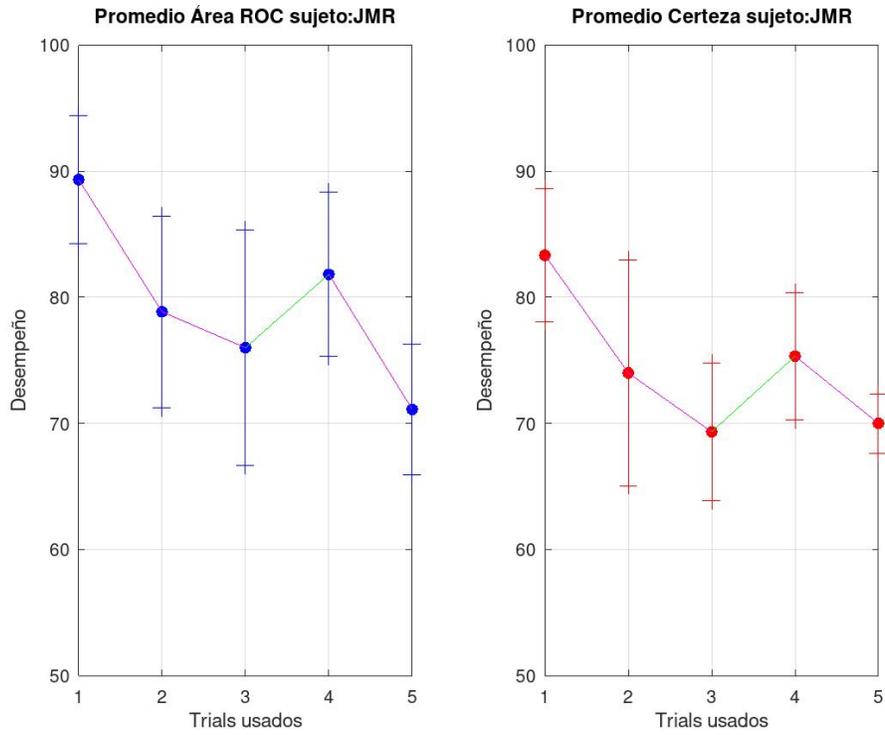


Figura A.18: Desempeño del clasificador para el sujeto JMR.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
JMR	1	89.33 % \pm 5.07	83.33 % \pm 5.27	2.6e+02	0.14
	2	78.84 % \pm 7.62	74.00 % \pm 8.94	4.7e+03	0.0078
	3	76.00 % \pm 9.33	69.33 % \pm 5.48	5.9e+02	0.024
	4	81.82 % \pm 6.52	75.33 % \pm 5.06	5e+04	0.0039
	5	71.11 % \pm 5.17	70.00 % \pm 2.36	0.57	5.3

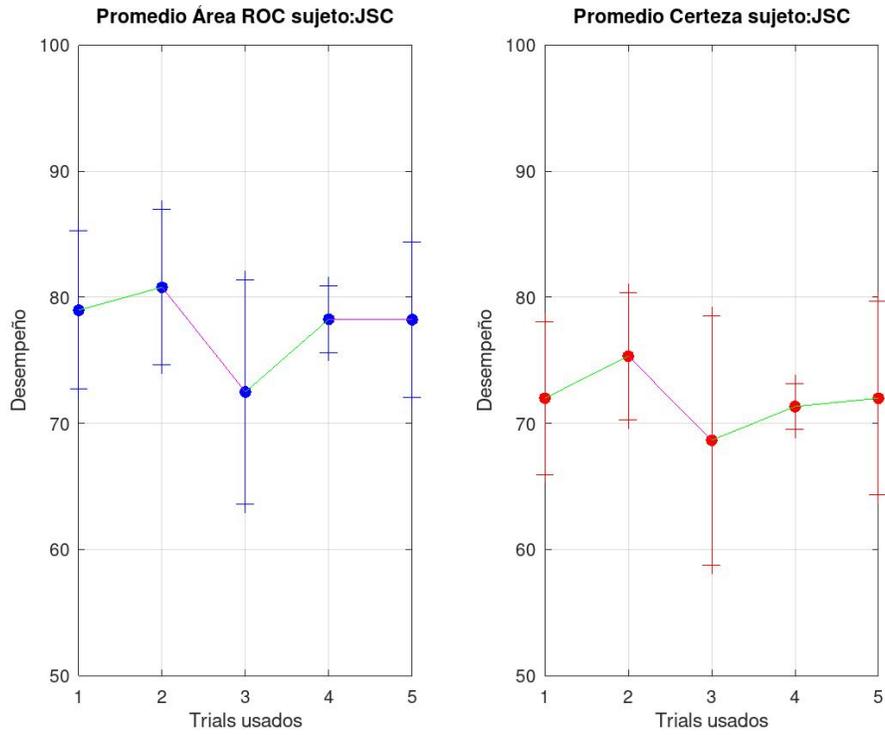


Figura A.19: Desempeño del clasificador para el sujeto JSC.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
JSC	1	78.98 % \pm 6.28	72.00 % \pm 6.06	1.1	9.2
	2	80.80 % \pm 6.15	75.33 % \pm 5.06	24	0.87
	3	72.49 % \pm 8.90	68.67 % \pm 9.89	3.3e+04	0.063
	4	78.27 % \pm 2.65	71.33 % \pm 1.83	0.19	0.14
	5	78.22 % \pm 6.19	72.00 % \pm 7.67	11	0.036

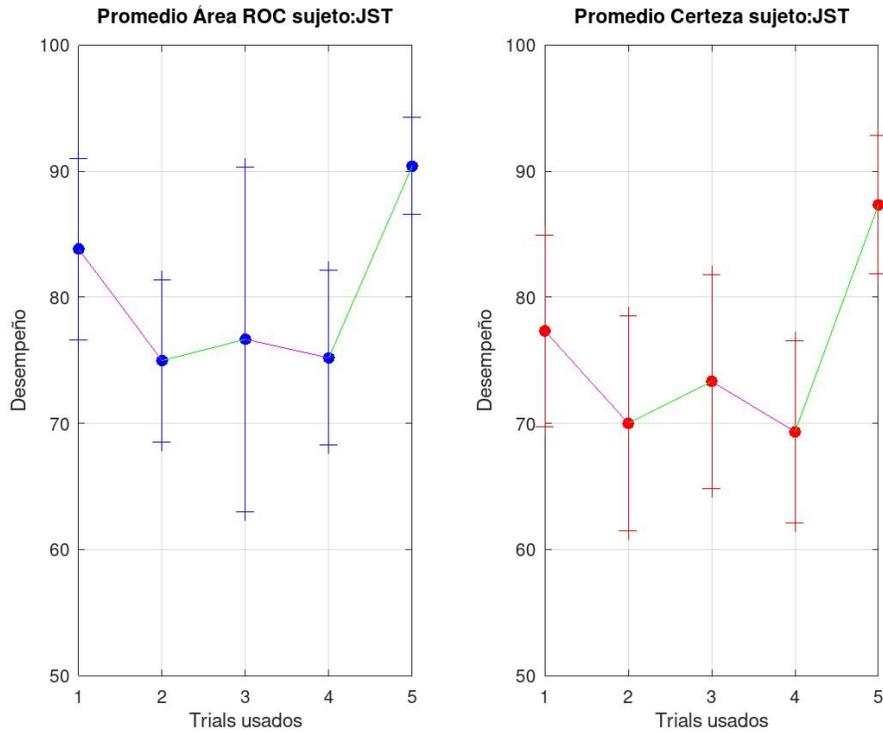


Figura A.20: Desempeño del clasificador para el sujeto JST.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
JST	1	83.82 % \pm 7.20	77.33 % \pm 7.60	64	9.2
	2	74.98 % \pm 6.45	70.00 % \pm 8.50	2	1
	3	76.67 % \pm 13.69	73.33 % \pm 8.50	0.095	1.3
	4	75.20 % \pm 6.92	69.33 % \pm 7.23	1.2e+03	0.024
	5	90.40 % \pm 3.85	87.33 % \pm 5.48	5.1e+02	0.16

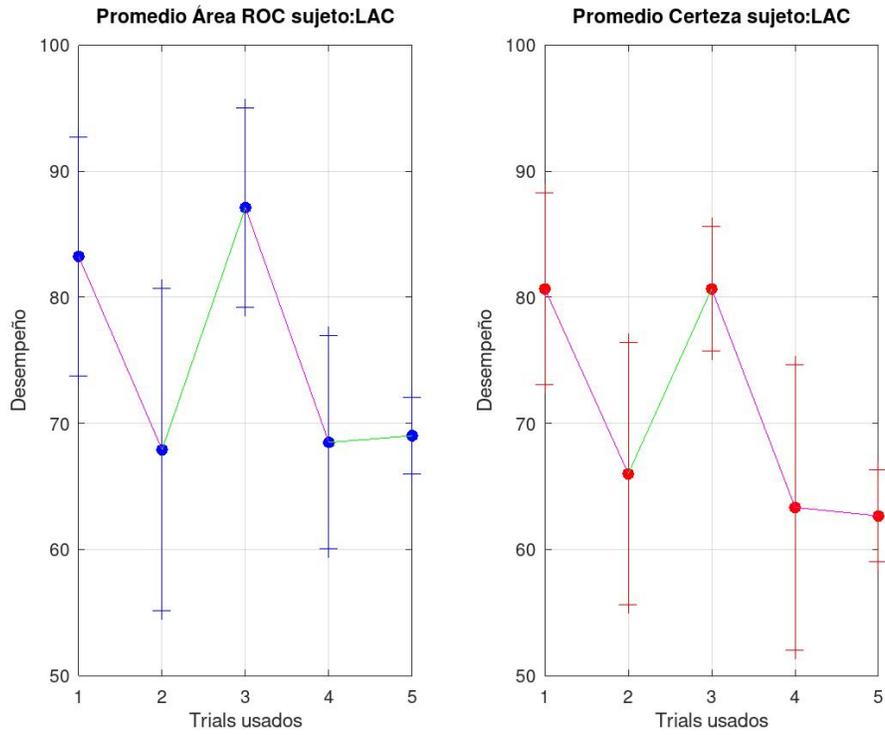


Figura A.21: Desempeño del clasificador para el sujeto LAC.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
LAC	1	83.24 % \pm 9.48	80.67 % \pm 7.60	74	0.38
	2	67.91 % \pm 12.79	66.00 % \pm 10.38	24	0.0078
	3	87.11 % \pm 7.90	80.67 % \pm 4.94	2.6	0.25
	4	68.49 % \pm 8.44	63.33 % \pm 11.30	3.8e+04	0.00056
	5	69.02 % \pm 3.06	62.67 % \pm 3.65	3.9e+02	8.1e-05

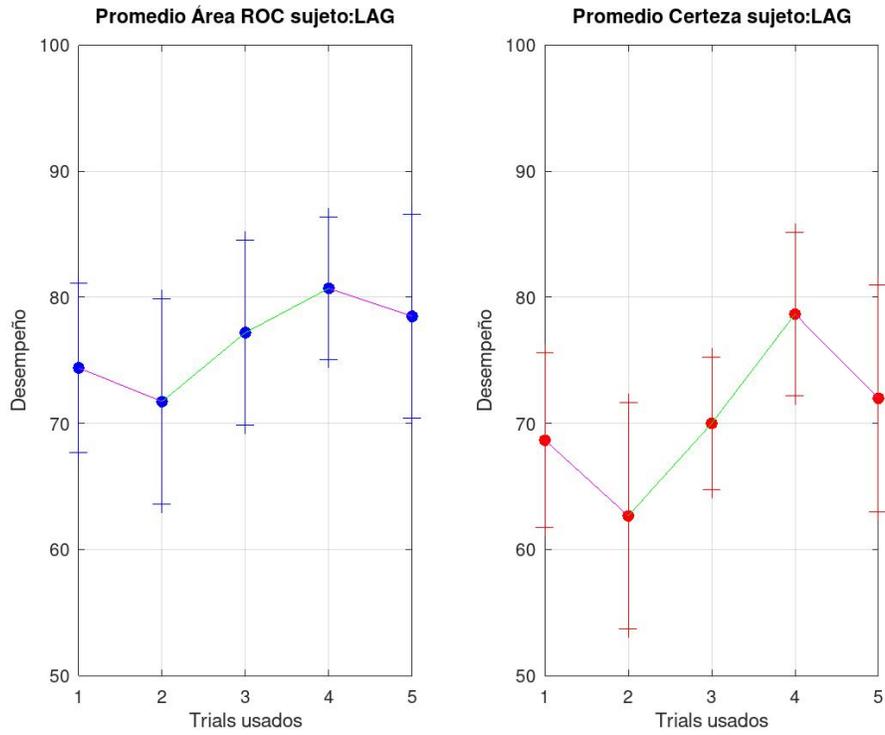


Figura A.22: Desempeño del clasificador para el sujeto LAG.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
LAG	1	74.40 % \pm 6.68	68.67 % \pm 6.91	4.5e+02	11
	2	71.73 % \pm 8.15	62.67 % \pm 8.94	7.8e+02	0.012
	3	77.20 % \pm 7.34	70.00 % \pm 5.27	1.3e+02	0.00019
	4	80.71 % \pm 5.64	78.67 % \pm 6.50	1.5e+02	0.14
	5	78.49 % \pm 8.10	72.00 % \pm 9.01	5.4e+03	0.0078

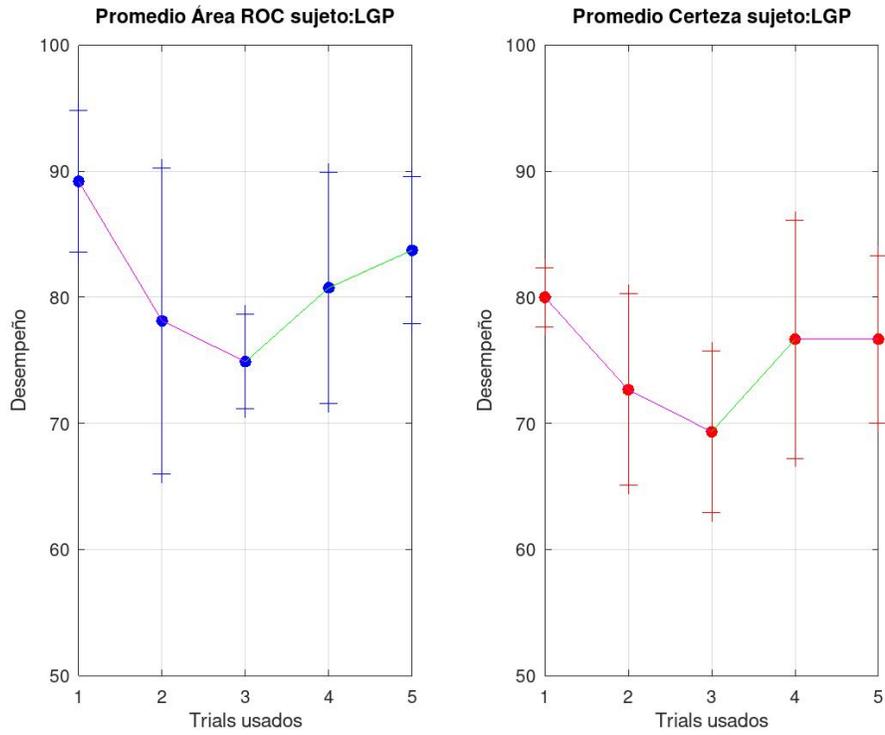


Figura A.23: Desempeño del clasificador para el sujeto LGP.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
LGP	1	89.20 % \pm 5.62	80.00 % \pm 2.36	12	1.5
	2	78.13 % \pm 12.15	72.67 % \pm 7.60	12	0.095
	3	74.89 % \pm 3.74	69.33 % \pm 6.41	1.6e+03	0.082
	4	80.76 % \pm 9.16	76.67 % \pm 9.43	2.6e+02	0.036
	5	83.73 % \pm 5.83	76.67 % \pm 6.67	42	0.16

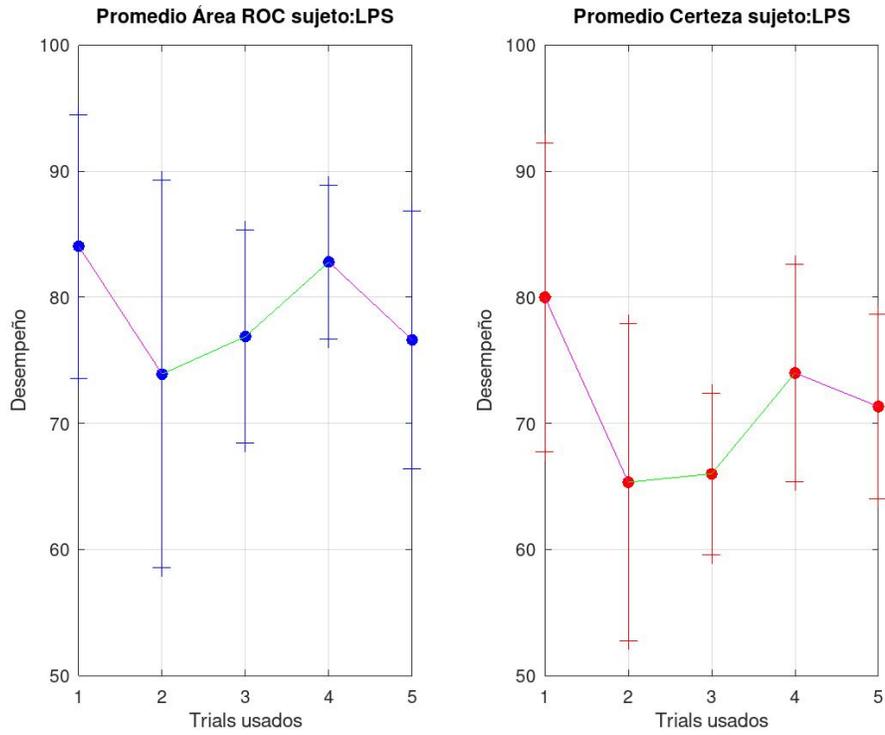


Figura A.24: Desempeño del clasificador para el sujeto LPS.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
LPS	1	84.04 % \pm 10.46	80.00 % \pm 12.25	97	7
	2	73.91 % \pm 15.38	65.33 % \pm 12.61	9.2	0.0022
	3	76.89 % \pm 8.45	66.00 % \pm 6.41	8.9e+02	0.14
	4	82.80 % \pm 6.11	74.00 % \pm 8.63	3.6e+03	0.0078
	5	76.62 % \pm 10.24	71.33 % \pm 7.30	0.57	2

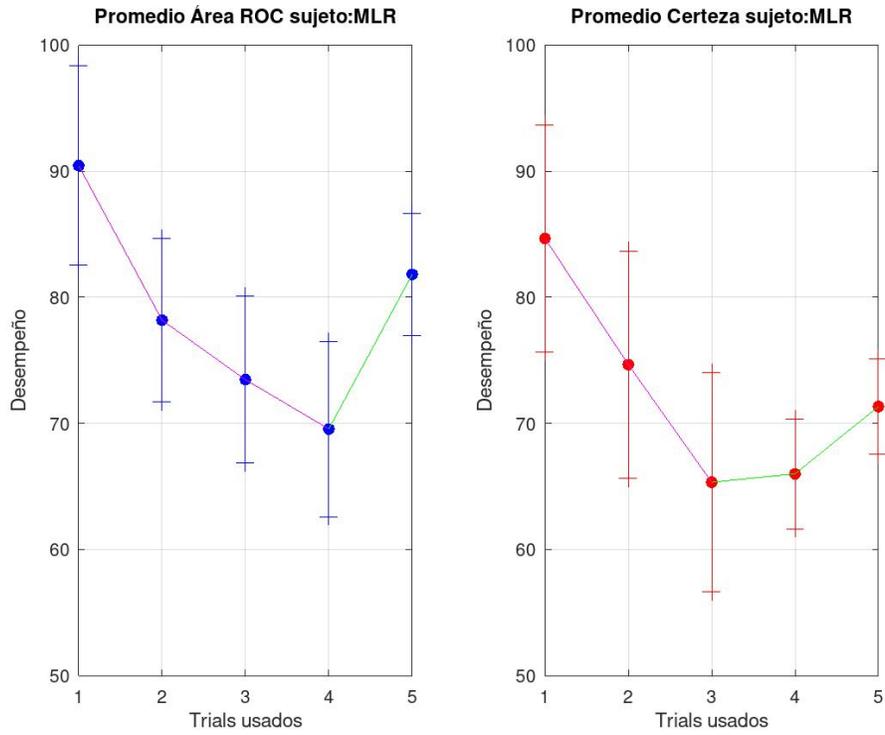


Figura A.25: Desempeño del clasificador para el sujeto MLR.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
MLR	1	90.44 % \pm 7.91	84.67 % \pm 9.01	3.3e+04	0.0034
	2	78.18 % \pm 6.46	74.67 % \pm 9.01	2.9e+04	0.00012
	3	73.47 % \pm 6.61	65.33 % \pm 8.69	0.57	2
	4	69.56 % \pm 6.96	66.00 % \pm 4.35	42	0.009
	5	81.82 % \pm 4.84	71.33 % \pm 3.80	2.9e+02	0.14

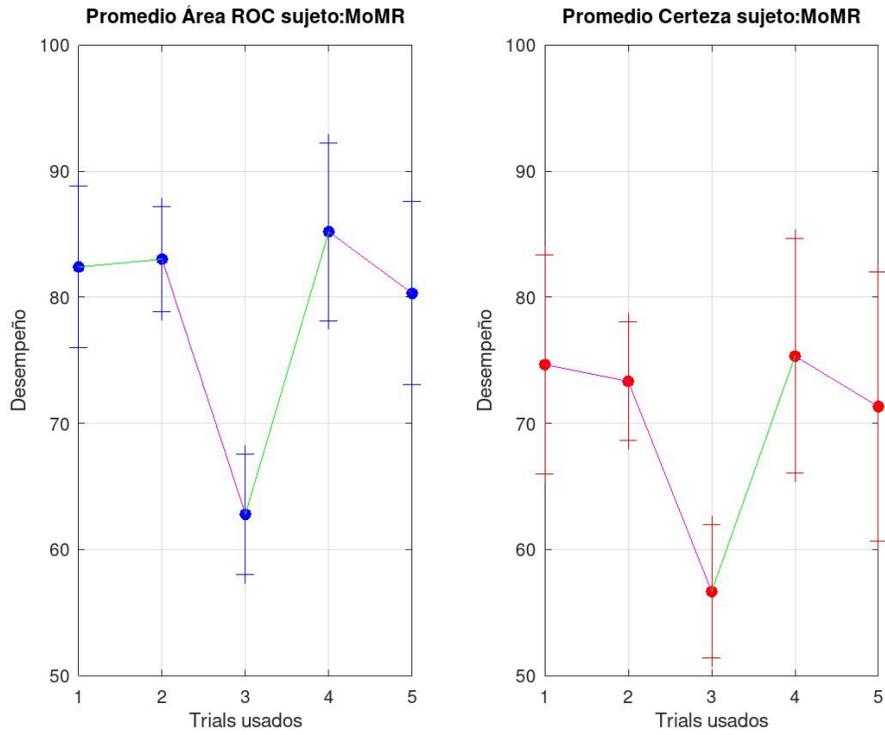


Figura A.26: Desempeño del clasificador para el sujeto MoMR.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
MoMR	1	82.40 % \pm 6.41	74.67 % \pm 8.69	14	11
	2	83.02 % \pm 4.14	73.33 % \pm 4.71	1.6e+04	0.024
	3	62.80 % \pm 4.78	56.67 % \pm 5.27	6.1	0.0034
	4	85.20 % \pm 7.06	75.33 % \pm 9.31	2.2e+04	0.031
	5	80.31 % \pm 7.27	71.33 % \pm 10.70	4.3e+04	0.00011

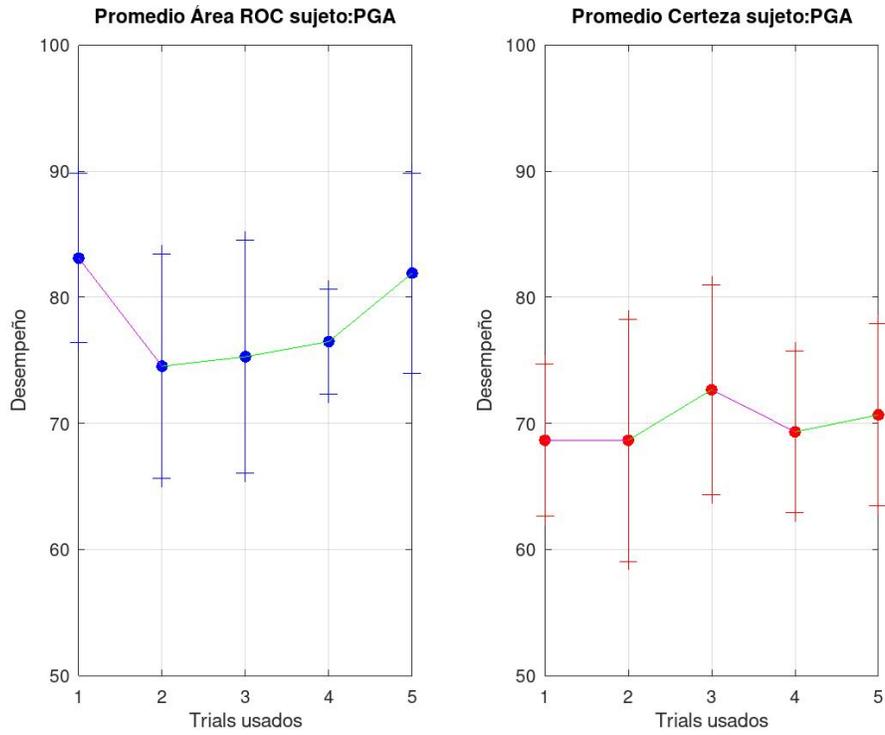


Figura A.27: Desempeño del clasificador para el sujeto PGA.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
PGA	1	83.11 % \pm 6.73	68.67 % \pm 6.06	0.19	6.1
	2	74.53 % \pm 8.90	68.67 % \pm 9.60	8.2e+03	0.00016
	3	75.29 % \pm 9.25	72.67 % \pm 8.30	4.5e+02	0.00043
	4	76.49 % \pm 4.16	69.33 % \pm 6.41	3.8e+04	0.00012
	5	81.91 % \pm 7.92	70.67 % \pm 7.23	6.2e+03	0.063

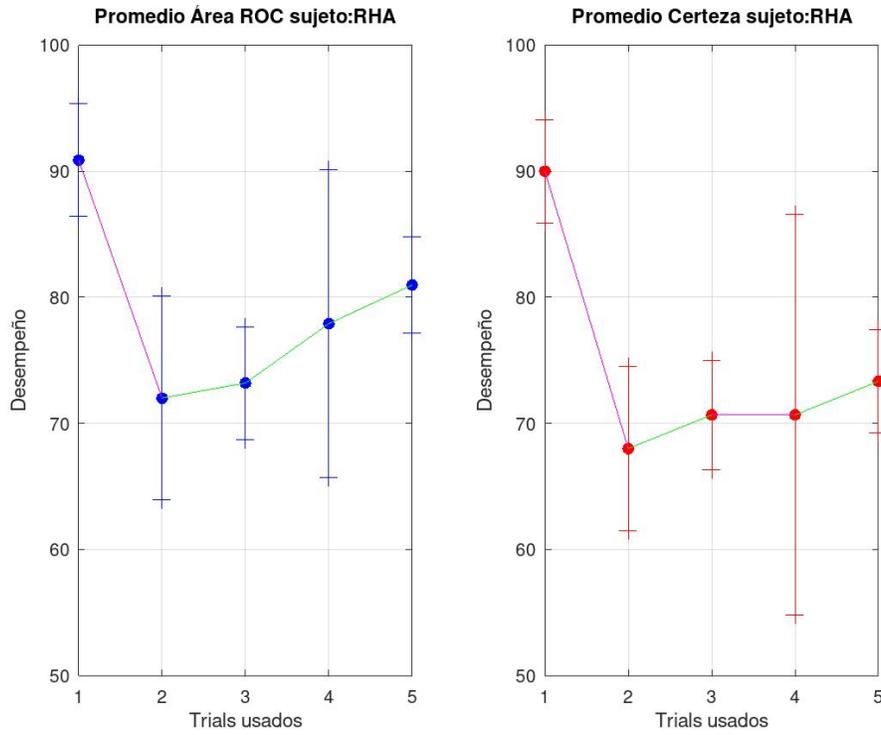


Figura A.28: Desempeño del clasificador para el sujeto RHA.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
RHA	1	90.89% \pm 4.45	90.00% \pm 4.08	2.9e+04	0.12
	2	72.00% \pm 8.07	68.00% \pm 6.50	32	0.063
	3	73.20% \pm 4.47	70.67% \pm 4.35	9.4e+03	0.00098
	4	77.91% \pm 12.23	70.67% \pm 15.88	1.4e+03	0.00098
	5	80.98% \pm 3.80	73.33% \pm 4.08	0.29	5.3

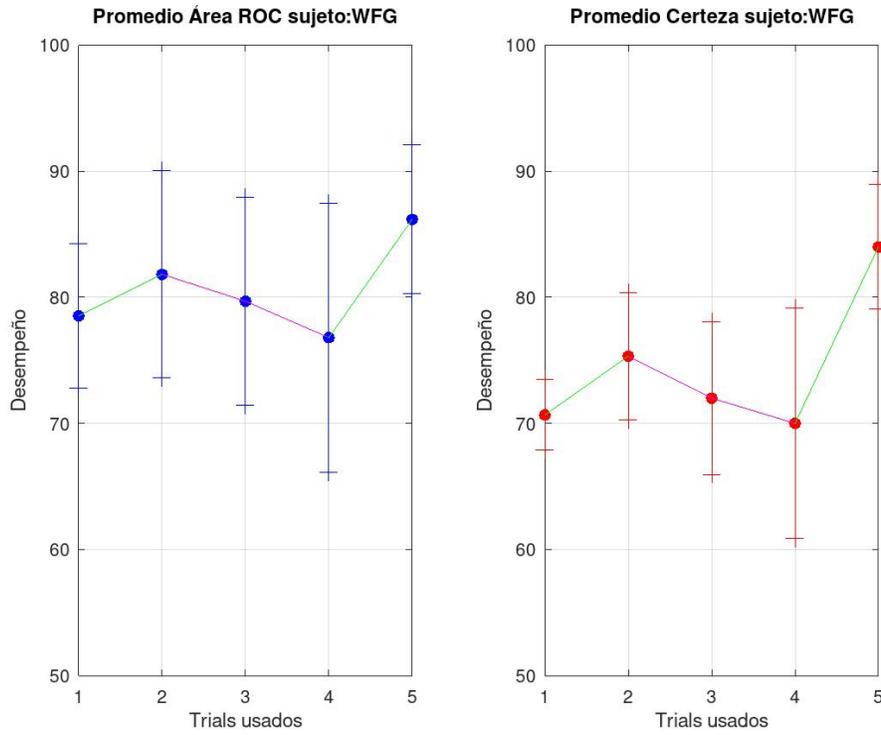


Figura A.29: Desempeño del clasificador para el sujeto WFG.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
WFG	1	78.53 % ±5.72	70.67 % ±2.79	1.3	7
	2	81.82 % ±8.20	75.33 % ±5.06	4.5e+02	1.1
	3	79.69 % ±8.24	72.00 % ±6.06	14	1
	4	76.80 % ±10.68	70.00 % ±9.13	0.054	1
	5	86.18 % ±5.89	84.00 % ±4.94	2.9e+02	0.082

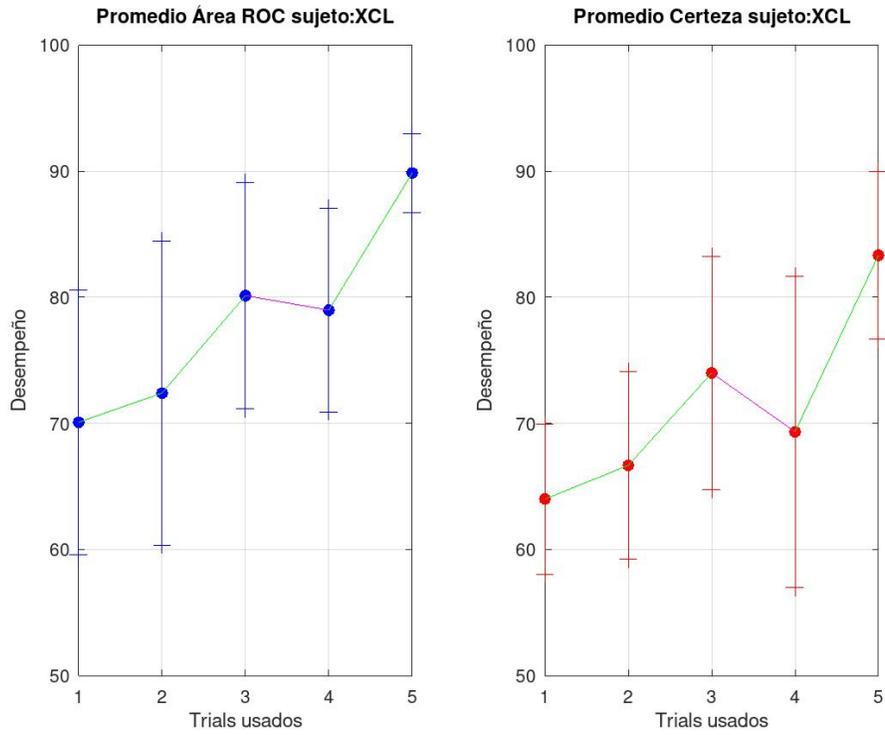


Figura A.30: Desempeño del clasificador para el sujeto XCL.

Resultados canales 1 y 2 (Fz y C4)					
Sujeto	Épocas utilizadas	AUC promedio	certeza promedio	C	γ
XCL	1	70.09 % \pm 10.49	64.00 % \pm 5.96	4	2.3
	2	72.40 % \pm 12.04	66.67 % \pm 7.45	56	0.072
	3	80.13 % \pm 8.97	74.00 % \pm 9.25	2e+03	0.047
	4	78.98 % \pm 8.06	69.33 % \pm 12.34	4.5e+02	0.082
	5	89.87 % \pm 3.14	83.33 % \pm 6.67	2.7e+03	0.072



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA

ACTA DE EXAMEN DE GRADO

No. 00134

Matrícula: 2151801117

Análisis de registros de EEG utilizando correlación canónica para optimización de tiempos en interfaces cerebro-computadora



Con base en la Legislación de la Universidad Autónoma Metropolitana, en la Ciudad de México se presentaron a las 15:00 horas del día 10 del mes de junio del año 2021 POR VÍA REMOTA ELECTRÓNICA,, los suscritos miembros del jurado designado por la Comisión del Posgrado:

DRA. VERONICA MEDINA BAÑUELOS
M. EN C. CLAUDIA IVETTE LEDESMA RAMIREZ
M. EN IB. OSCAR YAÑEZ SUAREZ

Bajo la Presidencia de la primera y con carácter de Secretario el último, se reunieron para proceder al Examen de Grado cuya denominación aparece al margen, para la obtención del grado de:

MAESTRO EN CIENCIAS (INGENIERIA BIOMEDICA)

DE: FELIPE DE JESUS GARCIDUEÑAS VARGAS

y de acuerdo con el artículo 78 fracción III del Reglamento de Estudios Superiores de la Universidad Autónoma Metropolitana, los miembros del jurado resolvieron:

FELIPE DE JESUS GARCIDUEÑAS VARGAS

ALUMNO

= APROBAR =

Acto continuo, la presidenta del jurado comunicó al interesado el resultado de la evaluación y, en caso aprobatorio, le fue tomada la protesta.

REVISÓ

MTRA. ROSALÍA SERRANO DE LA PAZ
DIRECTORA DE SISTEMAS ESCOLARES

DIRECTOR DE LA DIVISIÓN DE CBI

DR. JESUS ALBERTO OCHOA TAPIA

PRESIDENTA

DRA. VERONICA MEDINA BAÑUELOS

VOCAL

M. EN C. CLAUDIA IVETTE LEDESMA
RAMIREZ

SECRETARIO

M. EN IB. OSCAR YAÑEZ SUAREZ

El presente documento cuenta con la firma –autógrafa, escaneada o digital, según corresponda- del funcionario universitario competente, que certifica que las firmas que aparecen en esta acta – Temporal, digital o dictamen- son auténticas y las mismas que usan los c.c. profesores mencionados en ella