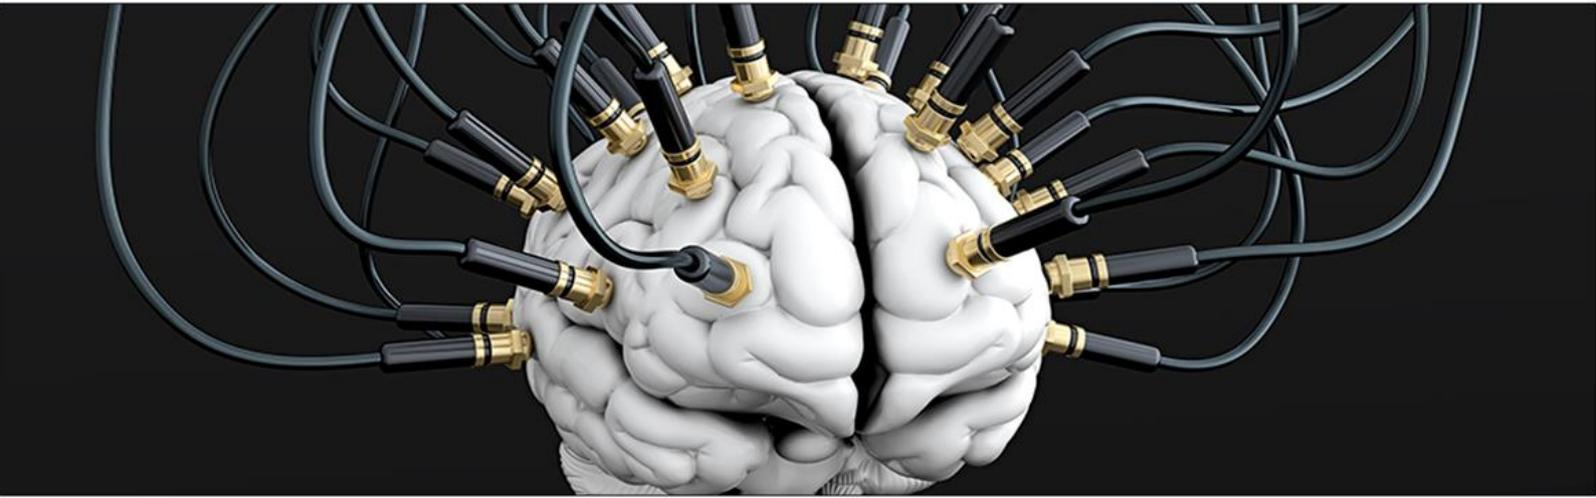


Maestría Profesional en Ciencia de Datos

INFORME FINAL



Implementación de *Analisis de Discriminante Lineal* para clasificación de movimientos de miembro superior en aplicaciones de Interfaces Cerebro Computadora

Baldezzari, Lucas

Fray Bentos, Uruguay

8 de Marzo de 2021

DECLARACIÓN DE AUTORÍA

Baldezari Lucas, Bioingeniero y estudiante en el Programa de Data Science de la Universidad Tecnológica de Uruguay, en calidad de autor del informe final presentado para la obtención del título de “Maestría Profesional en Ciencia de Datos”, titulado *“Implementación de Análisis de Discriminante Lineal para clasificación de movimientos de miembro superior para aplicación en Interfaces Cerebro Computadora”* y dirigida por el Dr. Bioingeniero Chelotti José Omar, DECLARO QUE:

- El presente informe final es una obra original que no infringe los derechos de propiedad intelectual ni los derechos de propiedad industrial de otras personas, de acuerdo con el ordenamiento jurídico vigente.
- Del mismo modo, asumo frente a la Universidad Tecnológica cualquier responsabilidad que pudiera derivarse de la autoría o falta de originalidad del contenido de la tesis presentada.
- En virtud del carácter curricular de esta obra, se reconoce el derecho de la Universidad Tecnológica de ejercer derechos de Propiedad Intelectual, de conformidad a su Ordenanza que regula estos derechos.



Bioingeniero BALDEZZARI Lucas
CI: 64388060
28 de febrero de 2021
Fray Bentos, Uruguay

AGRADECIMIENTOS

A Luciana, mi compañera, por su paciencia y apoyo incondicionales durante este proceso.

A Leonardo, por su confianza y constante enseñanza.

A la Universidad Tecnológica del Uruguay.

RESUMEN

Las Interfaces Cerebro Computadora (BCI) basadas en Imaginería Motora (MI) registran y monitorean la actividad eléctrica de las neuronas de una persona e intentan determinar la intención de movimiento para así controlar un dispositivo externo. Debido a esto, la correcta extracción de características de la señal que representen lo mejor posible la intención del usuario y una correcta clasificación de estas, son procesos críticos para asegurar una buena performance de la BCI. En el presente trabajo se procesó y clasificó las intenciones de movimientos sobre una base de datos de registros de electroencefalografía (EEG) de 15 sujetos voluntarios mientras llevaban a cabo tareas de MI. Se implementó un *Common Spatial Pattern* (CSP) para extraer las características de las señales y un *Linear Discriminant Analysis* (LDA) para clasificar las intenciones de movimiento. Los porcentajes de clasificación alcanzaron un promedio de $(63.46 \pm 8.31)\%$ para las clases *movimiento vs descanso*, llegando a máximos de 80%. Para el caso de las clases *movimiento vs movimiento* el porcentaje de clasificación promedio fue de $(63.41 \pm 9.12)\%$ llegando a un máximo de 83.4%.

Palabras claves: Brain Computer Interfaces, Linear Discriminant Analysis, Common Spatial Pattern.

Índice

DECLARACIÓN DE AUTORÍA	A
AGRADECIMIENTOS	B
RESUMEN	C
1. Introducción	2
2. Objetivos	3
2.1 Objetivo General	3
2.2 Objetivos específicos	3
3. Marco teórico	4
3.1 Introducción a las Interfaces Cerebro Computadora	4
3.1.1 Aplicaciones de una Interfaz cerebro computadora.	7
3.1.2 Transferencia de información en una Interfaz Cerebro Computadora	8
3.2 Potenciales ERD y ERS	9
3.3 Machine Learning aplicado a Interfaces Cerebro Computadora	11
3.3.1 Extracción de características	12
3.3.2 Métodos de Clasificación.....	14
4. Materiales y Métodos	15
4.1 Set de datos	15
4.2 Extracción de características y Clasificación.....	16
4.2.1 Pre procesamiento y preparación de datos	16
4.2.2 Extracción y selección de características mediante CSP	17
4.2.3 Clasificación utilizando LDA.....	18
5. Resultados	21
6. Discusión	27
7. Conclusiones	31
Bibliografía	34

I. Introducción

Las Interfaces Cerebro Computadora (BCI, del inglés *Brain Computer Interfaces*) son sistemas de comunicación que permiten a sus usuarios enviar mensajes o comandos para el control de un dispositivo utilizando solamente sus señales cerebrales [1]. Para operar una BCI, el usuario debe producir patrones de electroencefalografía (EEG) reconocibles, como pueden ser tareas mentales para mover un brazo, y el sistema debe reconocer, mediante procesamiento de señal y Machine Learning (ML) la intención del sujeto. Las BCI se estudian para aplicaciones de asistencia, diagnóstico, análisis de estados cognitivos y entretenimiento, entre otras.

Una BCI clasificarse en *evocada* y *espontanea* o en *exógena* y *endógenas*, respectivamente. Dentro del segundo grupo se encuentran las BCI basadas en Imaginería Motora (MI-BCI). Si una persona ejecuta o imagina el movimiento de un miembro o grupos musculares, generalmente genera cambios en aquellos ritmos cerebrales sobre la corteza sensoriomotora asociados a la tarea que se desea realizar produciéndose un decrecimiento típico en los ritmos *Mu* y *Beta* conocidos como *Desincronización Relacionada al Evento* (ERD del inglés *event related desynchronization*) seguido de una *Sincronización Relacionada al Evento* (ERS del inglés *event related synchronization*). Estos patrones pueden ser reconocibles aplicando técnicas de procesamiento y clasificación adecuadas.

Dentro de los bloques que conforman un sistema BCI se encuentran el bloque de Extracción de Características y el de Clasificación. El primero se utiliza para extraer aquellas características relevantes de las señales de EEG en la forma de un set de datos sobre los cuales se entrenará al clasificador. El bloque de clasificación permite discriminar entre una o más tareas mentales a través de las características otorgadas por el bloque de extracción de características.

Las señales de EEG utilizadas como set de datos en el presente informe corresponden a registros de EEG sobre 15 personas mientras realizaban tareas de imaginería motora asociadas a los movimientos *apertura de mano*, *cierre de mano*, *extensión de codo*, *flexión de codo*, *supinación de muñeca de mano*, *cierre de mano*, *extensión de codo*, *flexión de codo*, *supinación de muñeca* y *pronación de muñeca*. Los algoritmos de procesamiento, extracción de características, clasificación, graficación y análisis, fueron implementados en Python 3.8.

Para el bloque de extracción de características se implementó un Common Spatial Pattern (CSP), el cual es un tipo de filtro especial que permite aumentar las varianzas entre clases. Para la clasificación de los diferentes tipos de movimientos se implementó un clasificador del tipo Análisis de Discriminante Lineal (LDA) el cual es una herramienta de clasificación supervisada de variables cualitativas en la que dos o mas clases son conocidas a priori y aquellas nuevas observaciones se clasifican en alguno de estas clases en función de sus características.

Los porcentajes de clasificación alcanzaron un promedio de $(63.46 \pm 8.31)\%$ para las clases *movimiento vs descanso*, llegando a máximos de 80%. Para el caso de las clases *movimiento vs movimiento* el porcentaje de clasificación promedio fue de $(63.41 \pm 9.12)\%$ llegando a un máximo de 83.4%.

2. Objetivos

2.1 Objetivo General

Implementar un algoritmo para clasificación de movimientos de miembro superior utilizando señales de Electroencefalografía para ser utilizados en una Interfaz Cerebro Computadora.

2.2 Objetivos específicos

- Implementar un algoritmo del tipo *Common Spatial Pattern* (CSP) para reconocimiento de patrones y un clasificador del tipo *Linear Discriminant Analysis* (LDA).
- Entrenar el LDA utilizando una base de datos de señales de electroencefalografía adquiridas durante el desarrollo de tareas de Imaginería Motora.
- Utilizar el LDA con un set de datos de señales de electroencefalografía adquiridas durante el desarrollo de tareas de Imaginería Motora y medir su performance.

3. Marco teórico

3.1 Introducción a las Interfaces Cerebro Computadora

Las Interfaces Cerebro Computadora (BCI, del inglés *Brain Computer Interfaces*) son sistemas de comunicación que permiten a sus usuarios enviar mensajes o comandos para el control de un dispositivo utilizando solamente sus señales cerebrales [1]. Al día de hoy, la actividad eléctrica de las neuronas es usualmente adquirida y registrada mediante Electroencefalografía (EEG) y posteriormente procesadas por la BCI. El EEG es una técnica no invasiva, de bajo costo y de fácil implementación con los equipos disponibles. Por otro lado, la señal de EEG posee una muy buena resolución temporal y el costo-beneficio es alto comparado con otras técnicas para registrar la actividad eléctrica cerebral, como puede ser la Electroencefalografía (EEG) la cual es una técnica invasiva y de mayor complejidad de implementación que el EEG. Por otro lado, es posible monitorear cambios hemodinámicos que se suceden en las neuronas debido a la liberación de glucosa y oxígeno en el torrente sanguíneo para activar regiones neuronales específicas, las cuales luego crean gradientes de oxihemoglobina y desoxihemoglobina. Estos cambios pueden ser registrados mediante técnicas de neuroimágenes como la Resonancia Magnética Funcional (fMRI del inglés *Functional Magnetic Resonance Imaging*) o la Espectroscopía Infrarroja (NIRS del inglés *Near Infrared Spectroscopy*), debido a que los cambios hemodinámicos son producto de la actividad electrofisiológica de las células nerviosas, estos están indirectamente relacionados a la actividad neuronal [2]. A pesar de las ventajas de la electroencefalografía, la señal de EEG presenta retos desde el punto de vista de su procesamiento, ya que son señales no estacionarias, de baja resolución espacial y susceptibles de ser afectadas por ruidos externos y generación de artefactos sobre la señal [3].

Una BCI es la unión de dos procesos fundamentales, adquisición de señal y procesamiento de señal. En lo que respecta a la etapa de adquisición de señales mediante EEG, es importante la correcta colocación de los electrodos sobre el cuero cabelludo del usuario y la frecuencia de muestreo del sistema. Por otro lado, la etapa de procesamiento de señal implica el preprocesamiento de la señal, la extracción de características, clasificación de patrones y la traducción de estados mentales a mensajes o comandos para la aplicación de la BCI. El objetivo principal del preprocesamiento es reducir el ruido que pudiese contaminar la señal de EEG, usualmente aplicando filtros espaciales. La etapa de extracción de características hace hincapié en encontrar los principales patrones que diferencien tareas mentales – por ejemplo, supinación o pronación de una mano – las cuales son posteriormente sometidas a una selección para mejorar la búsqueda y reconocimiento de patrones característicos de la señal de EEG para un usuario en particular. Finalmente, las características principales del EEG son sometidas a un clasificador el cual alimenta un bloque de traducción para que la BCI lleve a cabo alguna acción [2]. La figura 1 muestra un diagrama de bloques de una Interfaz Cerebro Computadora.

Una BCI, como su nombre indica, requiere la interacción de dos componentes: las señales cerebrales de una persona y una computadora o dispositivo electrónico. En particular, para operar una BCI, el usuario debe producir patrones de EEG reconocibles, como pueden ser tareas mentales para mover un brazo, y el sistema debe reconocer, mediante procesamiento de señal y Machine Learning (ML) la intención del sujeto. Hasta ahora, para lograr una BCI confiable y lo suficientemente robusta para su uso, la mayoría de las investigaciones se enfocan en el procesamiento de la señal de EEG y los algoritmos de ML en busca de lograr una mejor performance y confianza por parte del usuario a la hora de utilizar la BCI[4].

Para que una BCI sea realmente utilizable y útil, es necesario que los diferentes patrones del EEG sean claros, estables y reconocibles. De hecho, el control de una BCI es una habilidad que debe ser aprendida y controlada por el usuario, además, los algoritmos de ML encargados del reconocimiento de patrones deben ser reentrenados con el tiempo para adaptarse a los posibles cambios en las características de la señal del usuario debido al uso e interacción entre la BCI y el sujeto[1]. Esto quiere decir que, la performance de la BCI mejora a medida que el usuario se entrena y qué, el usuario necesita aprender como producir señales claras, estables y reconocibles para controlar exitosamente la BCI[5]. La dificultad para lograr un adecuado control de la BCI dependerá de varios factores, entre estos, la capacidad cognitiva del sujeto para entender y llevar a cabo las indicaciones del uso de la interfaz y del tipo de tarea requerida para el control y comando del dispositivo, ya que como veremos, existen diferentes aplicaciones de una BCI.

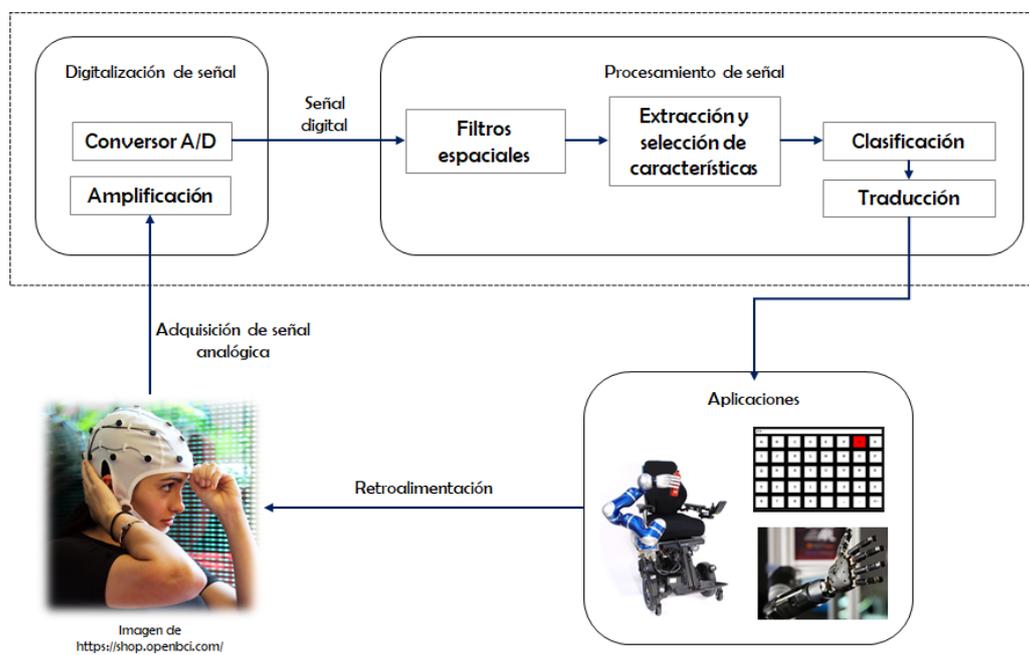


Figura 1: Diagrama de bloques de una Interfaz Cerebro Computadora. Adaptado de [2] y [8].

Las Interfaces Cerebro Computadora pueden ser clasificadas en *evocadas* y *espontaneas* [6]. Otros autores se refieren a éstas como *exógenas* y *endógenas*, respectivamente [7]. En las BCIs evocadas se hace uso de estímulos externos visuales, auditivos, somatosensoriales o combinación de estos. Estos estímulos generan respuestas en la actividad cerebral que son identificables por la BCI con el objetivo de llevar a cabo alguna acción. Dentro de este tipo de BCI podemos mencionar las que utilizan Potenciales Evocados del tipo P300 o los Potenciales Evocados Visuales de Estado Estacionario (SSVEP del inglés “*Stationary State Visual Evoked Potentials*”) que han demostrado ser útiles, entre otros casos, para el uso de deletreadores o control de sillas de ruedas robotizadas, ejemplos de estas BCI son [8] [9] y [10]. En las BCIs espontáneos no se necesitan estímulos externos, debido a que los comandos y acciones llevadas a cabo por el sistema son obtenidos directamente de la actividad mental de la persona. Ejemplos de este tipo de BCI son las Interfaces Cerebro Computadora por Imaginería Motora (MI-BCI del inglés “*Motor Imagery - Brain Computer Interfaces*”), en estas, el usuario tiene la tarea de imaginar que realiza alguna acción -como mover un miembro- y la BCI debe interpretar dicha intención, ejemplos de estos son los trabajos de [11] [12] y [13]. La MI es una habilidad

cognitiva que permite a un individuo realizar y experimentar acciones motoras, mentalmente, sin realizar la ejecución del movimiento en sí misma, es decir, sin activar ningún grupo muscular [14].

De manera similar es posible categorizar a las BCI en *activas, reactivas y pasivas* [15]. En una BCI del tipo activa, los comandos o salidas del sistema se controlan mediante la actividad cerebral, la cual es directamente y conscientemente controlada por el usuario, sin la necesidad de utilizar eventos o estímulos externos para generar patrones cerebrales reconocibles. Por otro lado, en una BCI reactiva es necesario algún tipo de estímulo externo para generar patrones reconocibles en la actividad cerebral del sujeto. Finalmente, en las BCI pasivas los comandos o salidas de la interfaz son producto de información implícita en los estados mentales del usuario, los cuales surgen arbitrariamente sin el propósito de control voluntario por parte del sujeto, estas BCI se utilizan, entre otras cosas, para el monitoreo cognitivo del sujeto, dando información, por ejemplo, de su estado emocional.

La tabla 1 muestra algunos ejemplos de los tipos de BCIs mencionadas y sus aplicaciones. Adaptado de [11].

Tabla 1: Ejemplos de Interfaces Cerebro Computadora evocadas y espontaneas. Adaptado de [11].

Tipo	Clase	Aplicación	Funcionamiento	Num Vol.	Promedio Clasificación	ITR
Evocada	VEP	Deletreador usando SSEVP	Los voluntarios enfocaban su vista a uno de los 30 estímulos visuales parpadeantes asociado a la tarea a realizar.	32	90,81%	35,78 bpm
	ERP	Deletreador usando P300 visuales	Los voluntarios debían enfocar su vista a uno de los caracteres que quería deletrear. Se utilizó un paradigma <i>odd-ball</i> para realizar la estimulación y así generar potenciales evocados P300.	15	69,28%	20,9 bpm
		Deletreador usando P300 auditivos	Se utilizaron señales auditivas espaciales en vez de estímulos visuales para generar P300.	21	86,1%	5,26 bpm
Espontanea	N/A	Imaginería Motora para control de exoesqueleto	Control de un exoesqueleto de miembro superior utilizando tareas mentales de movimiento de mano izquierda o mano derecha.	4	84,29%	NA

ITR: Tasa de transferencia de información, se mide en "bits por minuto". ERP: Event Related Potentials. VEP: Potenciales Evocados Visuales. SSVEP: Potenciales Evocados de Estado Estacionario.

La decisión entre usar un sistema evocado o exógeno no siempre es clara, ya que se debe tomar en consideración las fortalezas y debilidades del enfoque. Por ejemplo, en las BCIs evocadas, los resultados de comando, control y/o comunicación suelen dar mejores resultados comparados con los sistemas endógenos. En los primeros se requieren menores cantidades de sensores, menos horas de entrenamiento y pueden ser dominados por gran número de sujetos, sin embargo, en los segundos se requiere una gran cantidad de horas de entrenamiento por parte del sujeto para lograr dominar y utilizar la BCI, motivo por el cual no todos lo logran. Finalmente, los sistemas exógenos sí o sí requieren de una estimulación externa y tienden a ser agotadores para el usuario, ya que deben enfocarse y prestar atención a éstos por períodos de tiempo extensos, por otro lado, la ventaja de los sistemas endógenos es que no requieren de ningún tipo de estímulo exterior.

Las Interfaces Cerebro Computadora son utilizadas en cuatro grandes áreas, a saber, asistencia para pacientes con severas discapacidades motrices, diagnóstico de desórdenes de consciencia (DOC del inglés *disorders of consciousness*), entretenimiento y reconocimiento de estados cognitivos.

3.1.1 Aplicaciones de una Interfaz cerebro computadora.

I. Asistencia: Las aplicaciones de asistencia están mayormente dirigidas a pacientes que se encuentran en una condición llamada “síndrome de enclaustramiento” (LIS¹ del inglés *locked-in syndrome*) o en condición de pseudo coma, de hecho, las BCI surgen con la intención de ser una alternativa para mejorar la condición de vida de personas con LIS. El síndrome de enclaustramiento puede dividirse, según la severidad y extensión de la falta de movilidad y control muscular, en “clásico”, “incompleto” y “total” [16]. El primero se caracteriza por una inmovilidad completa de la musculatura voluntaria a excepción de movimientos oculares verticales y cierto control de parpadeo, las personas con LIS incompletos poseen algún control de su musculatura y finalmente, las personas con LIS total carecen de cualquier control voluntario sobre su musculatura, incluyendo movimientos oculares, razón por la cual se dice que estas personas están “atrapadas” en sus cuerpos.

Las causas comunes de LIS son los accidentes cerebrovasculares, daños físicos y enfermedades degenerativas del sistema nervioso -tales como la Esclerosis Lateral Amiotrófica (ELA)-. Si bien la principal etiología del síndrome de enclaustramiento es alguna patología vascular, la LIS puede ser también a causa de tumores cerebrales, encefalitis, reacciones inmunológicas a vacunas e hipoglicemia prolongada [17]. Con cuidados médicos adecuados, la mayoría de los pacientes pueden retornar a sus casas y sus expectativas de vida pueden superar los 10 años en el 83% de los casos y los 20 años de vida en el 40% de los casos [17].

Por lo tanto, cualquier chance de devolver cierta independencia a personas con LIS crónicos, aún de manera limitada, puede ser una enorme mejora en su calidad de vida. En muchos casos, profesionales médicos y personas sin este tipo de trastornos asumen que pacientes con LIS no desean vivir en esas condiciones, sin embargo, muy por el contrario, en aquellos casos donde pacientes crónicos de LIS han podido comunicarse, su demanda de eutanasia es sorprendentemente infrecuente [2].

II. Diagnóstico: En muchos casos es deseable detectar una condición previa al coma o bien confirmarla. De hecho, el diagnóstico erróneo de “estado vegetativo” (VS del inglés *vegetative state*) versus “estado de consciencia mínima” (MCS del inglés *minimally conscious state*) es de alrededor del 40% [2]. Las Interfaces Cerebro Computadora están cobrando relevancia en este campo ya que permitirían mejorar el diagnóstico de DOC [17][18][19], lo cual es de suma importancia, ya que, si un paciente es declarado en estado vegetativo de manera permanente, se presentan cuestiones éticas, morales y legales acerca de si se debe o no continuar con el tratamiento, las cuales son difíciles de resolver.

Luego de un accidente cerebro vascular (ACV) o algún trauma, el paciente puede entrar en coma, el cual es un estado temporal o bien puede evolucionar a muerte cerebral, VS o LIS -en los menores de los casos-. La muerte cerebral es el estado que mejor es diagnosticado utilizando EEG. Muchos países poseen sus propias guías para dar diagnóstico de esta condición, en el caso de Uruguay el documento oficial es el llamado “Actualización de Consenso de Muerte Encefálica en Adultos” [20]. Los estudios basados en EEG para el diagnóstico de muerte cerebral tienen una sensibilidad y una especificidad del 90% [21].

Las BCI han demostrado ser útiles para lograr detectar cierta consciencia en pacientes comatosos, por ejemplo, sería posible que pacientes con DOC puedan modular su actividad cerebral para responder “sí” o

¹ El síndrome de enclaustramiento o LIS fue definido por primera vez en 1966 por Freud Plum y Jerome Posner para describir cuadriplejía y anartria producidas por daño de médula espinal y vías corticobulbares del sistema nervioso central, respectivamente, en accidentes con daños en el tronco encefálico.

“no” a preguntas simples, aún sin haber detectado alguna señal o signo de consciencia desde un punto de vista físico [22].

Las BCI del tipo “single switch” o (ssBCI del inglés *single switch BCI*) es un paradigma que esta empezando a cobrar relevancia ya que permitiría mejorar el diagnóstico entre un estado VS o MCS. Las ssBCI son sistemas que operan con solo dos estados mentales para permitir respuestas del tipo “sí – no”, de esta manera, un usuario entrenado podría llevar a cabo una tarea mental para generar patrones que permitan ser identificados como sí y la ausencia de dicha tarea mental, ser utilizado como un no [23][24]. Este simple, pero poderoso enfoque podría ser utilizado para detectar niveles de consciencia en pacientes comatosos. De hecho, el proyecto llamado “EU Decoder” (2010 – 2013) [25] condujo estudios utilizando ssBCI para la detección de consciencia en pacientes en estado de coma y así mejorar el diagnóstico de DOC.

- III. Estados cognitivos: Las interfaces cerebro computadora del tipo “afectivas” (aBCI del inglés *affective brain computer interfaces*) son sistemas que permiten monitorear los estados mentales de una persona. Este tipo de dispositivos es una rama de la ciencia de la computación originada en 1995 relacionada con el estudio y desarrollo de dispositivos capaces de reconocer, interpretar, procesar y estimular emociones humanas [2]. Las aBCI buscan realizar, entre otras cosas, un reconocimiento del estado de atención o fatiga que podría tener un usuario luego de varias horas de uso de una BCI, como podría ser el caso de una interfaz para el control de una silla de ruedas robóticas en donde el sujeto debía enfocar su atención a los comandos que quisiera utilizar para movilizarse [10][26]. En el caso de entretenimiento, las BCI podrían monitorear y cuantificar cuan “enfocado” o “entretenido” esta el usuario durante el juego.
- IV. Entretenimiento: Una rama reciente en el uso de las BCI es para la industria de los video juegos. En estos, las BCI cumplen roles tales como monitorear y cuantificar el nivel de concentración del usuario durante la sesión de juego o bien de llevar a cabo acciones en el juego mismo, utilizando solamente sus señales cerebrales, ejemplo de esto es el Alpha-World of Warcraft (alphaWOW) que, mediante el registro de EEG sobre el lóbulo parietal, se monitorean los ritmos cerebrales Alpha, los cuales son utilizados para llevar a cabo algunas acciones sobre el personaje del juego [27].

3.1.2 Transferencia de información en una Interfaz Cerebro Computadora

Las Interfaces Cerebro Computadora basadas en EEG son, desde su concepción, sumamente prometedoras, ya que posibilitarían, sin ningún tipo de actividad física, controlar tecnologías asistivas -como utilizar teclados en una pantalla, controlar una silla de ruedas robotizada, controlar una prótesis robótica, entre otras- por personas con severas discapacidades motrices [28] o bien ser utilizadas como tecnología de rehabilitación para aquellos pacientes que hayan sufrido, por ejemplo, un accidente cerebro vascular [29]. A pesar del prometedor potencial de las BCI, tales aplicaciones son raramente vistas fuera de laboratorios de investigación. Las principales razones por las cuales las BCI aún no forman parte de nuestra vida cotidiana son, falta de confiabilidad y solidez para llevar a cabo las tareas deseadas [30][31]. Particularmente, las BCI suelen tener una alta tasa de fallas para reconocer correctamente los comandos mentales de los usuarios, sobre todo en las MI-BCI. Como ejemplo, se puede mencionar un estudio realizado sobre 80 personas voluntarias, en donde el promedio de precisión en la clasificación fue solamente 74,4% para una BCI usando solamente dos comandos controlados por imaginación motora [32], si bien existen otros estudios donde se alcanzan mejores resultados, poseen costos computacionales elevados [33][34]. Por otro lado, se estima que dependiendo de la BCI, entre un 10% a 30% de los usuarios no podrán controlar el sistema, problema conocido como *Interfaz Cerebro Computadora Deficiente* [4].

Como se ha mencionado, un inconveniente a tener en cuenta a la hora de implementar una BCI es su eficiencia en traducir las intenciones del usuario en acciones correctas, y, por otro lado, cómo cuantizar dicha performance. Algunas formas de contabilizar la eficiencia de una BCI son, la *precisión de la clasificación*, *tasa de falsos positivos* (FPR del inglés *false positive rate*), *tasa de verdaderos positivos* (TPR del inglés *true positive rate*) y la *tasa de transferencia de información* (ITR del inglés *information transfer rate*) [35][36][37].

La *precisión de clasificación* es simplemente el porcentaje de comandos correctamente clasificados por la BCI.

El *FRP* hace referencia a la tasa de comandos incorrectamente clasificados, mientras que el *TRP* se refiere a la tasa de comandos correctamente clasificados, sus expresiones son,

$$TPR = \frac{TP}{TP + FN} \quad (1), \quad FPR = \frac{FP}{FP + TN} \quad (2)$$

Donde *FN* y *TN* indican el número de falsos negativos y verdaderos negativos, respectivamente. Por otro lado, *FP* y *TP* representan el número de falsos positivos y de verdaderos positivos, respectivamente.

En estadística, cuando se realizan múltiples comparaciones, el *FPR* es

La tasa de transferencia de información, o *ITR*, es una medida estándar de la cantidad de información transferida por unidad de tiempo, la cual se define como,

$$ITR_{Wolpaw} = s \left[\log_2(N) + p \log_2(p) + (1 + p) \log_2 \left(\frac{1 - p}{N - 1} \right) \right] \quad (3)$$

Donde *N* es el número de comandos, *p* es la precisión de clasificación, y *s* es el número de comandos ejecutados por minuto. De la ecuación (2) podemos notar que mientras más alta sea *p*, mayor será la *ITR*.

3.2 Potenciales ERD y ERS

Como se ha mencionado, una de las formas de controlar una interfaz cerebro computadora es reconociendo patrones cerebrales mientras el usuario realiza alguna tarea mental, paradigma conocido como Imaginería Motora (MI). La MI requiere que el usuario *imagine* el movimiento de algún miembro. Este tipo de BCI monitorea los ritmos cerebrales provenientes de las regiones sensoriomotoras del cerebro (SMRs del inglés *sensorimotor rhythms*), los cuales son eventos oscilatorios en la señal de EEG y originados en las áreas asociadas con la preparación, control y ejecución de un movimiento voluntario [38][39].

La actividad cerebral registrada por el EEG puede ser clasificada, considerando su frecuencia de oscilación en el tiempo de cinco formas [2], las cuales son,

- Ritmos *delta*: Frecuencia entre 1Hz a 4Hz.
- Ritmos *theta*: Frecuencia entre 4Hz a 8Hz.
- Ritmos alfa: Frecuencia entre 8Hz a 13Hz.
- Ritmos beta: Frecuencia entre 14Hz a 30Hz.
- Ritmos gamma: Frecuencia entre los 25Hz a 100Hz.

Los cambios de amplitud en el espectro de frecuencias de las bandas *Mu* y *Beta* del EEG son utilizadas para identificar tareas de MI que se desean ejecutar o que están siendo ejecutadas [38][39]. Otros estudios plantean que los cambios de potencia en las bandas *Delta*, también poseen información acerca de las

intenciones de movimiento que una persona desea realizar y por lo tanto, podrían ser utilizadas para el control de una BCI [40].

Si una persona ejecuta o imagina el movimiento de un miembro o grupos musculares, generalmente genera cambios en aquellos ritmos cerebrales sobre la corteza sensoriomotora asociados a la tarea que se desea realizar. Cuando la población de neuronas asociadas al movimiento que la persona pretende llevar a cabo son activadas, existe un decrecimiento típico en los ritmos *Mu* y *Beta* conocidos como *Desincronización Relacionada al Evento* (ERD del inglés *event related desynchronization*) seguido de una *Sincronización Relacionada al Evento* (ERS del inglés *event related synchronization*). Esto tiene que ver al hecho de que cuando un grupo neuronal esta inactivo reciben señales provenientes del tálamo que las mantienen sincronizadas, así la suma de potenciales de estas neuronas provoca señales de EEG de gran amplitud. Por otro lado, cuando el mismo grupo neuronal es activado por estímulo o intención, pierden dicha sincronización, generando que la amplitud en la señal de EEG de este grupo neuronal decrezca, dando como resultado un ERD [2][41]. La figura 2 muestra un ejemplo de ritmos ERD/ERS obtenido a partir de un estudio realizado sobre nueve sujetos sanos que se les pidió que realicen algún tipo de movimiento de su mano derecha [42].

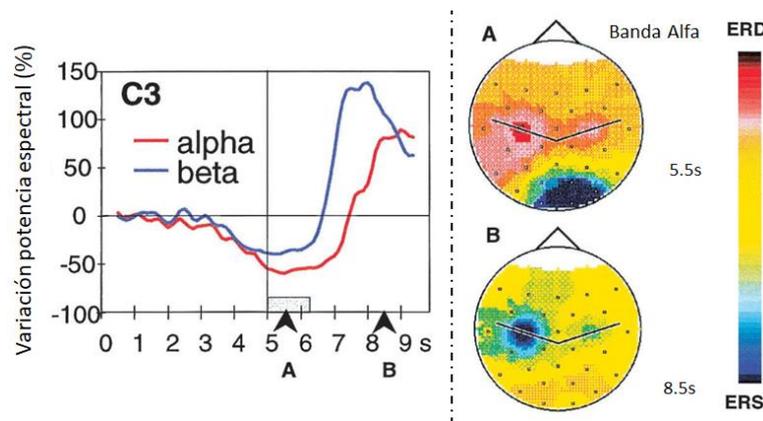


Figura 2: A la izquierda de la imagen se ven las curvas promedio (de 9 sujetos) calculadas en las bandas *alfa* y *beta* para la tarea de mover la mano derecha. El promedio fue calculado en ventanas de 125ms desde el inicio del movimiento -punto A- hasta la finalización del mismo -punto B-. La derecha de la imagen muestra la distribución topográfica de la variación de potencia para la banda alfa (adaptado de [42]).

Las características específicas de los patrones ERD/ERS los hacen relativamente fáciles para ser reconocidos luego de procesar las señales de EEG. Por otro lado, los ERD/ERS son las señales neurofisiológicas mayormente utilizadas dentro de las MI-BCI, las cuales sirven para discriminar movimientos imaginados de las manos derecha e izquierda, flexión del pie y tobillo, entre otras [36]. Avanzadas técnicas de procesamiento de señal y algoritmos de Machine Learning permiten reconocer estos patrones cerebrales con pocas sesiones de entrenamiento [41].

Es interesante resaltar que los ERD/ERS se producen tanto si se ejecuta el movimiento o se lo imagina, dando la posibilidad de que una persona en estado de LIS pueda llegar a controlar una BCI, con el entrenamiento adecuado, imaginando movimientos de sus miembros.

3.3 Machine Learning aplicado a Interfaces Cerebro Computadora

El diseño de una BCI confiable requiere, entre otras cosas, que el usuario sea entrenado correctamente, sobre todo en aquellos sistemas que utilizan MI-BCI. Existen dos metodologías o familias de entrenamiento bien diferenciadas para las MI-BCI, una es el enfoque de entrenar al usuario en el uso de la BCI y el otro es el enfoque de entrenar los algoritmos de Machine Learning (ML) [43]. Estos métodos difieren principalmente en que en el primero, el sujeto debe aprender a utilizar la BCI, adaptándose y aprendiendo de esta, sin embargo, en el enfoque ML, se hace hincapié en entrenar los algoritmos de clasificación y reconocimiento de patrones para mejorar el desempeño de la BCI. En ambos métodos es necesario dar una retroalimentación, tanto al usuario como al operador de la BCI. Generalmente esta retroalimentación es visual, indicando si la tarea mental fue reconocida por la BCI y también el nivel de confianza en la clasificación de dicha tarea. Un ejemplo de esto es el protocolo conocido como *Graz BCI* [44], en el cual los usuarios son instruidos en realizar movimientos kinestésicos² de sus manos izquierda o derecha a medida que observan una pantalla en donde se muestra una flecha que indica izquierda o derecha, respectivamente. Los usuarios reciben una retroalimentación visual en la forma de barra que se extiende en longitud hacia la izquierda o la derecha dependiendo si la tarea a realizar es mover la mano izquierda o derecha, respectivamente. La longitud de la barra es proporcional a la salida del clasificador [44].

Las Interfaces Cerebro Computadora controladas por Imaginería Motora (MI-BCI) son sistemas en investigación y desarrollo ampliamente expandidos debido a que las tareas mentales que una persona realiza para controlar la BCI son procesos naturales incorporados. Sin embargo, como se ha mencionado, no todas las personas son capaces de utilizar una BCI controlada por MI, además, el procesamiento necesario para reconocimiento de patrones en el EEG y su posterior clasificación es sumamente desafiante, a su vez, los enfoques de procesamiento y clasificación son complejos a lo que se suma que muchos de estos métodos sufren bajos promedios de clasificación debido a la inestabilidad de la señal de EEG [45], por lo tanto, la tarea de obtener una MI-BCI confiable es una atarea compleja de realizar, tanto por parte de usuario como de los operarios.

Como se comentó en la sección 3.1, las BCI poseen varios bloques constitutivos. No obstante, para la realización de este trabajo se hace hincapié en los bloques de extracción de características y su posterior clasificación.

Set de datos y protocolo de registro

La adquisición de datos para su posterior análisis es crítica para entrenar y testear los algoritmos de ML que serán utilizados en la BCI. Las variaciones principales entre un set de datos a otros son,

- i. Número de tareas de imaginería motora a realizar, usualmente cada tarea mental -por ejemplo, mover la mano izquierda o la derecha- es considerada *una clase*, la cantidad de clases puede ir desde dos hasta cuatro (o más aún).
- ii. Variación en el número de canales de EEG utilizados durante el estudio y aquellos utilizados para el procesamiento de datos. La cantidad de canales a procesar es de suma importancia desde un punto de

² Un movimiento kinestésico es el proceso mental en el cual una persona imagina un movimiento muscular hasta el punto de percibir que lo hace, pero sin realizarlo realmente. En general estos tipos de movimientos son logrados por personas especialmente entrenadas.

vista del impacto computacional requerido para llevar a cabo la BCI, a mayor cantidad de canales, mayor poder de procesamiento se requiere.

- iii. Variación en los tiempos de descanso que tienen los usuarios de la BCI entre una tarea mental y la otra.
- iv. Número de trials³ y sesiones de entrenamiento.
- v. Número de voluntarios en los que se realizaron los registros.
- vi. Si el set de datos es de acceso público o privado

Estos factores deben ser tenidos en cuenta a la hora de comparar diferentes estudios y/o algoritmos ya que tendrán impacto directo sobre los promedios de clasificación, y, por ende, sobre la performance de la BCI.

Extracción de características, selección de características y clasificación en MI-BCI

Los bloques de extracción de características, selección de características y clasificación tienen como objetivo fundamental capturar las particularidades relevantes de la señal de EEG las cuales serán utilizadas para la diferenciación entre estados mentales. Basado en la selección de características, el clasificador identifica el tipo de tarea mental que se está llevando a cabo por parte del usuario y genera una señal de control, la cual a su vez puede ser utilizada para la selección de un ícono o comando en una interfaz gráfica, o el control de una neuroprótesis. Los métodos de clasificación mencionados en la literatura incluyen Análisis de Discriminante Lineal (LDA del inglés *linear discriminant analysis*) [40][46][47][48], Máquinas de Soporte Vectorial [46][47][49], análisis k-nearest neighbor [6][46], regresión logística [50] y redes neuronales recurrentes (RNNs del inglés *recurrent neural networks*) [51]. La figura 3 muestra un resumen de las técnicas más utilizadas para extracción de características en BCI.

3.3.1 Extracción de características

El bloque de extracción de características es el procesamiento de señal realizado para extraer información discriminativa y no redundante del registro de EEG en la forma de un set de características sobre los cuales se entrenará al clasificador. Las técnicas básicas de extracción de características utilizan análisis en el dominio del tiempo o de las frecuencias. También se destacan las técnicas de análisis en tiempo-frecuencia, las cuales son procesos avanzados que permiten obtener información espectral relacionada con el tiempo. Finalmente, en el dominio espacial la técnica más utilizada es la de patrones espectrales comunes (CSP del inglés *common spatial patterns*).

3.3.1.1 Extracción en dominio del Tiempo y Dominio de la Frecuencia

Dentro de las técnicas en el dominio del tiempo se destaca el enfoque del Modelo de Autoregresión (AR Model del inglés *autoregressive model*). En este enfoque, el modelo AR es alimentado con segmentos del EEG lo que permite extraer un set de características [6]. Otro enfoque es el conocido como Modelo de Autoregresión Adaptativo (AAR del inglés *adaptive autoregressive modelling*) en el cual segmentos del EEG alimentan un modelo de regresión adaptativo. Los coeficientes que serán utilizados como características se obtienen de diferentes maneras utilizando, entre otras técnicas, mínimos cuadrados (*least squares*), medias de mínimos cuadrados (*least mean squares*) y filtros Kalman [52][53].

³ Palabra en inglés, que en el contexto de las BCI es utilizada para indicar la cantidad de veces que se ejecuta una tarea o conjunto de tareas en un determinado tiempo.

En el caso del dominio frecuencial la extracción de características se realiza analizando diferentes bandas espectrales. Dichas bandas se obtienen a partir de varias técnicas, siendo la más utilizada la Transformada Rápida de Fourier (FFT del inglés *fast Fourier transform*) [52]. Sin embargo, también se utiliza la transformada de Welch, la cual posee menos ruido en el espectro de frecuencias comparada con la FFT, pero a un costo de reducir la resolución frecuencial [47].

El análisis de características en el espacio de frecuencias es pobre, en el sentido de que no provee relación del contenido frecuencial a medida que la señal de EEG varía en el tiempo. Similarmente, el análisis basado solamente en el dominio temporal no posee información acerca del contenido espectral, la cual podría ser utilizada para clasificar.

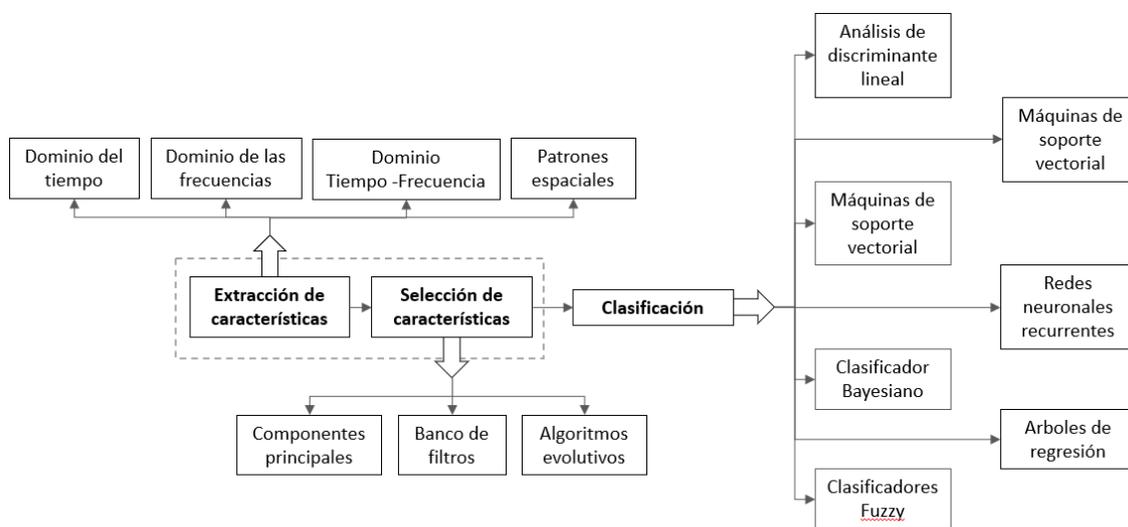


Figura 3: Diagrama que resume algunos métodos de extracción de características, selección de características y técnicas de clasificación para MI-BCI. Adaptado de [11].

3.3.1.2 Extracción en el dominio Tiempo-Frecuencia

El análisis de características en tiempo-frecuencia es sumamente poderoso ya que permite obtener información espectral relacionada con el dominio temporal, lo cual es una ventaja, debido a que el contenido espectral de la señal de EEG varía de una tarea mental a otra, y también luego de un tiempo de uso de la BCI [39]. Los métodos de extracción de características para MI-BCI bajo el enfoque tiempo-frecuencia incluyen la Transformada de Fourier en tiempo corto (STFT del inglés *short-time Fourier transform*) [54], la Transformada Wavlet (WT del inglés *Wavlet transform*) y la Transformada Wavlet Discreta (DWT el inglés *discrete Wavlet transform*) [55]. La descomposición de la señal en bandas frecuenciales a través de los métodos de STFT, WT y la DWT son de importancia, ya que diferentes bandas frecuenciales del EEG contienen diferente información acerca de la acción de imaginación motora llevada a cabo. Por otro lado, una ventaja de las técnicas WT y DWT es que ambas son mejores que la STFT para la extracción de características de señales dinámicas, lo cual es particularmente importante debido a la variabilidad temporal que posee la señal de EEG dada que son señales no estacionarias, no lineales y no Gaussianas [6].

Algunos trabajos utilizan DWT y análisis de envolvente para extraer las características de la señal, considerando que las señales bioeléctricas son moduladas en amplitud [51][56]. En estos trabajos se hace uso

de la Transformada de Hilbert (HT del inglés *Hilbert Transform*) y de la DWT para extraer características relacionadas a la modulación de amplitud y frecuencia presente en la señal de EEG. El primer paso fue descomponer la señal mediante DWT, con la envolvente de la señal se la descompuso en sub bandas obtenidas a partir de la HT. La información obtenida era sometida a un clasificador del tipo Red Neuronal de Memoria a Largo Plazo (LSTM RNN del inglés *long-term short-term memory RNN*) [51][56].

3.3.1.3 Common Spatial Pattern

El método Common Spatial Pattern (CSP) es una de las técnicas más utilizadas para extraer características de la señal de EEG. El CSP es un proceso matemático de filtrado *espacial* que transforma el espacio original de la señal de EEG a un nuevo espacio donde se busca que las varianzas entre dos clases se maximicen. Es una poderosa técnica para el procesamiento de MI-EEG ya que, las diferentes bandas frecuenciales del EEG contienen diferente información relacionada a la tarea mental en cuestión, y el CSP permite la extracción de información para una banda frecuencial en particular. No obstante, la extracción de características utilizando solamente CSP no es adecuada para la clasificación de MI-BCI de elevada performance, debido a que diferentes usuarios poseen diferencias en sus bandas frecuenciales, por lo tanto, la banda frecuencial óptima es específica de cada sujeto. Esto significa que, en el rango de frecuencias entre los 4Hz a los 40Hz -típicamente utilizados en MI-BCI- se procesará información redundante. La literatura establece que una forma de mejorar los resultados de la CSP es aplicar filtros en las bandas de interés [49][57][58].

En [47] se compara la performance de clasificación para tareas de MI cuando se usa CSP y Densidad Espectral de Potencia (PSD del inglés *power spectral density*) para la extracción de características. Luego, la salida de estos algoritmos alimentaba un clasificador del tipo LDA y SVM separadamente. El enfoque PSD demostró tener mejores resultados que el caso de CSP para clasificar clases del tipo MI mano derecha vs MI mano izquierda. La mejora puede deberse a la alta dimensionalidad obtenida con el PSD. Cuando se utilizó CSP para extraer características, los algoritmos LDA y SCM obtuvieron resultados de clasificación similares. Sin embargo, cuando se utilizó PSD, el clasificador por SVM obtuvo significativamente mejores resultados que el LDA.

3.3.2 Métodos de Clasificación

El bloque de clasificación permite discriminar entre una o más tareas mentales a través de las características otorgadas por el bloque de extracción y selección de éstas, finalmente, la salida del clasificador será introducida al bloque de traducción para obtener un comando o control para la BCI.

Los métodos de clasificación basados en SVMs y LDA son ampliamente utilizados dentro de la literatura para aplicaciones MI-BCI [46][47][48]. En general las SVM poseen mejores resultados de clasificación que otros métodos como LDA, $k - NN$, regresión logística y los arboles de regresión [46][47][48]. Los algoritmos de LDA poseen buenos promedios de clasificación cuando son utilizados con CSP y PSD como extractores de características [6].

El enfoque mediante $k - NN$ también ha sido utilizado como clasificador. Sin embargo, este método conlleva un alto costo computacional ya que el set de datos completo debe ser almacenado en memoria y procesado de una sola vez. De hecho, los LDA y las SVMs son consideradas mejores herramientas de clasificación comparadas con $k - NN$ ya que las primeras son un problema de optimización, por lo tanto, la solución óptima puede encontrarse de una manera global y en forma directa [59].

Arquitecturas de *Deep Learning* tales como las RNNs también son utilizadas como clasificadores. Algunos estudios muestran mejores resultados de clasificación mediante Redes Neuronales Convolucionales (CNN del inglés *convolutional neural network*) que LDA y SVM [11]. No obstante, deben llevarse a cabo trabajos futuros que comparen las precisiones de clasificación entre los métodos de Deep Learning con los SVM y LDA [11].

4. Materiales y Métodos

4.1 Set de datos

Para el presente trabajo se utilizó el set de datos número 25 titulado, *Upper limb movement decoding from EEG (001-2017)* [40] de acceso público y perteneciente al proyecto *BCI Horizon 2020* [60].

4.1.1 Paradigma de experimentación

El set de datos esta formado por el registro de EEG de 15 sujetos sanos con edades comprendidas entre los 22 a 44 años con una media de edad de 27 años y desvío estándar de 5 años. De estos, nueve sujetos eran de sexo femenino.

Los voluntarios se sentaron sobre una silla con sus brazos derechos soportados por un exoesqueleto con soporte anti gravedad para evitar fatiga muscular. Se registraron datos en dos sesiones. Entre cada sesión hubo un máximo de siete días de separación. La primera sesión consistió en movimientos ejecutados (ME), mientras que la segunda sesión consistió en movimientos imaginados (MI). Los movimientos/tareas-mentales que los sujetos debían realizar fueron de seis clases, más una clase de descanso donde no debían realizar ninguna acción. La tabla 2 muestra las diferentes clases de movimientos/tareas-mentales realizadas por los sujetos voluntarios.

Tabla 2: Clases de movimientos/tareas-mentales realizadas durante las sesiones de experimentación para los 15 sujetos voluntarios.

Clases	Acción	
	Sesión Movimientos Ejecutados	Sesión Movimientos Imaginados
Clase 1	Ejecutar flexión de codo	Imaginar flexión de codo
Clase 2	Ejecutar extensión de codo	Imaginar extensión de codo
Clase 3	Ejecutar supinación de muñeca	Imaginar supinación de muñeca
Clase 4	Ejecutar pronación de muñeca	Imaginar pronación de muñeca
Clase 5	Ejecutar cierra de mano	Imaginar cierra de mano
Clase 6	Ejecutar apertura de mano	Imaginar apertura de mano
Clase 7	Sin acción	Sin acción

La figura 4 muestra el protocolo de estimulación. En cada sesión los sujetos debían observar una pantalla con información referente a la tarea a realizar. Al segundo 0, un sonido del tipo *beep* era emitido y una *crux* aparecía en pantalla. Luego, transcurridos dos segundos, una terea era presentada sobre la pantalla de la computadora, indicando si debía realizarse una acción o bien descansar (sin acción). Al finalizar el trial, los sujetos volvían a su posición inicial. Se presentaron 6 clases de movimiento y una clase de descanso, se registraron 60 trials por cada clase en cada sesión.

4.1.2 Adquisición de datos

Las señales de EEG fueron registradas desde 61 canales con electrodos activos cubriendo las áreas frontales, centrales, temporales y parietales del cráneo utilizando un equipo de la marca "*g.tec medical engineering*

GmbH” [61]. Se utilizó un filtro pasa banda del tipo Chebyshev de 8vo orden entre los 0.01Hz a los 200Hz con una frecuencia de muestreo de 512Hz. El ruido de línea fue suprimido con un filtro notch a los 50Hz.



Figura 4: Secuencia de un trial. A tiempo cero un sonido (*beep*) era emitido y una cruz era presentada en pantalla indicando el inicio del trial. Transcurridos dos segundos, la tarea a realizar era presentada y el sujeto debía ejecutar/imaginar el movimiento solicitado o no realizar ninguno (*rest*). Al finalizar el trial, le seguía un tiempo de entre 2 – 3[seg] sin acciones.

Las señales registradas durante las sesiones de experimentación fueron comprimidas y almacenadas en archivos de formato GDF⁴ para cada sujeto, sesión y corrida.

4.2 Extracción de características y Clasificación

Los algoritmos de procesamiento, extracción de características, clasificación, graficación y análisis, fueron implementados en *Python 3.8* [62]. Entre los paquetes utilizados se destaca *MNE* [63], el cual es utilizado para explorar, visualizar y analizar datos neurofisiológicos (EEG, MEG, ECoG, etc). También se utilizaron diferentes dependencias como NumPY, SciPy, Matplotlib, entre otras.

Todos los procesos implementados descriptos a continuación han sido registrados en Github⁵. La dirección del repositorio figura en [64].

4.2.1 Pre procesamiento y preparación de datos

Reducción del ancho de banda

Cada una de las seis corridas, correspondiente a la sesión MI de cada sujeto fueron concatenadas, formando así una única corrida o señal general. A esta señal se le aplicó un filtro FIR pasa banda entre 1Hz y 20Hz para reducir el ancho de banda. La señal sin filtrar, las características del filtro y la señal filtrada para la sesión MI del sujeto 1 pueden verse en la figura 5.

Obtención de épocas

Una vez acotado el ancho de banda de la señal, se procedió a separar la misma en sus diferentes épocas constitutivas. Se entiende a una *época*, en el contexto del set de datos utilizado en este trabajo, cómo el período de la señal conformado por un conjunto de trials. Los archivos GDF contienen diferentes tipos de información referentes al registro de señales biomédicas, como, por ejemplo, los nombres de los canales de

⁴ El Formato de Datos Generales (GDF del inglés *general data format*) es un tipo de archivo para almacenar datos médicos y científicos.

⁵ GitHub es una plataforma de desarrollo colaborativo para alojar proyectos utilizando el sistema de control de versiones Git. Se utiliza principalmente para la creación de código fuente de programas de ordenador.

EEG utilizados, canales de EOG, identificadores de *eventos* -también llamados *marcadores* -, canales ruidosos, entre otros, que fueron anotados por los operadores durante y luego de las sesiones de experimentación.

De esta manera, para cada sujeto, se procedió a generar las épocas considerando siete clases a clasificar resumidas en la tabla 2. A su vez, todos los trials fueron obtenidos en una ventana de -2 segundos a 3 segundos respecto del inicio del evento de realizar una tarea.

La figura 6 muestra un ejemplo de las épocas obtenidas para los cinco primeros canales del EEG correspondiente a los eventos de flexión de codo y descanso del sujeto 1.

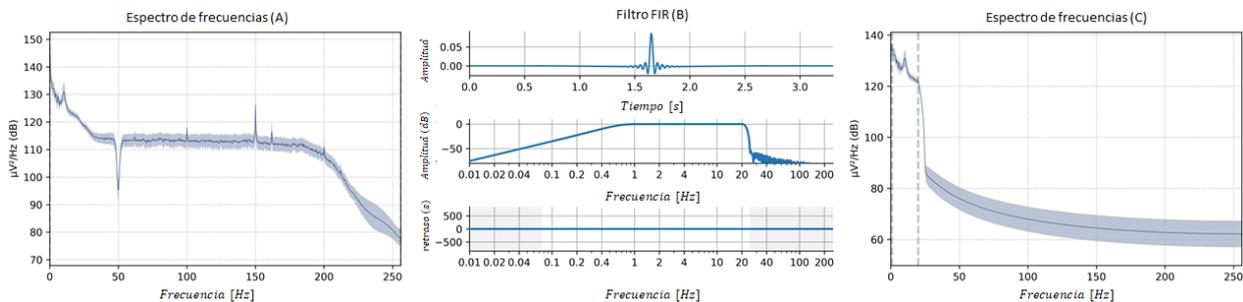


Figura 5: A) Promedio del espectro de frecuencia de los 61 canales de EEG. B) Características del filtro pasa banda aplicado a las señales a clasificar. C) Promedio del espectro de los 61 canales de EEG luego de aplicado el filtro B). Sujeto 1.

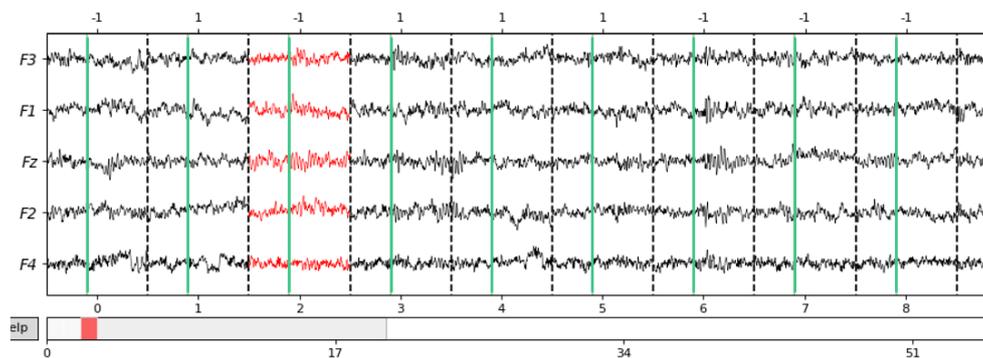


Figura 6: Épocas de EEG obtenidas a partir de los eventos de flexión codo (identificador -1) y descanso (identificador 1) para los cinco primeros canales del EEG. Las líneas verticales punteadas representan el inicio de un trial, mientras que las líneas verticales verdes representan el inicio de un evento. En rojo se resalta el trial número 2 para el evento -1, el cual se corresponde con la tarea de “descanso”.

Finalmente, se descartaron aquellas épocas donde la señal de EEG superaba los $\pm 200 \mu V$.

4.2.2 Extracción y selección de características mediante CSP

Para la extracción de características de las señales de EEG se implementó un método conocido con el nombre de Common Spatial Pattern (CSP).

Cuando una persona ejecuta o imagina el movimiento de un miembro, se produce un ERD seguido de un ERS, esto es, una atenuación seguido de un incremento de la actividad rítmica de cierto grupo neuronal asociado a dicha acción.

El algoritmo de CSP es un método de filtrado espacial ampliamente utilizado en MI-BCI, el cual es reconocido por su eficacia a la hora de detectar potenciales ERD y ERS. Asumiendo que tenemos dos clases, por ejemplo, *apertura mano (ape)* y *descanso (des)*, el CSP aplica un filtrado espacial que maximiza la relación entre las varianzas de las dos clases. Si llamamos Σ_{ape} y Σ_{des} a las matrices de covarianza de las clases apertura mano y descanso, respectivamente, las cuales se obtienen a partir de las relaciones en (4),

$$\Sigma_{ape} = \sum_{j \in C_{ape}} \frac{E_j * E_j^T}{\text{traza}(E_j * E_j^T)}, \quad \Sigma_{des} = \sum_{j \in C_{des}} \frac{E_j * E_j^T}{\text{traza}(E_j * E_j^T)} \quad (4)$$

Donde $E_j \in \mathbb{R}^{n \times m}$ es la matriz de datos de EEG correspondiente al *j-ésimo* trial, n es el número de canales, m es la cantidad de muestras en cada trial y C_{ape} y C_{des} son las clases apertura mano y descanso, respectivamente.

Para poder maximizar la diferencia entre las varianzas de cada clase, el CSP encuentra un filtro espacial dado por un vector $w \in \mathbb{R}^d$ que maximiza dicha diferencia. Una de las formas de lograr esto, es buscar la solución para un problema generalizado de autovalores y autovectores, dada por las siguientes relaciones,

$$w \Sigma_{ape} w^T = D, \quad w \Sigma_{des} w^T = I - D \quad (5)$$

Donde I es la matriz identidad y D es una matriz diagonal. A su vez, la matriz identidad debe cumplir con,

$$I = D_{ape} + D_{des}, \quad (6)$$

$$D_{ape} = w^T \Sigma_{ape} w, \quad D_{des} = w^T \Sigma_{des} w, \quad (7)$$

Con la relación (5) se puede encontrar una solución óptima para hallar una matriz W , llamada *matriz de transformación de CSP*, la cual esta conformada por el primer n y el último n del vector w , los cuales corresponden los valores máximo y mínimo de los autovalores obtenidos y ordenados [65].

Los datos de EEG fueron filtrados usando el filtro W de tal manera de resaltar aquellos canales con información relevante para detectar la tarea mental llevada a cabo por el sujeto.

Finalmente, la selección de las características de la señal de EEG para su posterior clasificación, fue realizada considerando aquellos dos canales de EEG, llamados **canales componentes**, que contenían la máxima diferencia de varianza entre las dos clases a clasificar.

4.2.3 Clasificación utilizando LDA

El Análisis de Discriminante Lineal (LDA) es una herramienta de clasificación *supervisada* de variables cualitativas en la que dos o mas clases son conocidas *a priori* y aquellas nuevas observaciones se clasifican en alguno de estas clases en función de sus características. En el contexto de una BCI, el LDA implica encontrar un umbral o *recta de decisión* dada por un vector y mas un *bias* b , de tal forma de que la evaluación de un trial u observación x , sea mayor o igual a y , así, se define si x pertenece o una u otra clase.

El LDA parte de la suposición de que las observaciones a clasificar poseen una distribución normal y se puede obtener la media y varianza de las mismas. Con esta información es posible aplicar el teorema de Bayes para calcular la probabilidad de pertenecer a una clase en particular.

El teorema de Bayes permite calcular la probabilidad condicional de un evento A dada la ocurrencia de un evento B aplicando la fórmula,

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}, \quad (8)$$

Bajo la suposición de que se desea clasificar los movimientos imaginados de, por ejemplo, $c_{apertura\ mano}$ vs $c_{descanso}$, lo que se requiere es asignar una observación \mathbf{x} , a una de estas dos clases c_i . Además, se parte de suponer que la probabilidad *a priori* de que la observación pertenezca a alguna de las clases c_i esta dada por la probabilidad $P(c_i)$, entonces, a partir del teorema de Bayes se establece que,

$$P(C = c_i | X = \mathbf{x}) = \frac{P(c_i)P(\mathbf{x}|c_i)}{\sum_{l=1}^{C=2} P(c_l)P(\mathbf{x}|c_l)} = \frac{\pi_i f_i(\mathbf{x})}{\sum_{l=1}^{C=2} \pi_l f_l(\mathbf{x})}, \quad (9)$$

En donde π_i es la *probabilidad a priori* de la clase c_i y $f_i(\mathbf{x})$ es la *función de distribución* de la observación \mathbf{x} dentro de la clase c_i . Se asume que $f_i(\mathbf{x}) = P(\mathbf{x}|c_i) \rightarrow \mathcal{N}(\mu_i, \Sigma_i)$.

La ecuación (9) puede interpretarse como,

$$P(\text{pertener a la clase } c_i \mid \text{observación } \mathbf{x}) = \frac{P(\text{pertener a la clase } c_i \text{ y observar } \mathbf{x})}{P(\text{observar } \mathbf{x})}$$

Debido a que el denominador de la ecuación (9), $\sum_{l=1}^{C=2} \pi_l f_l(\mathbf{x})$, es el mismo para las dos clases bajo estudio, la pertenencia de la observación \mathbf{x} , será asignada a la clase en donde se cumpla que $\pi_i f_i(\mathbf{x})$ sea mayor, es decir,

$$\mathbf{x} \text{ pertenece a la clase } c_i \Leftrightarrow P(c_i|\mathbf{x}) \geq P(c_l|\mathbf{x}), \forall i \neq l$$

Para poder aplicar la ecuación (9) es necesario conocer la distribución de probabilidad de que una observación cualquiera pertenezca a la clase π_i , y la distribución de probabilidad de que una observación perteneciente a la clase c_i tome el valor \mathbf{x} , es decir, $P(\mathbf{x}|c_i)$ [66]. Por lo general esta información no esta disponible y deben ser estimadas a partir de la muestra que se tiene. En el caso del presente trabajo se realizó una estimación de estas distribuciones con el set de datos de señales de EEG registradas durante las tareas de MI de [60].

Se ha hecho la consideración de que las observaciones dentro de cada clase poseen una distribución normal, entonces, si se tienen k observaciones, la distribución $f_i(\mathbf{x})$ puede expresarse cómo,

$$f_i(\mathbf{x}_1 \dots \mathbf{x}_k) = \frac{1}{(2\pi)^{k/2} |\Sigma|^{1/2}} e^{\left(-\frac{1}{2}(\mathbf{x}-\mu)^T \Sigma^{-1}(\mathbf{x}-\mu)\right)}, \quad (10)$$

Por otro lado, una observación \mathbf{x} cualquiera, será asignada a la clase c_{ape} (*apertura mano*), si se cumple que,

$$P(c_{ape})P(\mathbf{x}|c_{ape}) \geq (1 - P(c_{des})P(\mathbf{x}|c_{des})), \quad (11)$$

A partir de la ecuación (11) es posible encontrar una recta que separe las observaciones \mathbf{x} , para esto se hace,

$$\begin{aligned} P(c_{ape})P(\mathbf{x}|c_{ape}) &= (1 - P(c_{des})P(\mathbf{x}|c_{des})) \\ \frac{1 - P(c_{des})P(\mathbf{x}|c_{des})}{P(c_{ape})P(\mathbf{x}|c_{ape})} &= \frac{1 - \pi_{c_{ape}} f_{c_{ape}}(\mathbf{x})}{\pi_{c_{des}} f_{c_{des}}(\mathbf{x})} = 1, \end{aligned} \quad (12)$$

Utilizando la expresión (10) y aplicando *logaritmo* a ambos lados de la ecuación (12) es posible obtener una *recta de decisión* o *frontera* que nos permita asignar la pertenencia a una clase para nuevas observaciones. LA recta de decisión posee la siguiente expresión,

$$y = \mathbf{w}^T \mathbf{x} + b, \quad (13)$$

Donde el vector \mathbf{w} y el bias b , se obtienen de resolver (12).

Finalmente, la clasificación de una observación a una clase u otra se obtiene evaluando el signo de \mathbf{y} , esto es,

$$\hat{c}_i = \text{sign}(\mathbf{y}) = \text{sign}(\mathbf{w}^T \mathbf{x} + b), \quad (14)$$

La resolución completa de las ecuaciones 9 a 14 pueden encontrarse en [66] y [67].

4.2.3.1 Entrenamiento y validación del LDA

Para el entrenamiento y validación del LDA se utilizó el método de Validación cruzada (CV de del ingles, *cross validation*). La validación cruzada permite entrenar y validar algoritmos de clasificación utilizando información o datos disponibles, sin necesidad de recopilar nuevos. En general, el método implica dividir el set de datos existente en tres nuevos sets, los cuales son, set de entrenamiento, validación y testeo.



Figura 7: Esquema de división del set de datos original para el entrenamiento, validación y testeo del clasificador. De la totalidad de trials disponibles, 80% fueron utilizados como set de entrenamiento y validación. El 20% restante sirvió como set de testeo.

Para el presente trabajo se utilizó el 80% de los trials para generar los sets de entrenamiento y validación del LDA. El 20% restante fue utilizado para testeo. A su vez, los trials del 80% del set de entrenamientos y validación fueron reordenados aleatoriamente y luego divididos en 5 sets mas pequeños, los cuales fueron utilizados para entrenar y testear el LDA. Este proceso se conoce como validación por “*k-divisiones*” o “*k-folds*”. La figura 7 muestra un esquema de la división realizada en el presente trabajo.

El proceso mencionado anteriormente fue realizado 5 veces por cada sujeto, haciendo un total de 25 corridas. Finalmente, las 5 mejores rectas de clasificación obtenidas a partir del set de entrenamiento y validación fueron utilizadas sobre el set de testeo. La figura 8 muestra un diagrama del proceso.

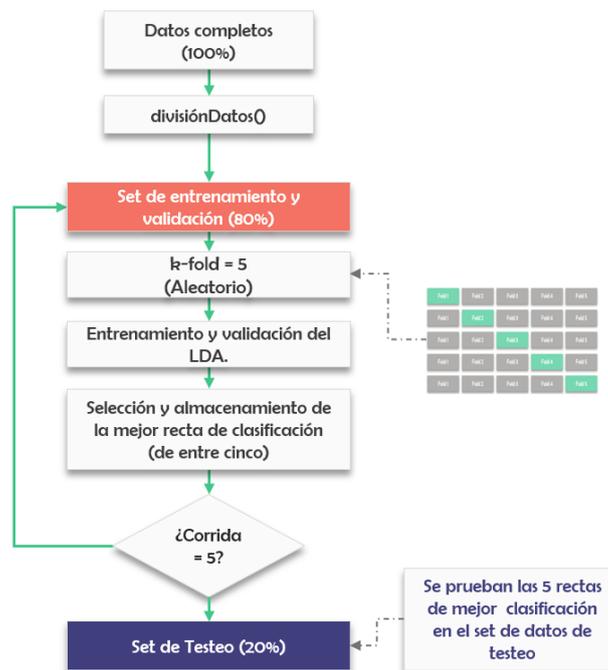


Figura 8: Diagrama de bloques para el proceso de entrenamiento y testeo del LDA. El 80% de los trials del set original fue sometido a un proceso de validación mediante *k-folds*, de cada uno de estos se seleccionó la recta que mejor clasificaba el set de testeo. El proceso se repitió 5 veces. Finalmente, las 5 mejores rectas fueron sometidas al set de testeo.

5. Resultados

Los resultados se computaron a partir de evaluar el clasificador sobre el set de testeo.

5.1 Resultados de clasificación

La figura 9 muestra las matrices de confusión normalizadas con los promedios de clasificación para todas las corridas de las tareas mentales correspondientes a *movimiento vs descanso* para cada uno de los 15 sujetos voluntarios. Una matriz de confusión permite visualizar el desempeño de un algoritmo de clasificación de aprendizaje supervisado. Las columnas de la matriz representan el porcentaje relativo o la cantidad de predicciones de cada clase, mientras que las filas representan las instancias de la clase real, es decir, las filas representan los datos *conocidos*, y las columnas los datos *clasificados*. Además, la diagonal principal de la matriz representa la *especificidad* del clasificador a una clase en particular. De esta forma se observa que sobre los datos del sujeto 9 se obtuvo una clasificación correcta de las clases *movimiento* cuando realmente el sujeto imaginó un movimiento en el 68.6% (verdadero positivo o TP) de las veces, o que, en un 31.6% de los casos, se clasificó la tarea mental como *movimiento* cuando en realidad debería haber clasificado como *descanso*.

De manera similar, la figura 10 muestra las matrices de confusión completamente normalizadas (FNCM del inglés *full normalized confusion matrix*) con los promedios de clasificación de todas las corridas para las tareas correspondientes a *movimiento vs movimiento* para cada uno de los 15 sujetos voluntarios. La FNCM provee los mismos datos que una matriz de confusión, pero manteniendo información acerca del número de trials totales y de la distribución de clasificación entre clases. Para lograr esto se agrega una columna adicional que representa la probabilidad a priori $P(c_i)$ de la clase c_i , y una fila adicional, que representa la probabilidad de

clasificar la clase c_i como c_j , es decir $P(c_j|c_i)$. Finalmente, el último ítem de la matriz de confusión (esquina inferior derecha) contiene el número total de trials [68].

La figura 11 muestra un gráfico de barras con los porcentajes máximos de las clasificaciones para las corridas *movimiento vs descanso* (gráfico de la izquierda) y *movimiento vs movimiento* (gráfico de la derecha) correspondiente a cada uno de los 15 sujetos voluntarios. Por otro lado, la figura 12 muestra los porcentajes de clasificación promedio alcanzados por el clasificador para las corridas *movimiento vs movimiento* y *movimiento vs movimiento* computados sobre los 15 sujetos voluntarios.

La tabla número 3 muestra un resumen de los porcentajes de clasificación para las tareas mentales de *movimientos vs descanso* para cada uno de los 15 sujetos voluntarios. La tabla 3 se computó a partir de las matrices de confusión, simplemente como la suma de la diagonal principal dividido por el número total de trials. El máximo porcentaje de precisión del clasificador fue del 80.0%. La precisión total correspondiente a *movimiento vs descanso* alcanzó un valor de $(63.46 \pm 8.31)\%$.

La tabla número 4 muestra un resumen de las clasificaciones para las tareas mentales de *movimientos vs movimiento* para cada uno de los 15 sujetos voluntarios. El clasificador obtuvo un promedio de precisión total en la clasificación del $(63.41 \pm 9.12)\%$ para la discriminación de las clases *movimiento vs movimiento*.

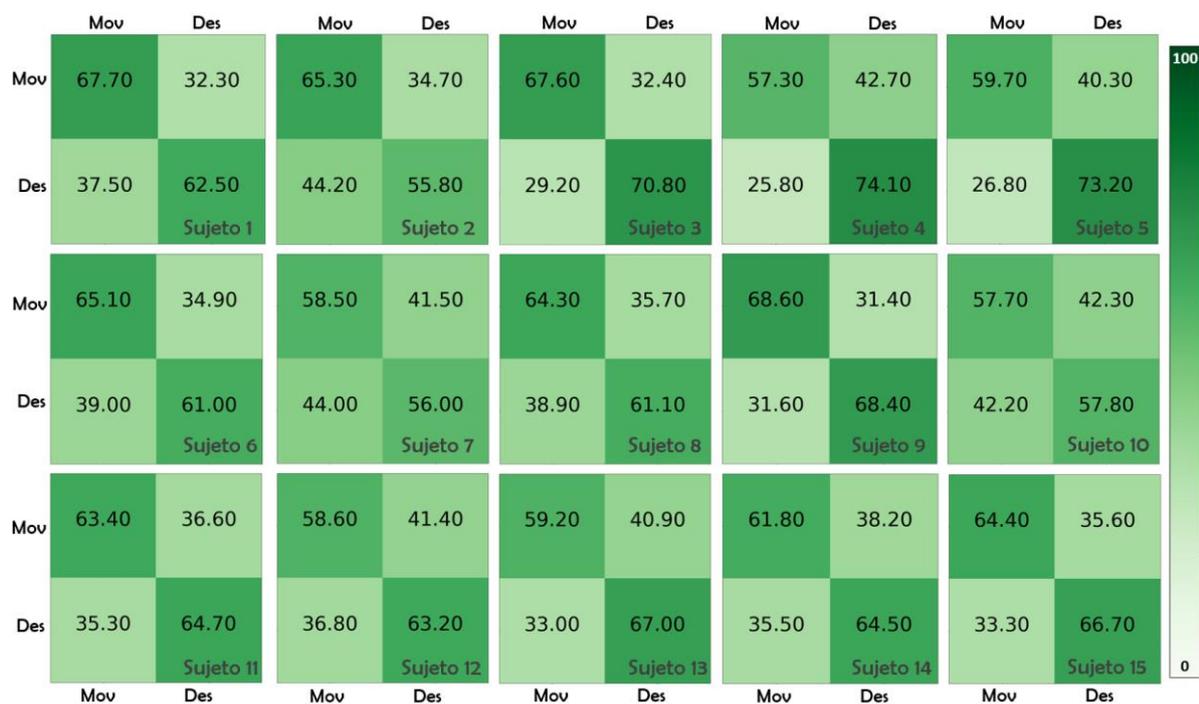


Figura 9: Matrices de confusión con promedios de clasificación (en porcentajes) totales para todas las clases movimiento vs descanso.

La tabla 5 muestra los porcentajes de *TPR* -ecuación (1)- y *FPR* -ecuación (2)- de cada sujeto computado sobre las tareas mentales de las clases *movimiento vs descanso*. Similarmente, la tabla 6 muestra los porcentajes de *TPR* y *FPR* de cada sujeto computado sobre las tareas mentales *movimiento vs movimiento*.

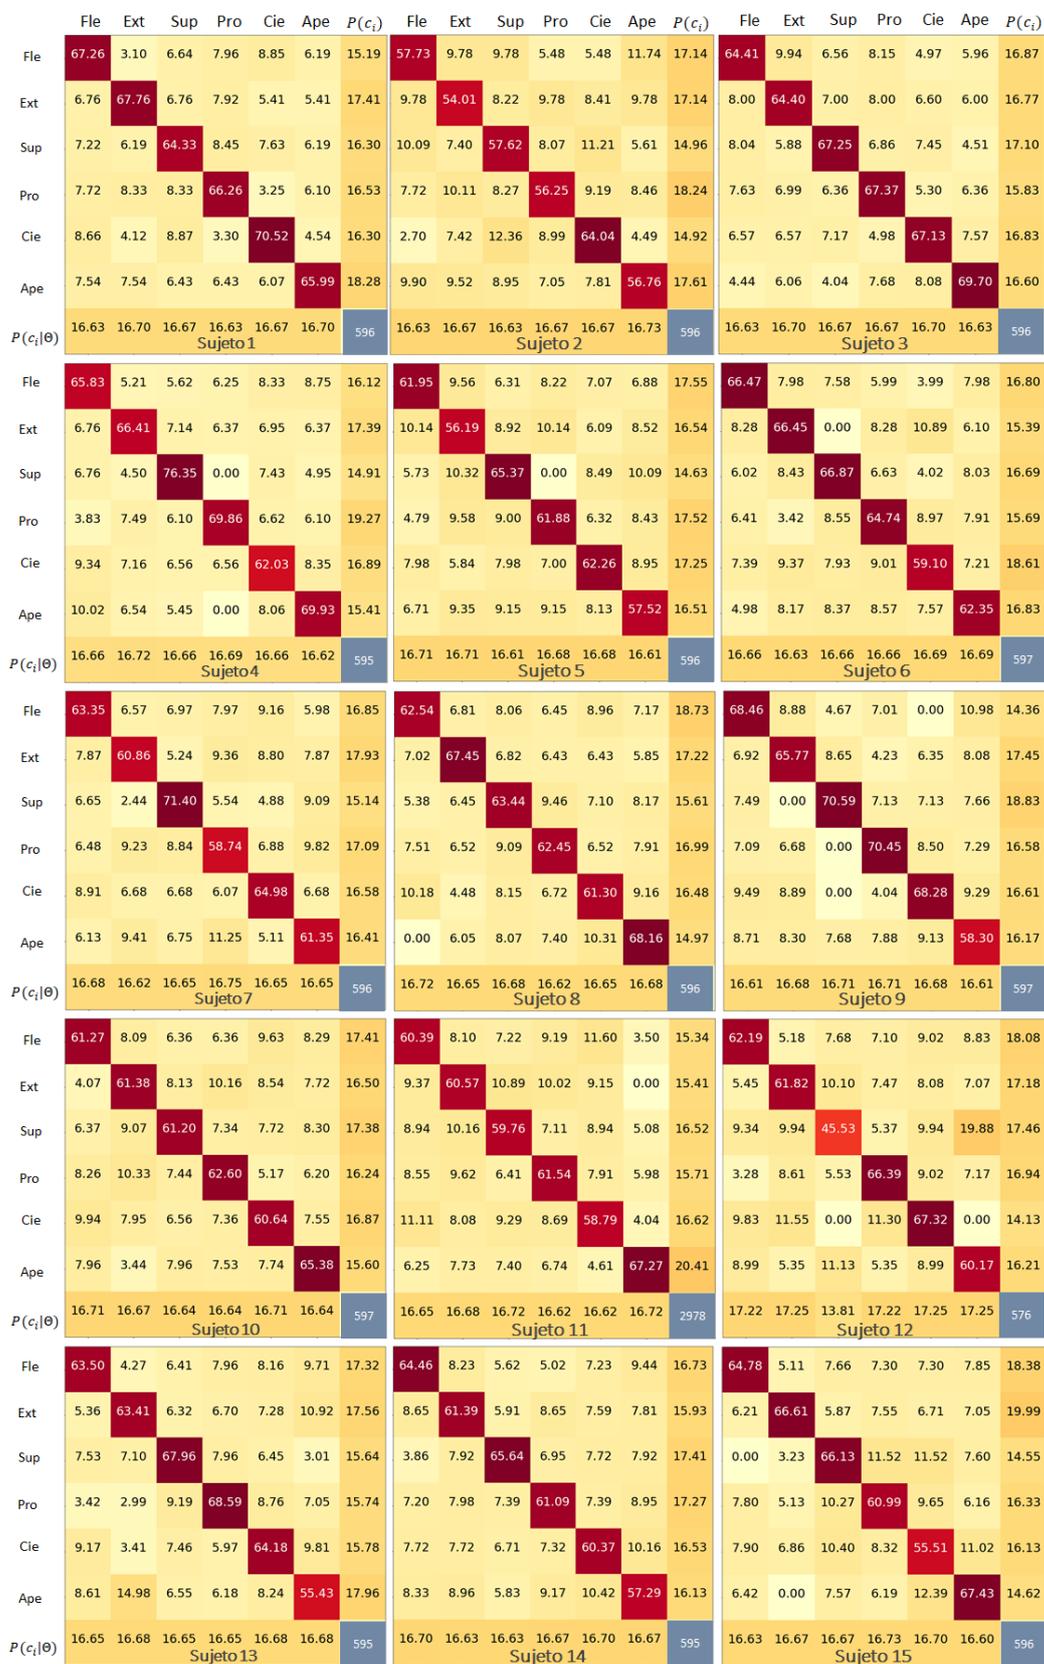


Figura 10: Matrices de confusión completamente normalizadas computadas sobre las clases *movimiento vs movimiento*.

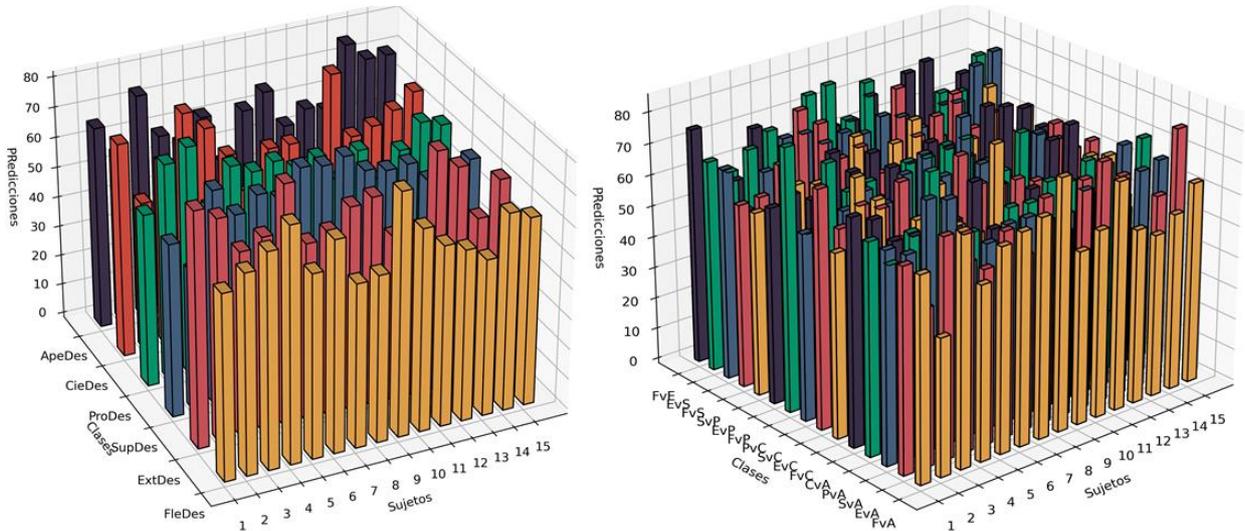


Figura 11: Porcentajes de clasificación máximos de las clasificaciones para la tarea movimiento vs descanso (gráfico izquierdo) y movimiento vs movimiento (gráfico derecho) correspondiente a cada uno de los 15 sujetos voluntarios. Referencias gráfico izquierdo, Flexión de codo (Fle), Extensión de codo (Ext), Supinación muñeca (Sup), Pronación muñeca (Pro), Cierre mano (Cie) y Apertura Mano (Ape). Referencias gráfico derecho, Flexión vs Extensión de codo (FvE), Extensión de codo vs Supinación (EvS), Flexión de codo vs Supinación (FvS), Supinación vs Pronación (SvP), Extensión vs Pronación (EvP), Flexión vs Pronación (FvP), Pronación vs Cierre (PvC), Supinación vs Cierre (SvC), Extensión vs Cierre (EvC), Flexión vs Cierre (FvC), Cierre vs Apertura (CvA), Pronación vs Apertura (PvA), Supinación vs Apertura (SvA), Extensión vs Apertura (EvA) y Flexión vs Apertura (FvA).

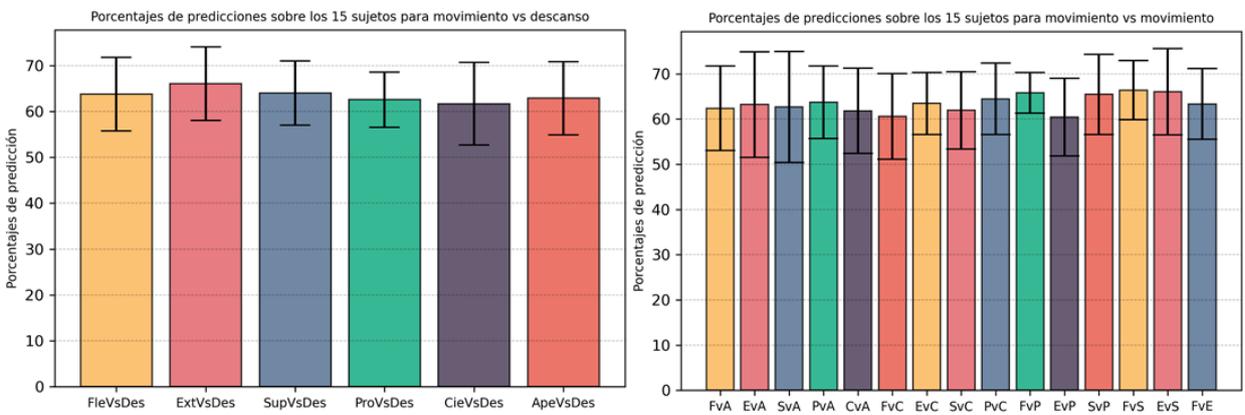


Figura 12: Porcentajes de clasificación máximos totales de las clasificaciones para la tarea movimiento vs descanso (gráfico izquierdo) y movimiento vs movimiento (gráfico derecho) correspondiente computado sobre los resultados promedios de los 15 sujetos voluntarios. Referencias gráfico izquierdo, Flexión de codo (Fle), Extensión de codo (Ext), Supinación muñeca (Sup), Pronación muñeca (Pro), Cierre mano (Cie) y Apertura Mano (Ape). Referencias gráfico derecho, Flexión vs Extensión de codo (FvE), Extensión de codo vs Supinación (EvS), Flexión de codo vs Supinación (FvS), Supinación vs Pronación (SvP), Extensión vs Pronación (EvP), Flexión vs Pronación (FvP), Pronación vs Cierre (PvC), Supinación vs Cierre (SvC), Extensión vs Cierre (EvC), Flexión vs Cierre (FvC), Cierre vs Apertura (CvA), Pronación vs Apertura (PvA), Supinación vs Apertura (SvA), Extensión vs Apertura (EvA) y Flexión vs Apertura (FvA).

Tabla 3: Resumen de clasificaciones para las clases de movimientos vs descanso para cada uno de los 15 sujetos voluntarios.

Promedios de clasificación clases <i>movimiento vs descanso</i>							
Sujeto/Clases	Fle vs Des	Ext vs Des	Suo vs Des	Pro Vs Des	Cie vs Des	Ape vs Des	Promedios de clasificación mov vs des para cada sujeto
Sujeto 1	61.111	77.273	57.071	57.071	70.854	67.172	65.09 ± 7.42
Sujeto 2	65.829	73.232	46.231	71.859	50	56.281	60.57 ± 10.42
Sujeto 3	70.854	61.111	71.212	75.879	61.111	74.874	69.17 ± 5.98
Sujeto 4	77.5	64.141	61.809	54.545	76.382	60.101	65.75 ± 8.43
Sujeto 5	60.606	79.397	66.667	66.667	70	55.556	66.48 ± 7.45
Sujeto 6	69.697	58.794	63.317	63.317	59.596	63.317	63.01 ± 3.52
Sujeto 7	54.04	60.804	72.222	65.152	44.949	46.231	57.23 ± 9.85
Sujeto 8	55.051	67.337	71.212	61.111	58.794	62.626	62.69 ± 5.33
Sujeto 9	80	68.844	72.727	63.317	58.794	67.337	68.5 ± 6.74
Sujeto 10	66.667	54.545	66.667	54.04	50	54.545	57.74 ± 6.5
Sujeto 11	55.051	50	78.283	54.04	75.253	65.152	62.96 ± 10.81
Sujeto 12	56.566	78.894	65.657	51.256	56.784	56.566	60.95 ± 9.07
Sujeto 13	51.759	72.222	58.794	59.596	58.794	77.387	63.09 ± 8.81
Sujeto 14	65.152	54.04	58.586	67.337	62.626	71.212	63.16 ± 5.64
Sujeto 15	62.121	65.152	62.626	65	67.337	71.212	65.57 ± 3.06
Promedios de clasificación totales mov vs mov	63.47 ± 8.22	65.72 ± 8.98	64.87 ± 7.68	62.01 ± 6.79	61.42 ± 8.91	63.3 ± 8.27	

Tabla 4: Resumen de clasificaciones para las clases de movimientos vs movimiento para cada uno de los 15 sujetos voluntarios.

Promedios de clasificación clases <i>movimiento vs descanso</i>																
Sujetos/Clases	FvA	EvA	SvA	PvA	CvA	FvC	EvC	SvC	PvC	FvP	EvP	SvP	FvS	EvS	FvE	Promedios clasificación mov vs des para cada sujeto
Sujeto 1	65.2	65.2	67.3	67.3	72.2	58.8	75.9	59.6	83.8	62.6	58.6	58.6	67.3	67.3	75.3	67. ± 7.06
Sujeto 2	43.7	50	63.8	58.1	69.3	79.8	61.6	47.2	55	64.6	47.2	59.1	52.3	62.1	50	57.6 ± 9.37
Sujeto 3	73.7	69.8	78.4	65.8	60.8	70.9	66.7	62.6	75	61.1	63.3	67.3	62.6	67.3	55	66.7 ± 5.95
Sujeto 4	55.6	68.3	76.4	82.4	60.1	56.3	63.6	66.7	64.1	73.7	61.6	82.4	71.4	71.4	69.8	68.26 ± 8.06
Sujeto 5	65.2	55.6	55.1	55.1	56.8	60.6	70	60.6	65.2	65.8	50	76.4	70.9	55.1	50	60.8 ± 7.61
Sujeto 6	67.5	65.2	58.8	59.6	60.8	69.3	48.7	67.8	53.8	69.8	72.7	63.3	65.8	78.9	60.8	64.2 ± 7.29
Sujeto 7	69.8	55.6	62.6	47.2	70.9	54.5	59.6	72.2	67.3	63.3	51.3	65	67.3	80.3	62.1	63.28 ± 8.4
Sujeto 8	80.0	71.2	62.6	63.3	54	50	72.2	63.3	66.7	62.6	66.7	54.5	65	67.3	62.6	64.15 ± 7.27
Sujeto 9	55.1	58.8	59.6	62.6	54.5	76.4	61.1	80	68.8	67.3	72.2	80	68.8	77.4	62.6	67.02 ± 8.41
Sujeto 10	59.6	72.7	59.6	67.3	62.6	50	58.8	63.3	68.8	63.3	50	62.6	66.7	56.3	68.8	62.04 ± 6.35
Sujeto 11	63.3	62.6	77.4	62.6	81.9	50	38.9	58.6	67.3	62.6	62.6	66.7	59.6	50	54	61.22 ± 10.26
Sujeto 12	55.6	69.8	23.6	69.8	78.9	56.3	56.3	50	54.5	73.2	60.1	72.7	56.3	50	72.7	60. ± 13.33
Sujeto 13	51.8	31.2	75.3	66.7	54.5	57.1	72.7	67.3	65.2	71.2	75.3	59.6	65.7	66.7	74.7	63.65 ± 11.28
Sujeto 14	56.3	59.6	65.2	54.5	50	62.6	62.6	63.3	62.6	68.8	58.6	62.6	75.9	65.2	58.6	61.76 ± 5.91
Sujeto 15	64.1	78.9	66.7	71.2	46	60.8	63.3	50	56.3	60.8	65	50	78.9	75.3	67.2	63.63 ± 9.79
Promedios de clasificación totales mov vs mov	61.76 ± 8.9	62.3 ± 11.14	63.49 ± 12.81	63.58 ± 8.02	62.23 ± 10.09	60.89 ± 9.05	62.14 ± 9.17	62.18 ± 8.34	64.97 ± 7.81	66.07 ± 4.21	61.01 ± 8.41	65.39 ± 8.86	66.29 ± 6.65	66.03 ± 9.53	62.96 ± 8.12	

Tabla 5: Valores correspondientes a TPR y FPR de los 15 sujetos voluntarios para las clases movimiento vs descanso.

Sujetos	Rates (%)	Clases <i>Movimiento vs Descanso</i>						Promedios
		FlVsDes	ExtVsDes	SupVsDes	PronVsDes	CieVsDes	ApeVsDes	
Sujeto 1	TPR	62.0	73.0	57.0	57.0	69.0	66.0	64. ± 5.94
	FPR	39.0	17.0	43.0	43.0	27.0	31.0	33.33 ± 9.41
Sujeto 2	TPR	64.0	69.0	46.0	67.0	50.0	56.0	58.67 ± 8.63
	FPR	32.0	21.0	53.0	21.0	50.0	43.0	36.67 ± 12.89
Sujeto 3	TPR	75.0	60.0	72.0	78.0	62.0	73.0	70. ± 6.66
	FPR	32.0	38.0	29.0	26.0	40.0	22.0	31.17 ± 6.34
Sujeto 4	TPR	100.0	65.0	61.0	55.0	100.0	61.0	73.67 ± 18.85
	FPR	31.0	37.0	38.0	46.0	32.0	40.0	37.33 ± 5.02
Sujeto 5	TPR	61.0	100.0	69.0	69.0	75.0	55.0	71.5 ± 14.26
	FPR	40.0	29.0	35.0	35.0	33.0	44.0	36. ± 4.83
Sujeto 6	TPR	69.0	59.0	62.0	62.0	58.0	65.0	62.5 ± 3.69
	FPR	29.0	41.0	35.0	35.0	39.0	38.0	36.17 ± 3.85
Sujeto 7	TPR	54.0	60.0	75.0	63.0	45.0	47.0	57.33 ± 10.18
	FPR	46.0	39.0	30.0	33.0	55.0	54.0	42.83 ± 9.65
Sujeto 8	TPR	55.0	67.0	72.0	60.0	59.0	63.0	62.67 ± 5.56
	FPR	45.0	32.0	29.0	38.0	41.0	38.0	37.17 ± 5.34
Sujeto 9	TPR	71.0	71.0	79.0	65.0	59.0	67.0	68.67 ± 6.16
	FPR	35.0	33.0	31.0	38.0	41.0	32.0	35. ± 3.51
Sujeto 10	TPR	67.0	54.0	67.0	54.0	50.0	55.0	57.83 ± 6.67
	FPR	33.0	45.0	33.0	46.0	50.0	46.0	42.17 ± 6.67
Sujeto 11	TPR	60.0	55.0	67.0	62.0	100.0	59.0	67.17 ± 15.12
	FPR	41.0	45.0	37.0	37.0	30.0	41.0	38.5 ± 4.68
Sujeto 12	TPR	56.0	100.0	66.0	51.0	57.0	56.0	64.33 ± 16.56
	FPR	43.0	30.0	35.0	48.0	43.0	43.0	40.33 ± 5.99
Sujeto 13	TPR	51.0	75.0	59.0	59.0	59.0	100.0	67.17 ± 16.33
	FPR	48.0	30.0	41.0	40.0	41.0	31.0	38.5 ± 6.24
Sujeto 14	TPR	67.0	54.0	59.0	68.0	63.0	71.0	63.67 ± 5.76
	FPR	37.0	46.0	41.0	33.0	38.0	28.0	37.17 ± 5.7
Sujeto 15	TPR	61.0	67.0	62.0	69.0	67.0	71.0	66.17 ± 3.58
	FPR	37.0	37.0	37.0	38.0	32.0	28.0	34.83 ± 3.62

Tabla 6: Valores correspondientes a TPR y FPR de los 15 sujetos voluntarios para las clases *movimiento vs movimiento*.

Sujetos	Rates (%)	Clases <i>Movimiento vs Movimiento</i>						Promedios
		Flexión	Extensión	Supinación	Pronación	Cierre	Apertura	
Sujeto 1	TPR	67.0	68.0	64.0	66.0	71.0	66.0	67. ± 2.16
	FPR	8.0	6.0	7.0	7.0	6.0	6.0	6.67 ± .75
Sujeto 2	TPR	58.0	54.0	58.0	56.0	64.0	57.0	57.83 ± 3.08
	FPR	8.0	9.0	9.0	8.0	8.0	8.0	8.33 ± .47
Sujeto 3	TPR	64.0	64.0	67.0	67.0	67.0	70.0	66.5 ± 2.06
	FPR	7.0	7.0	6.0	7.0	6.0	6.0	6.5 ± .5
Sujeto 4	TPR	66.0	66.0	76.0	70.0	62.0	70.0	68.33 ± 4.38
	FPR	7.0	6.0	6.0	4.0	7.0	7.0	6.17 ± 1.07
Sujeto 5	TPR	62.0	56.0	65.0	62.0	62.0	58.0	60.83 ± 2.97
	FPR	7.0	9.0	8.0	7.0	7.0	9.0	7.83 ± .9
Sujeto 6	TPR	66.0	66.0	67.0	65.0	59.0	62.0	64.17 ± 2.79
	FPR	7.0	8.0	7.0	8.0	7.0	7.0	7.33 ± .47
Sujeto 7	TPR	63.0	61.0	71.0	59.0	65.0	61.0	63.33 ± 3.9
	FPR	7.0	7.0	7.0	8.0	7.0	8.0	7.33 ± .47
Sujeto 8	TPR	63.0	67.0	63.0	62.0	61.0	68.0	64. ± 2.58
	FPR	6.0	6.0	8.0	7.0	8.0	8.0	7.17 ± .9
Sujeto 9	TPR	68.0	66.0	71.0	70.0	68.0	58.0	66.83 ± 4.26
	FPR	8.0	6.0	4.0	6.0	6.0	9.0	6.5 ± 1.61
Sujeto 10	TPR	61.0	61.0	61.0	63.0	61.0	65.0	62. ± 1.53
	FPR	7.0	8.0	7.0	8.0	8.0	8.0	7.67 ± .47
Sujeto 11	TPR	60.0	61.0	60.0	62.0	59.0	67.0	61.5 ± 2.63
	FPR	9.0	9.0	8.0	8.0	8.0	4.0	7.67 ± 1.7
Sujeto 12	TPR	62.0	62.0	46.0	66.0	67.0	60.0	60.5 ± 6.92
	FPR	7.0	8.0	7.0	7.0	9.0	9.0	7.83 ± .9
Sujeto 13	TPR	63.0	63.0	68.0	69.0	64.0	55.0	63.67 ± 4.53
	FPR	7.0	7.0	7.0	7.0	8.0	8.0	7.33 ± .47
Sujeto 14	TPR	64.0	61.0	66.0	61.0	60.0	57.0	61.5 ± 2.87
	FPR	7.0	8.0	6.0	7.0	8.0	9.0	7.5 ± .96
Sujeto 15	TPR	65.0	67.0	66.0	61.0	56.0	67.0	63.67 ± 3.99
	FPR	6.0	4.0	8.0	8.0	9.0	8.0	7.17 ± 1.67

6. Discusión

6.1 Extracción de características mediante CSP

Para la extracción de características fue implementado un Common Saptial Pattern (CSP) con el objetivo de encontrar aquellos canales de EEG que posean las mejores características para discriminar entre un tipo de movimiento y otro. La idea fundamental detrás del algoritmo de CSP es poder aumentar la varianza entre clases, de esta forma, sería posible separar ambas.

La figura 14 muestra las varianzas antes -gráfico izquierdo- y después -gráfico derecho- de la aplicación del CSP asociadas a todos los canales para una de las corridas de entrenamiento computadas sobre los datos del sujeto 1 correspondiente a *cierre mano vs descanso*. Puede notarse que luego de la aplicación del CSP la diferencia entre las varianzas aumenta, es esperable que esto suceda con mayor énfasis en aquellos canales del electroencefalograma que registran la actividad eléctrica de zonas de la corteza cerebral donde se procesa la información para llevar a cabo la acción o imaginación de movimiento deseado por el sujeto. Las diferencias de varianzas máximas correspondieron a los canales izquierdos F3 y FFC3h, ambos pertenecen a regiones cerebrales del hemisferio izquierdo asociadas a la tarea de realizar o imaginar movimientos sobre los miembros [2].

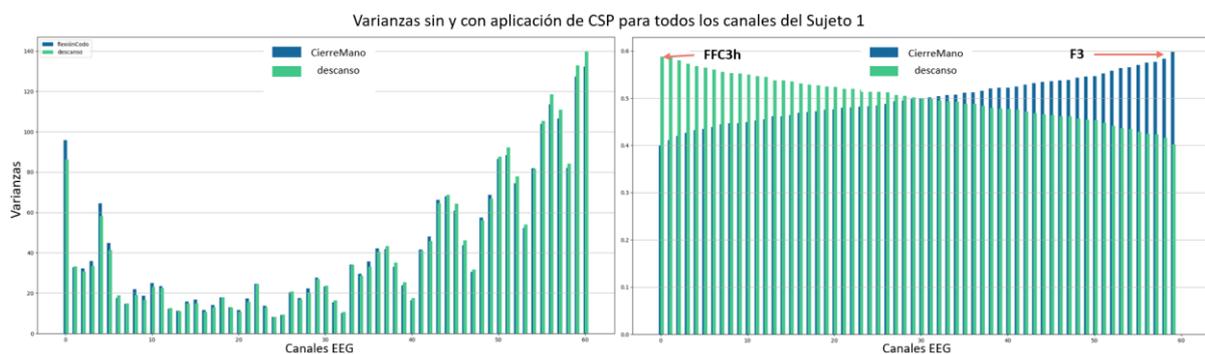


Figura 14: Varianzas con y sin CSP computadas durante las fases de entrenamiento para los datos del sujeto 8. Las flechas indican las varianzas máximas entre clases correspondientes a los canales FFC3h y F3.

La figura 15 muestra el gráfico de dispersión de las varianzas para las clases *flexión codo* y *descanso*, computadas a partir de una de las corridas de entrenamiento sobre los datos del sujeto 1. Puede verse que el CSP aumenta la varianza intra clase, esto es notoria en los extremos del gráfico, en donde se maximizan las diferencias entre las clases Descanso y Cierre Mano. El gráfico de dispersión se obtuvo a partir de tomar los canales FFC3h y F3 como canales componentes de las características relevantes para discriminar las tareas de *cierre mano vs descanso*.

6.2 Clasificación usando LDA

Luego de extraídas y seleccionadas las características para cada tarea mental sobre cada sujeto se entrenó y utilizó un LDA para clasificar las clases.

La figura 16 muestra los gráficos de dispersión de varianzas para el set de entrenamiento y testeo junto con la recta de decisión obtenida por el LDA.

Es importante mencionar que en las gráficas de la figura 16 algunas observaciones parecen tocar la recta de decisión, sin embargo, este no es el caso, es decir que, si se hiciera un *zoom* sobre la imagen, será posible observar que ninguna de las observaciones toca la recta. En todas las observaciones clasificadas, la recta obtenida por el LDA asignaba un valor 1 o -1 dependiendo de la clase a discriminar. Se puede observar que el LDA logró una correcta recta de decisión luego de ser procesado con el set de entrenamiento.

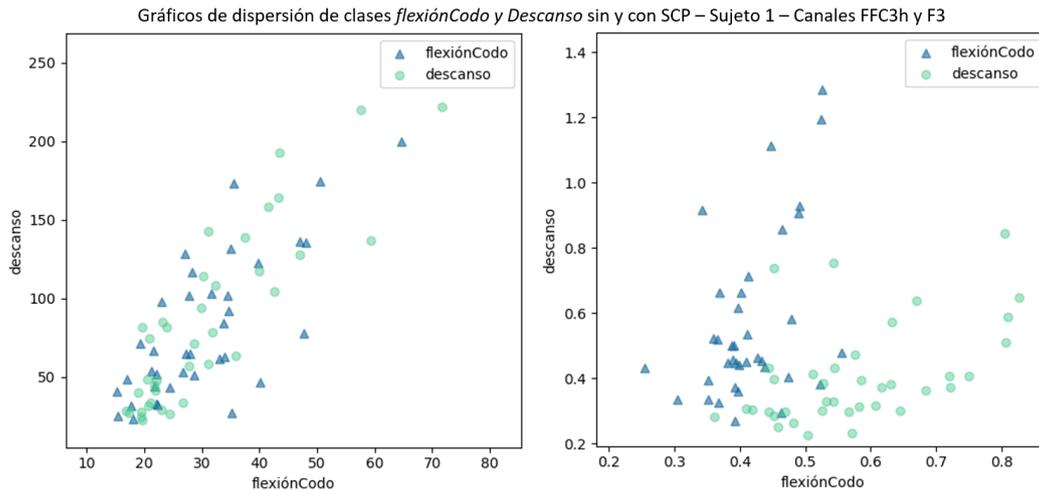


Figura 15: Gráfico de dispersión de los valores de varianza considerando los canales FFC3h y F3 como canales componentes de las características para discriminar las tareas *flexión codo vs descanso* para el sujeto 8 durante una de las corridas de entrenamiento del LDA.

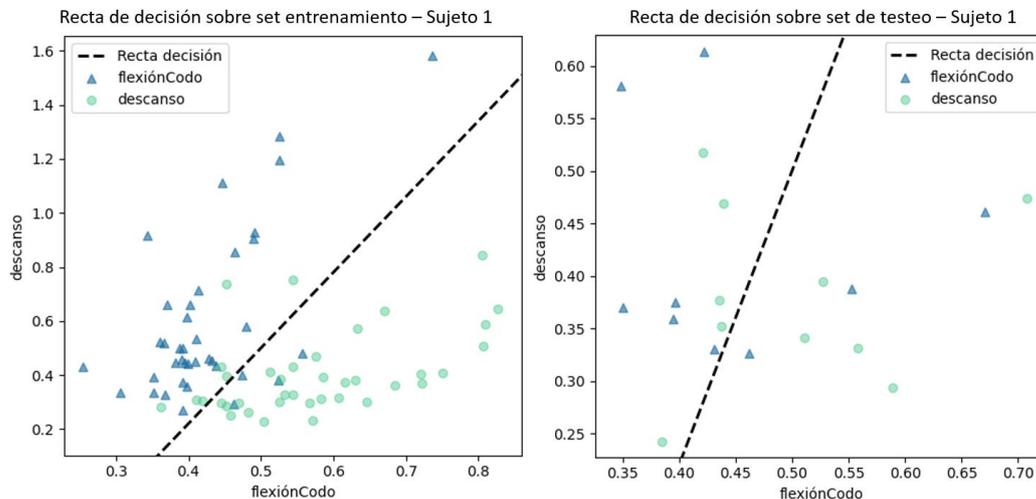


Figura 16: Gráfico de dispersión de varianzas para las clases *flexión codo vs descanso* del sujeto 8. El gráfico de la izquierda muestra la recta de decisión resultante luego de entrenar el LDA utilizando los puntos mostrados. El gráfico de la derecha muestra la recta de decisión aplicada sobre el set de testeo.

Puede notarse de la figura 16 que el LDA ejecuta una buena recta de decisión entre los datos de las clases, pero no logra generalizar correctamente el set de testeo, lo que podría ser un indicador de *overfitting*.

Si bien en la mayoría de los casos el LDA computó una recta de decisión que separaba lo mejor posible las observaciones tanto para las clases *movimiento vs descanso* y *movimiento vs movimiento* de cada uno de los sujetos, se observó que el CSP en ocasiones tuvo dificultades para lograr una adecuada separación de las

varianzas de cada clase. Esto es notorio si se observa la figura 17 donde puede verse que el CSP tuvo una mala performance para separar las clases *extensión codo vs descanso* para el sujeto 11. Con estas observaciones, el LDA computará una recta de decisión, no obstante, dichas observaciones no presentan una correcta dispersión, haciendo que recta computada no sea representativa a la hora de separar las clases. Como consecuencia, se espera un bajo promedio de clasificación.

Para las tareas de clasificación de las clases *movimiento vs descanso* y *movimiento vs movimiento* se obtuvieron promedios generales de clasificación de $(63.46 \pm 8.31)\%$ y $(63.41 \pm 9.12)\%$, los cuales pueden estar asociado a la implementación del CSP, el cual no logró separar adecuadamente las características de la señal en algunos casos, y también, a un posible *overfitting* por parte del LDA. Es esperable que los promedios de clasificación de las tareas *movimiento vs movimiento* sean menores dado que la extracción de características a partir de la señal es mas difícil de discriminar entre clases, sobre todo en aquellas en las que las acciones o tareas mentales que se desean realizar activan grupos de neuronas muy cercanas entre sí, como podría ser el caso de *supinación de muñeca vs pronación de muñeca*.

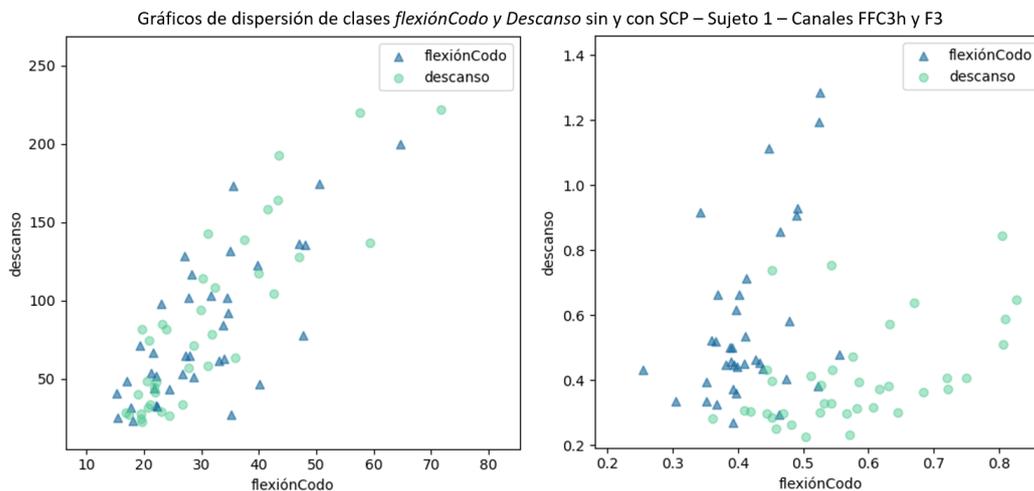


Figura 17: Gráfico de dispersión de los valores de varianza considerando los canales FZ y F3 como canales componentes de las características para discriminar las tareas *extensión codo vs descanso* para el sujeto 11 durante una de las corridas de entrenamiento del LDA.

Una de las estrategias para mejorar el desempeño de la extracción de características, es aumentar el número de canales utilizados como componentes y así tener mayor cantidad de características representativas de las intenciones del sujeto. También es posible utilizar lo que se conoce como Banco de Filtros para Patrones Espaciales Comunes (FBCSP del inglés *filter bank common spatial pattern*). En este enfoque las señales de EEG se filtran y dividen en diferentes bandas frecuenciales, luego cada una de estas bandas es sometida a un CSP para extraer las características que serán utilizadas para entrenar un LDA u otro tipo de clasificador -como máquinas de soporte vectorial (SVM)-, trabajos que utilizan este enfoque logran hasta un 85% de precisión en clasificación de *movimiento vs descanso* y de casi 89.68% utilizando LDA [40] y SVM[6], respectivamente.

6.3 Transferencia de información

Los promedios generales de la tasa de verdaderos positivos (*TPR*) -o *sensibilidad*- y de la tasa de falsos positivos (*FPR*) alcanzaron valores de $(65.02\% \pm 11.08)\%$ y $(37.14\% \pm 7.36)\%$, respectivamente, para las clases *movimiento vs descanso*. Para las tareas de *movimiento vs movimiento* se alcanzaron valores de

(63.4% ± 1,23)% y (7.3% ± 1.14)% para *TPR* y *FPR*, respectivamente. Es importante destacar el bajo *FPR* en las clases *movimiento vs movimiento*. En una BCI es deseable tener un bajo *FPR*, ya que comportamientos no deseados podrían causar accidentes, tales como un malfuncionamiento de una silla de ruedas o un brazo robótico [69]. No obstante, el promedio de *FPR* para la clase *movimiento vs descanso* es elevado, esto se debe en parte al bajo promedio de clasificación general (65%), además, el autor cree que el alto *FPR* también se debe a que durante el computo del mismo se utilizaron todas las clases de *movimiento vs la de descanso*, por ende, las probabilidades de obtener falsos positivos aumentan ya que todas las clases son consideradas como una sola, lo que finalmente se traduce en un *FPR* elevado, sin embargo, el *FPR* de las clases *movimiento vs movimiento* se computaron considerando a cada clase de manera individual, lo que reduce las probabilidades de obtener falsos positivos, por lo tanto, se obtienen *FPR* menores.

Con la ecuación (3), es posible determinar el *ITR* de cada sujeto asociado a la clasificación binaria de cada clase *movimiento vs descanso*. La tabla 7 muestra los valores de transferencia de información obtenidos considerando los promedios de clasificación alcanzados por el clasificador en cada una de las tareas *movimiento vs descanso* para cada sujeto.

Tabla 7: *ITR* promedios calculados a partir de (3) correspondientes a las clases *movimiento vs descanso* para todos los sujetos.

Transferencia de información para clases <i>movimiento vs descanso</i>															
Sujetos	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15
Comandos	0.55	0.43	0.68	0.57	0.59	0.49	0.35	0.48	0.65	0.36	0.49	0.43	0.49	0.49	0.56

Finalmente, si se quiere saber la cantidad de comandos por minutos que un sujeto podría realizar ejecutando tareas mentales *movimiento vs descanso*, se debe multiplicar los valores de la tabla 7 por el promedio de trials ejecutados por minuto.

El *ITR* computado a partir de la ecuación 3 es comúnmente utilizado cuando se trabaja con problemas binarios, como es el caso de *movimiento vs descanso*. Sin embargo, para obtener la tasa de transferencia de información asociado a las clasificaciones *movimiento vs movimiento* se recomienda utilizar un enfoque diferente.

Es posible obtener el *ITR* para cada clase a partir de la matriz de confusión la cual provee una matriz de transición entre un canal de comunicación para una entrada X y una salida Y . Si la variable aleatoria X modela la intención de movimiento del usuario, entonces puede tomar $M = 6$ clases de acuerdo a las tareas mentales a realizar con el set de datos utilizados, además, si la variable aleatoria Y modela la salida del clasificador, también puede tomar $M = 6$ valores, representados por los tipos de movimientos que el sujeto desea realizar.

Se define la entropía de una variable aleatoria discreta cómo,

$$H(X) = - \sum_{j=1}^M p(x_j) \cdot \log_2(p(x_j)), \quad (15)$$

Nykopp [70] propone una ecuación para calcular la transferencia de información a partir de la matriz de confusión de la forma,

$$I_{Nykopp} = I(X; Y) = H(Y) - H(Y|X), \quad (16)$$

Con,

$$H(Y) = - \sum_{j=1}^M p(y_j) \cdot \log_2(p(y_j)), \quad (17)$$

$$p(y_j) = \sum_{i=1}^M p(x_i) \cdot p(y_j|x_i), \quad (18)$$

$$H(Y|X) = - \sum_{i=1}^M \sum_{j=1}^M p(x_i) \cdot p(y_j|x_i) \cdot \log_2(p(y_j|x_i)), \quad (19)$$

Lo que finalmente nos da,

$$I_{Nykopp} = \sum_{i=1}^M \sum_{j=1}^M p(x_i) \cdot p(y_j|x_i) \cdot \log_2(p(y_j|x_i)) - \sum_{j=1}^M p(y_j) \cdot \log_2(p(y_j)), \quad (20)$$

El método propuesto por Nykopp [70] calcula la transferencia de información basándose en la performance de clasificación y distribución de cada clase utilizada en la BCI.

La tabla 8 muestra los valores de transferencia de información obtenidos computados a partir de la ecuación (20) I_{Nykopp} para cada clase de *movimiento vs movimiento*.

Tabla 8: Transferencia de información calculados a partir de I_{Nykopp} (ecuación 20) correspondientes a las clases *movimiento vs movimiento* para todos los sujetos.

Transferencia de información para clases <i>movimiento vs movimiento</i>															
Sujetos	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15
Transferencia de información	0.92	0.63	0.9	0.98	0.73	0.84	0.8	0.83	0.98	0.76	0.76	0.76	0.82	0.75	0.83

Al igual que antes, si se quiere saber la cantidad de comandos por minutos que un sujeto podría realizar ejecutando tareas mentales *movimiento vs movimiento*, se debe multiplicar los valores de la tabla 8 por el promedio de trials ejecutados por minuto.

7. Conclusiones

En este trabajo se aplicó un algoritmo de Análisis de Discriminante Lineal para clasificar movimientos de miembro superior a partir de señales de EEG y así obtener comandos que puedan ser utilizados en una interfaz cerebro computadora. Se aplicó la técnica de *Common Spatial Pattern* para poder extraer las características relevantes de las señales de EEG y así entrenar el LDA. Posteriormente se computaron los promedios de clasificación asociados a las tareas *movimiento vs descanso* y *movimiento vs movimiento*.

Es interesante notar que, en general para todas las clases, el clasificador mostró estar balanceado en cuanto a los porcentajes de clasificación, lo que sugiere, al menos para el set de datos utilizado, que el clasificador posee la misma especificidad para todas las clases.

Por otro lado, observando las últimas filas de las matrices de confusión completamente normalizadas de la figura 10, puede observarse que no existe una inclinación o carga por parte del clasificador de la BCI a la hora

de seleccionar una clase, lo que se conoce como *unbiased*, ya que se el promedio de selección en general fue del 16,67%, por lo tanto, se espera que el clasificador alcance los mismos niveles de performance para todas las clases. Esto se vuelve importante cuando se desea computar los *ITR* a partir de las ecuaciones (3) y (20) cómo indicadores de performance de una BCI, ya que es requisito que las probabilidades de ocurrencia de cada clase estén balanceadas.

En general los porcentajes de clasificación fueron moderados, con un promedio de $(63.46 \pm 8.31)\%$ para las clases *movimiento vs descanso*, llegando a máximos de 80%. Para el caso de las clases *movimiento vs movimiento* el porcentaje de clasificación promedio fue de $(63.41 \pm 9.12)\%$ llegando a un máximo de 83.4%. El bajo porcentaje de clasificación en general puede deberse a un errores o una falta de optimización del bloque de extracción de características, debido a que en algunos casos no logró separar adecuadamente las varianzas entre clases, lo que finalmente se traduce en un decremento en los porcentajes de clasificación. Existen otros trabajos que reportan porcentajes de clasificación más bajos para el caso de las clases *movimiento vs movimiento*, no obstante, muestran un mejor desempeño para la clasificación de *movimiento vs descanso* utilizando el mismo set de datos [40].

7.1 Propuestas de trabajos a futuro

Se propone realizar un análisis cualitativo del CSP utilizado y evaluar si el LDA produce o no overfitting sobre los datos de entrenamiento, lo que llevaría a una mala generalización cuando se presenten datos nuevos, impactando directamente sobre la performance del clasificador. Además, podría compararse el desempeño del LDA contra un clasificador del tipo máquina de soporte vectorial (SVM). Con un SVM pueden llegar a obtenerse buenos resultados de clasificación considerando que los márgenes del clasificador no tomarían en cuenta aquellas observaciones cercanas a la línea de clasificación, lo cual fue uno de los inconvenientes presentados por el CSP aplicado en este trabajo.

Otra propuesta es implementar algoritmos de Deep Learning para clasificar el set de datos utilizados. Con este enfoque, los procesos de extracción y selección de características y su clasificación se realizan dentro de un solo bloque. La arquitectura mayormente utilizada para MI-BCI es la de Redes Neuronales Convolucionales (CNN). Dentro de la literatura se reportan trabajos en donde las CNN mejoran el desempeño de clasificación de los LDA y SVM [11]. Una de las ventajas de las CNN es que aprovechan de forma inherente las características de ciertas señales, lo cual permite prescindir el bloque de extracción de características, además, las CNN permiten trabajar con grandes conjuntos de datos. Debe tenerse en cuenta que las CNN empezaron a utilizarse para procesar señales de EEG luego de ser establecidas como una herramienta para procesar imágenes, por ende, es necesario transformar los datos de EEG de forma tal de poder implementar una CNN. Las desventajas detrás del uso de redes neuronales es la cantidad de hiperparámetros que son necesarios entrenar, lo que resulta en mayores tiempos requeridos en las sesiones de entrenamiento comparado con otros métodos [11], no obstante, podría hacerse uso de GPUs para optimizar el tiempo de entrenamiento de estos parámetros, y una vez obtenidos los mismos, serían fáciles de aplicar a nuevos datos -siempre que se cuente con un hardware adecuado-. Estudios que utilizan este enfoque reportan hasta un 95% de precisión de clasificación para MI-BCI [71].

7.2 Comentarios finales

Uno de los requisitos para aprobar el Master en Data Science es aplicar algunos de los tópicos estudiados durante el cursado a un trabajo final. En el presente informe se muestran los resultados de aplicar un

clasificador lineal sobre un set de datos de electroencefalografía registrados durante el desarrollo de tareas de imaginación motora y así decodificar las intenciones del usuario para usarlas como comandos en una Interfaz Cerebro Computadora. Los métodos y algoritmos implementados en el presente trabajo permitieron al autor revisar, repasar y aprender conceptos nuevos durante el desarrollo del mismo, los cuales son objetivos inherentes del proyecto.

En el presente informe se muestra sólo una pequeña parte de las técnicas utilizadas en los sistemas de interfaces cerebro computadora, siendo este tópico, mucho más amplio. Las BCI pretenden ser una herramienta que permita mejorar la calidad de vida de personas con diferentes problemas motrices, devolviéndoles cierta autonomía que han perdido, sin embargo, para lograr esto, aún quedan muchos desafíos por resolver, sobre todo en lo que clasificación de las intenciones del usuario respecta. Afortunadamente, existen grandes cantidades de grupos de investigación y desarrollo que buscan, mediante diferentes enfoques, la mejor solución. El autor considera que no existe una única solución, sino que es necesario aplicar, en la medida de lo posible, diferentes técnicas de procesamiento y clasificación para poder determinar con certeza las intenciones del usuario, sabiendo que el cerebro tiene plasticidad, por lo tanto, el uso de una interfaz cerebro computadora, también generará modificaciones a nivel neuronal, similar al que se produce cuando una persona con un miembro amputado utiliza una prótesis. Estas modificaciones se traducirán finalmente en cambios en las características de la señal procesada, por lo tanto, a medida que la persona hace uso de la BCI, será necesario reentrenar los algoritmos para adaptarse a ésta.

Finalmente, el autor considera que la constante evolución de los algoritmos de Machine Learning y el aumento constante del poder de cómputo y procesamiento, harán que una BCI sea implementable y segura tanto para su usuario, como para terceros, en el corto plazo.

Bibliografía

- [1] J. R. Wolpaw and E. W. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press, 2012.
- [2] T. F. Bastos-Filho, *Introduction to Non-Invasive EEG-Based Brain-Computer Interfaces for assistive technologies*, vol. 53, no. 9. 2015.
- [3] P. Stawicki, F. Gemblar, A. Rezeika, and I. Volosyak, “A novel hybrid mental spelling application based on eye tracking and SSVEP-based BCI,” *Brain Sciences*, vol. 7, no. 4. 2017, doi: 10.3390/brainsci7040035.
- [4] B. Z. Allison and C. Neuper, “Could Anyone Use a BCI?,” Springer, London, 2010, pp. 35–54.
- [5] F. Lotte, F. Larrue, and C. Mühl, “Flaws in current human training protocols for spontaneous Brain-Computer Interfaces: lessons learned from instructional design,” *Front. Hum. Neurosci.*, vol. 7, no. SEP, p. 568, Sep. 2013, doi: 10.3389/fnhum.2013.00568.
- [6] J. Kevric and A. Subasi, “Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system,” *Biomed. Signal Process. Control*, vol. 31, pp. 398–406, 2017, doi: 10.1016/j.bspc.2016.09.007.
- [7] M. van S. UMCU *et al.*, “Title: Contribution to Roadmap,” 2014.
- [8] L. Baldezzari and G. G. Gentiletti, “Preliminary Design of a Regions-Based BCI Speller for Locked-in Patients,” in *IFMBE Proceedings*, 2020, vol. 75, pp. 1043–1050, doi: 10.1007/978-3-030-30648-9_135.
- [9] T. Freire, M. Sarcinelli-Filho, S. Mara Torres Müller, W. Cardoso Celeste, and T. Freire Bastos-Filho, “Brain-computer Interface Based on Visual Evoked Potentials to Command Autonomous Robotic Wheelchair Architecture for a Wheelchair Integrated in an Intelligent Environment View project Virtual Remote Training System for Users of Powered Wheelchairs View project Brain-computer Interface Based on Visual Evoked Potentials to Command Autonomous Robotic Wheelchair,” *Artic. J. Med. Biol. Eng.*, vol. 30, no. 6, pp. 407–416, 2010, doi: 10.5405/jmbe.765.
- [10] J. F. Castillo-Garcia, S. Müller, E. F. Caicedo-Bravo, T. F. Bastos, and A. F. De Souza, “Nonfatigating Brain-Computer Interface Based on SSVEP and ERD to Command an Autonomous Car,” *Adv. Data Sci. Adapt. Anal.*, vol. 10, no. 02, p. 1840005, Apr. 2018, doi: 10.1142/s2424922x18400053.
- [11] N. Padfield, J. Zabalza, H. Zhao, V. Masero, and J. Ren, “EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges,” *Sensors (Switzerland)*, vol. 19, no. 6, pp. 1–34, 2019, doi: 10.3390/s19061423.
- [12] P. Ofner, A. Schwarz, J. Pereira, D. Wyss, R. Wildburger, and G. R. Müller-Putz, “Attempted Arm and Hand Movements can be Decoded from Low-Frequency EEG from Persons with Spinal Cord Injury,” *Sci. Rep.*, vol. 9, no. 1, pp. 1–15, 2019, doi: 10.1038/s41598-019-43594-9.
- [13] N. Robinson and A. P. Vinod, “Noninvasive Brain-Computer Interface: Decoding Arm Movement Kinematics and Motor Control,” *IEEE Syst. Man, Cybern. Mag.*, vol. 2, no. 4, pp. 4–16, 2016, doi: 10.1109/msmc.2016.2576638.
- [14] A. Moran, A. Guillot, T. MacIntyre, and C. Collet, “Re-imagining motor imagery: Building bridges between cognitive neuroscience and sport psychology,” *British Journal of Psychology*, vol. 103, no. 2. Br J Psychol, pp. 224–247, May 2012, doi: 10.1111/j.2044-8295.2011.02068.x.
- [15] T. O. Zander and C. Kothe, “Towards passive brain-computer interfaces: Applying brain-computer interface technology to human-machine systems in general,” in *Journal of Neural Engineering*, Apr. 2011, vol. 8, no. 2, doi: 10.1088/1741-2560/8/2/025005.

- [16] G. Bauer, F. Gerstenbrand, and E. Rimpl, "Varieties of the locked-in syndrome," *J. Neurol.*, vol. 221, no. 2, pp. 77–91, Aug. 1979, doi: 10.1007/BF00313105.
- [17] S. Laureys *et al.*, "The locked-in syndrome: What is it like to be conscious but paralyzed and voiceless?," *Progress in Brain Research*, vol. 150. Prog Brain Res, pp. 495–511, 2005, doi: 10.1016/S0079-6123(05)50034-7.
- [18] S. Laureys, "Eyes open, brain shut," *Scientific American*, vol. 296, no. 5. Scientific American Inc., pp. 84–89, 2007, doi: 10.1038/scientificamerican0507-84.
- [19] I. S. Gantner, O. Bodart, S. Laureys, and A. Demertzi, "Our rapidly changing understanding of acute and chronic disorders of consciousness: Challenges for neurologists," *Future Neurology*, vol. 8, no. 1. Future Medicine Ltd London, UK , pp. 43–54, Jan. 14, 2013, doi: 10.2217/fnl.12.77.
- [20] H. Correa Agda Dra Corina Puppo Alberto Biestro Adj Raúl Mizraji Mario Cancela, "Muerte Encefálica Actualización de Consenso de Muerte Encefálica en adultos."
- [21] S. Laureys, A. M. Owen, and N. D. Schiff, "Brain function in coma, vegetative state, and related disorders," *Lancet Neurology*, vol. 3, no. 9. Lancet Neurol, pp. 537–546, Sep. 01, 2004, doi: 10.1016/S1474-4422(04)00852-X.
- [22] M. M. Monti *et al.*, "Willful Modulation of Brain Activity in Disorders of Consciousness," *N. Engl. J. Med.*, vol. 362, no. 7, pp. 579–589, Feb. 2010, doi: 10.1056/NEJMoa0905370.
- [23] G. R. Müller-Putz, C. Pokorny, D. S. Klobassa, and P. Horki, "A single-switch BCI based on passive and imagined movements: Toward restoring communication in minimally conscious patients," *Int. J. Neural Syst.*, vol. 23, no. 2, Apr. 2013, doi: 10.1142/S0129065712500372.
- [24] G. Bauernfeind, P. Horki, E. M. Kurz, W. Schippinger, G. Pichler, and G. R. Müller-Putz, "Improved concept and first results of an auditory single-switch BCI for the future use in disorders of consciousness patients," in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Nov. 2015, vol. 2015-November, pp. 1902–1905, doi: 10.1109/EMBC.2015.7318754.
- [25] "Deployment of Brain-Computer Interfaces for the Detection of Consciousness in Non-Responsive Patients | DECODER Project | FP7 | CORDIS | European Commission." <https://cordis.europa.eu/project/id/247919> (accessed Feb. 10, 2021).
- [26] A. Cotrina *et al.*, "Towards an architecture of a hybrid BCI based on SSVEP-BCI and passive-BCI," in *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2014*, Nov. 2014, pp. 1342–1345, doi: 10.1109/EMBC.2014.6943847.
- [27] A. Nijholt, D. P. O. Bos, and B. Reuderink, "Turning shortcomings into challenges: Brain-computer interfaces for games," *Entertain. Comput.*, vol. 1, no. 2, pp. 85–94, 2009, doi: 10.1016/j.entcom.2009.09.007.
- [28] J. D. R. Millán *et al.*, "Combining brain-computer interfaces and assistive technologies: State-of-the-art and challenges," *Front. Neurosci.*, vol. 4, no. SEP, pp. 1–15, 2010, doi: 10.3389/fnins.2010.00161.
- [29] M. Ahn and S. C. Jun, "Performance variation in motor imagery brain-computer interface: A brief review," *J. Neurosci. Methods*, vol. 243, pp. 103–110, Mar. 2015, doi: 10.1016/j.jneumeth.2015.01.033.
- [30] "Brain-Computer Interfaces: Principles and Practice - Google Libros." https://books.google.com.uy/books?id=IlZpAgAAQBAJ&printsec=frontcover&hl=es&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false (accessed Feb. 03, 2021).
- [31] J. B. F. Van Erp, F. Lotte, and M. Tangermann, "Brain-computer interfaces: Beyond medical

- applications,” *Computer (Long. Beach. Calif.)*, vol. 45, no. 4, pp. 26–34, Apr. 2012, doi: 10.1109/MC.2012.107.
- [32] B. Blankertz *et al.*, “Neurophysiological predictor of SMR-based BCI performance,” *Neuroimage*, vol. 51, no. 4, pp. 1303–1309, Jul. 2010, doi: 10.1016/j.neuroimage.2010.03.022.
- [33] A. Korik, R. Sosnik, N. Siddique, and D. Coyle, “Imagined 3D hand movement trajectory decoding from sensorimotor EEG rhythms,” *2016 IEEE Int. Conf. Syst. Man, Cybern. SMC 2016 - Conf. Proc.*, no. 76, pp. 4591–4596, 2017, doi: 10.1109/SMC.2016.7844955.
- [34] A. Korik, R. Sosnik, N. Siddique, and D. Coyle, “Decoding imagined 3D hand movement trajectories from EEG: Evidence to support the use of mu, beta, and low gamma oscillations,” *Front. Neurosci.*, vol. 12, no. MAR, pp. 1–16, 2018, doi: 10.3389/fnins.2018.00130.
- [35] F. B. Vialatte, M. Maurice, J. Dauwels, and A. Cichocki, “Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives,” *Progress in Neurobiology*, vol. 90, no. 4. Pergamon, pp. 418–438, Apr. 01, 2010, doi: 10.1016/j.pneurobio.2009.11.005.
- [36] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, “Filter Bank Common Spatial Pattern (FBCSP) in brain-computer interface,” in *Proceedings of the International Joint Conference on Neural Networks*, 2008, pp. 2390–2397, doi: 10.1109/IJCNN.2008.4634130.
- [37] D. Delisle-Rodriguez *et al.*, “Adaptive spatial filter based on similarity indices to preserve the neural information on EEG signals during on-line processing,” *Sensors (Switzerland)*, vol. 17, no. 12, Dec. 2017, doi: 10.3390/s17122725.
- [38] L. F. Nicolas-Alonso and J. Gomez-Gil, “Brain computer interfaces, a review,” *Sensors*, vol. 12, no. 2. Multidisciplinary Digital Publishing Institute (MDPI), pp. 1211–1279, Feb. 2012, doi: 10.3390/s120201211.
- [39] B. Graimann, B. Allison, and G. Pfurtscheller, “Brain–Computer Interfaces: A Gentle Introduction,” Springer, Berlin, Heidelberg, 2009, pp. 1–27.
- [40] P. Ofner, A. Schwarz, J. Pereira, and G. R. Müller-Putz, “Upper limb movements can be decoded from the time-domain of low-frequency EEG,” *PLoS One*, vol. 12, no. 8, pp. 1–24, 2017, doi: 10.1371/journal.pone.0182578.
- [41] *Signal Processing and Machine Learning for Brain-Machine Interfaces*. 2018.
- [42] G. Pfurtscheller and F. H. Lopes Da Silva, “Event-related EEG/MEG synchronization and desynchronization: Basic principles,” *Clinical Neurophysiology*, vol. 110, no. 11. Elsevier, pp. 1842–1857, Nov. 01, 1999, doi: 10.1016/S1388-2457(99)00141-8.
- [43] C. Jeunet, B. N’Kaoua, and F. Lotte, “Advances in user-training for mental-imagery-based BCI control: Psychological and cognitive factors and their neural correlates,” *Prog. Brain Res.*, vol. 228, pp. 3–35, 2016, doi: 10.1016/bs.pbr.2016.04.002.
- [44] G. Pfurtscheller and C. Neuper, “Motor imagery direct communication,” *Proc. IEEE*, vol. 89, no. 7, pp. 1123–1134, 2001, doi: 10.1109/5.939829.
- [45] S. Marchesotti, M. Bassolino, A. Serino, H. Bleuler, and O. Blanke, “Quantifying the role of motor imagery in brain-machine interfaces,” *Sci. Rep.*, vol. 6, no. 1, pp. 1–12, Apr. 2016, doi: 10.1038/srep24076.
- [46] M. Z. Baig, N. Aslam, H. P. H. Shum, and L. Zhang, “Differential evolution algorithm as a tool for optimal feature subset selection in motor imagery EEG,” *Expert Syst. Appl.*, vol. 90, pp. 184–195, Dec. 2017, doi: 10.1016/j.eswa.2017.07.033.

- [47] V. P. Oikonomou, K. Georgiadis, G. Liaros, S. Nikolopoulos, and I. Kompatsiaris, "A Comparison Study on EEG Signal Processing Techniques Using Motor Imagery EEG Data," in *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, Nov. 2017, vol. 2017-June, pp. 781–786, doi: 10.1109/CBMS.2017.113.
- [48] Q. Novi, C. Guan, T. H. Dat, and P. Xue, "Sub-band common spatial pattern (SBCSP) for brain-computer interface," in *Proceedings of the 3rd International IEEE EMBS Conference on Neural Engineering, 2007*, pp. 204–207, doi: 10.1109/CNE.2007.369647.
- [49] S. Kumar, A. Sharma, and T. Tsunoda, "An improved discriminative filter bank selection approach for motor imagery EEG signal classification using mutual information," *BMC Bioinformatics*, vol. 18, no. S16, p. 545, Dec. 2017, doi: 10.1186/s12859-017-1964-6.
- [50] M. Z. Ilyas, P. Saad, M. I. Ahmad, and A. R. I. Ghani, "Classification of EEG signals for brain-computer interface applications: Performance comparison," Mar. 2017, doi: 10.1109/ICORAS.2016.7872610.
- [51] J. Zhou, M. Meng, Y. Gao, Y. Ma, and Q. Zhang, "Classification of motor imagery EEG using wavelet envelope analysis and LSTM networks," in *Proceedings of the 30th Chinese Control and Decision Conference, CCDC 2018*, Jul. 2018, pp. 5600–5605, doi: 10.1109/CCDC.2018.8408108.
- [52] G. Rodríguez-Bermúdez and P. J. García-Laencina, "Automatic and adaptive classification of electroencephalographic signals for brain computer interfaces," *J. Med. Syst.*, vol. 36, no. SUPPL.1, pp. 51–63, Nov. 2012, doi: 10.1007/s10916-012-9893-4.
- [53] D. J. Krusienski, D. J. McFarland, and J. R. Wolpaw, "An evaluation of autoregressive spectral estimation model order for brain-computer interface applications," in *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings, 2006*, pp. 1323–1326, doi: 10.1109/IEMBS.2006.259822.
- [54] Y. R. Tabar and U. Halici, "A novel deep learning approach for classification of EEG motor imagery signals," *J. Neural Eng.*, vol. 14, no. 1, Feb. 2017, doi: 10.1088/1741-2560/14/1/016003.
- [55] Y. Wang, X. Li, H. Li, C. Shao, L. Ying, and S. Wu, "Feature extraction of motor imagery electroencephalography based on time-frequency-space domains," *Sheng Wu Yi Xue Gong Cheng Xue Za Zhi*, vol. 31, no. 5, pp. 955–961, Oct. 2014, Accessed: Feb. 16, 2021. [Online]. Available: <https://europepmc.org/article/med/25764703>.
- [56] M. Li, W. Chen, and T. Zhang, "Classification of epilepsy EEG signals using DWT-based envelope analysis and neural network ensemble," *Biomed. Signal Process. Control*, vol. 31, pp. 357–365, Jan. 2017, doi: 10.1016/j.bspc.2016.09.008.
- [57] S. Kumar, R. Sharma, A. Sharma, and T. Tsunoda, "Decimation filter with Common Spatial Pattern and Fishers Discriminant Analysis for motor imagery classification," in *Proceedings of the International Joint Conference on Neural Networks*, Oct. 2016, vol. 2016-October, pp. 2090–2095, doi: 10.1109/IJCNN.2016.7727457.
- [58] B. Yang, H. Li, Q. Wang, and Y. Zhang, "Subject-based feature extraction by using fisher WPD-CSP in brain-computer interfaces," *Comput. Methods Programs Biomed.*, vol. 129, pp. 21–28, Jun. 2016, doi: 10.1016/j.cmpb.2016.02.020.
- [59] C. M. Bishop, "Bishop - Pattern Recognition And Machine Learning - Springer 2006," *Antimicrob. Agents Chemother.*, 2014.
- [60] "Data sets - BNCI Horizon 2020." <http://bnci-horizon-2020.eu/database/data-sets> (accessed Feb. 16, 2021).

- [61] “g.tec medical engineering GmbH | Brain-Computer Interfaces and Neurotechnology.” <https://www.gtec.at/> (accessed Feb. 16, 2021).
- [62] “Welcome to Python.org.” <https://www.python.org/> (accessed Feb. 16, 2021).
- [63] “MNE — MNE 0.22.0 documentation.” <https://mne.tools/stable/index.html> (accessed Feb. 16, 2021).
- [64] L. Baldezzari, “Repositorio proyecto final Maestría en DS,” 2021. <https://github.com/lucasbaldezzari/proyectoFinalDS> (accessed Feb. 16, 2021).
- [65] Q. Zhao, L. Zhang, A. Cichocki, and J. Li, “Incremental common spatial pattern algorithm for BCI,” 2008, doi: 10.1109/IJCNN.2008.4634170.
- [66] S. A. Cruces, “Estudio del método Superior de Ingeniería Patterns y sus variantes en interfaces,” *Univ. Sevilla*, 2016.
- [67] B. Blankertz, S. Lemm, M. Treder, S. Haufe, and K. R. Müller, “Single-trial analysis and classification of ERP components - A tutorial,” *Neuroimage*, vol. 56, no. 2, pp. 814–825, 2011, doi: 10.1016/j.neuroimage.2010.06.048.
- [68] E. Thomas, M. Dyson, and M. Clerc, “An analysis of performance evaluation for motor-imagery based BCI,” *J. Neural Eng.*, vol. 10, no. 3, 2013, doi: 10.1088/1741-2560/10/3/031001.
- [69] C. H. Han, E. Kim, and C. H. Im, “Development of a brain–computer interface toggle switch with low false-positive rate using respiration-modulated photoplethysmography,” *Sensors (Switzerland)*, vol. 20, no. 2, Jan. 2020, doi: 10.3390/s20020348.
- [70] T. Nykopp, “Statistical Modelling Issues for The Adaptive Brain Interface.”
- [71] Y. Hou, L. Zhou, S. Jia, and X. Lun, “A novel approach of decoding EEG four-class motor imagery tasks via scout ESI and CNN,” *J. Neural Eng.*, vol. 17, no. 1, 2020, doi: 10.1088/1741-2552/ab4af6.