



CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS
DEL INSTITUTO POLITÉCNICO NACIONAL
UNIDAD MONTERREY

Clasificación de señales electroencefalográficas usando la
coherencia parcialmente dirigida

Tesis que presenta

Jorge Antonio Gaxiola Tirado

Para obtener el grado de

Maestro en Ciencias en
Ingeniería y física biomédicas

Director de tesis: Dr. David Gutiérrez Ruiz

Co-directora: Dra. Rocío Salazar Varas

Agradecimientos

Quiero agradecer a la Dra. Dania Gutiérrez por la confianza brindada para formar parte de su grupo de trabajo. A la Dra. Rocío Salazar por la paciencia, tiempo y conocimientos compartidos.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por la beca de manutención y por el financiamiento otorgado a través del Proyecto de Ciencia Básica no. 220145.

A mi familia, en especial a mi padre Jorge (1961-2015) que fue mi principal aliado para comenzar este proyecto de maestría y sigue siendo mi principal motivador. A mi madre Tere y hermana Yuliana por el apoyo y la confianza que me brindan.

A todo el personal académico, administrativo y de servicio del CINVESTAV Monterrey, por las facilidades y el conocimiento brindado.

Índice general

1. Introducción	1
1.1. Antecedentes y motivaciones	4
1.2. Hipótesis	9
1.3. Objetivos	10
1.3.1. Objetivo general	10
1.3.2. Objetivos particulares	10
1.4. Estructura de la tesis	11
2. Fundamentos	12
2.1. Actividad cerebral	12
2.2. Electroencefalograma	18
2.2.1. Sistema internacional 10-20	19
2.3. Conectividad cerebral	20
2.4. Causalidad de Granger	21
2.5. Coherencia Parcialmente Dirigida	22
3. Metodología	25
3.1. Descripción del método propuesto	25
3.2. Selección de la combinación de alta certidumbre	26
3.2.1. Significancia estadística de la PDC	26
3.2.2. Prueba de Wilcoxon	27
3.3. Clasificación	27
4. Ejemplos numéricos	29

5. Resultados	33
5.1. Selección	33
5.2. Clasificación	44
5.3. Conectividad en reposo	46
5.4. Dirección que más se repite	47
5.5. Evaluación de la conectividad usando red de nueve electrodos	55
6. Conclusiones y trabajo a futuro	57
Bibliografía	60

Índice de figuras

Figura 1: Esquema genérico de una BCI	3
Figura 2: Partes de una neurona	12
Figura 3: Sistema nervioso central	13
Figura 4: Diagrama del encéfalo	14
Figura 5: Principales áreas motoras y sensoriales de la corteza cerebral	15
Figura 6: Áreas motoras y sensoriales de la corteza cerebral	17
Figura 7: Ubicación de electrodos acorde al sistema internacional 10-20	20
Figura 8: Distribución de electrodos de EEG utilizados	30
Figura 9: Direcciones de interconexión en una red de tres electrodos	31
Figura 10: Total de mediciones significativas de cada clase en las seis direcciones de interconexión, para cada una de las 84 combinaciones del sujeto <i>al</i> durante movimiento imaginado	35
Figura 11: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto <i>al</i>	36
Figura 12: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto <i>aw</i>	37
Figura 13: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto <i>ay</i>	38
Figura 14: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto <i>aa</i>	39

Figura 15 : Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto <i>av</i>	40
Figura 16: Valores p en escala logarítmica para la dirección $Fz \rightarrow C3$ de la combinación {Fz C3 P3} del usuario <i>al</i>	41
Figura 17 : Combinaciones elegidas para cada voluntario	43
Figura 18 : Total de mediciones significativas de cada clase en las seis direcciones de interconexión, para cada una de las 84 combinaciones del sujeto <i>al</i> durante el reposo	48
Figura 19 : Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones en los periodos de MI y reposo. Sujeto <i>al</i>	49
Figura 20 : Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones en los periodos de MI y reposo. Sujeto <i>av</i>	50
Figura 21: Evaluación de la aparición de las 72 direcciones posibles en cada una de las tareas mentales y en la diferencia entre ellas. Sujeto <i>al</i>	52
Figura 22: Evaluación de la aparición de las 72 direcciones posibles en cada una de las tareas mentales y en la diferencia entre ellas para cada sujeto	53
Figura 23: Evaluación de la conectividad usando una red de {F3,Fz,F4,C3,Cz,C4,P3,POz,P4} electrodos para el sujeto <i>al</i>	56

Índice de tablas

Tabla 1: Funciones de los lóbulos cerebrales	16
Tabla 2: Combinaciones posibles formadas a partir de los electrodos {F3, Fz, F4, C3, Cz, C4, P3, POz, P4}	32
Tabla 3: Combinación, dirección y banda de frecuencias elegidas para cada sujeto	42
Tabla 4: Porcentajes de clasificación obtenidos al aplicar el método propuesto	45
Tabla 5: Resultados de la BCI competition III	45
Tabla 6: Direcciones formadas al utilizar los electrodos {F3,Fz,F4,C3,Cz,C4,P3,POz,P4}	51
Tabla 7: Direcciones más recurrentes para cada sujeto	54

Abreviaturas

BCI	Brain-computer interface (interfaz cerebro-computadora)
PDC	Partial directed coherence (coherencia parcialmente dirigida)
ECoG	Electrocorticografía
EEG	Electroencefalografía
MEG	Magnetoencefalografía
ERD	Event-related desynchronization (desincronización relacionada a evento)
ERS	Event-related synchronization (sincronización relacionada a evento)
SNC	Sistema nervioso central
MI	Movimiento imaginado
ERP	Event-related potential (potenciales relacionados a eventos)

Resumen

Para generar un comando de control exitoso en una interfaz cerebro-computadora (BCI, por sus siglas en inglés), es necesario establecer una correcta relación entre la señal cerebral registrada y un evento mental determinado. Dicha relación depende de una extracción óptima de características y de una buena clasificación.

En este trabajo se propone un método para el análisis y la clasificación de señales de EEG basado en la coherencia parcialmente dirigida (PDC, por sus siglas en inglés). Esta métrica permite conocer, en el dominio de la frecuencia, la interacción dirigida existente entre un conjunto de señales provenientes de diferentes electrodos. Entonces, la propuesta aquí es utilizar esta información para identificar y evaluar las redes que surgen debido a diferentes tareas mentales.

En función de las interacciones significativas para cada tarea mental, se selecciona la red de electrodos que brinda mayor certidumbre en la discriminación de las señales. La clasificación se lleva a cabo por un sistema de votos, evaluando la magnitud de los valores de PDC del nuevo dato para las diferentes tareas mentales.

Una característica destacable del método es que opera con un número reducido de electrodos, haciéndolo atractivo para aplicaciones de BCI en escenarios reales. Los electrodos son seleccionados sin conocimiento *a-priori* de las tareas mentales involucradas. Aún así, los electrodos utilizados resultan ser aquellos relacionados por su distribución espacial con las tareas mentales desarrolladas. Los resultados obtenidos en la clasificación muestran que el método propuesto tiene un desempeño satisfactorio.

Abstract

To generate a successful command control on a brain-computer interface (BCI), it is necessary to establish a proper relationship between the recorded brain signal and a certain mental event. The ability on establishing such relationship depends on optimal feature extraction and good classification.

This thesis presents a method for the analysis and classification of electroencephalographic (EEG) signals based on the partial directed coherence (PDC). This metric provides information, in the frequency domain, about the existing directed interaction between a set of signals from different electrodes. Here, this information is used to identify and evaluate sensor networks associated to different mental tasks.

According to the significant interactions for every mental task, the sensor network that provides the greatest certainty in discriminating signals is selected. Then, the classification of the EEG signals for different tasks is performed through a voting system, in which the magnitude of the PDC values are compared for the mental tasks.

A remarkable feature of the proposed method is that it operates with a reduced number of electrodes, making it attractive for realistic BCI applications. The electrodes are selected without *a-priori* knowledge of mental tasks involved. Yet, the electrodes are those which are spatially related to the mental tasks. The results obtained in the classification show that the proposed method has good performance.

Capítulo 1

Introducción

El control de nuestras extremidades es de suma importancia para interaccionar con nuestro entorno. Sin embargo, existen diversas patologías como la esclerosis lateral amiotrófica, la lesión de la médula espinal, entre otras, que ocasionan una disminución o ausencia total de la capacidad motora. Una tecnología que puede ayudar a personas con este tipo de deficiencias es la interfaz cerebro-computadora (*brain-computer interface* o BCI). Una BCI es un dispositivo que permite la comunicación de una persona con su entorno a partir de la actividad eléctrica del cerebro sin la asistencia de nervios periféricos o actividad muscular [1].

El principal objetivo de una BCI es brindar un canal de comunicación alternativo al motriz que permita el control de un dispositivo externo. En general, una BCI consta del registro de la actividad eléctrica cerebral, su procesamiento y la posterior asociación con un comando de control capaz de accionar el dispositivo.

Actualmente existen diversas aplicaciones asociadas a las BCIs: para el control de prótesis, deletreadores de palabras, control de sillas de ruedas o de algún dispositivo robótico, e incluso se han utilizado como medio para la evaluación en el proceso de aprendizaje de una tarea específica [2-6]. Recientemente también se han utilizado para entender de mejor manera los procesos neuronales que se desencadenan en cada usuario y evaluar su capacidad para operar un sistema BCI [7].

Independientemente de la aplicación final de la BCI, desde la adquisición de la actividad eléctrica cerebral hasta la generación del comando de control, usualmente son requeridas las siguientes etapas para su implementación [1]:

1. Adquisición de la señal: Consiste en la captura de la actividad eléctrica cerebral. Puede realizarse mediante técnicas invasivas, como la electrocorticografía (ECoG), y no invasivas, como la electroencefalografía (EEG) y la magnetoencefalografía (MEG). En sistemas BCI se ha preferido el uso de la EEG ya que es una técnica no invasiva, de bajo costo y de fácil instrumentación.

2. Procesamiento de la señal: Asocia la señal registrada con comandos de control para el dispositivo. Este bloque se divide en tres etapas que actúan de manera secuencial, las cuales son:

- **Preprocesamiento:** Se eliminan artefactos debido a otros tipos de actividades como el movimiento ocular y muscular o el producido por la línea eléctrica. Además, la señal filtrada es amplificada, ya que las señales de EEG son extremadamente pequeñas (en el orden de los μV).
- **Extracción de características:** En esta etapa se traduce la señal cerebral en un conjunto de características correlacionadas con el fenómeno estudiado. Esto se hace con el objetivo de generar una representación reducida y significativa de la señal, usualmente en forma de vector, que es empleada en la siguiente etapa de clasificación.
- **Clasificación:** Esta es la etapa crucial del procesamiento. Todo sistema BCI relaciona la señal registrada con un evento mental determinado (clase). Para esto, el sistema debe entrenarse previamente con un conjunto de datos representativos para cada clase.

- 3. Control:** Una vez que la señal registrada se asigna a una clase y se emite un comando de control vinculado con la actividad cerebral correspondiente. Esto tiene el fin de controlar un dispositivo externo.

En la Figura 1 se muestran las etapas antes descritas mediante un esquema representativo de un sistema típico de BCI.

La generación de un comando de control exitoso depende de establecer una correcta relación entre la señal registrada y un evento fisiológico determinado. Aunque dicha relación se establece en la etapa de clasificación, el éxito de esta asociación depende también de la información que le es ingresada al clasificador. Esto hace de la extracción de características una etapa de vital importancia.

La señal de EEG incluye una gran variedad de patrones o ritmos. Estos pueden ser identificados por su frecuencia, morfología en función del sitio de registro, entre otras, para ser utilizados como las características más representativas de la señal.

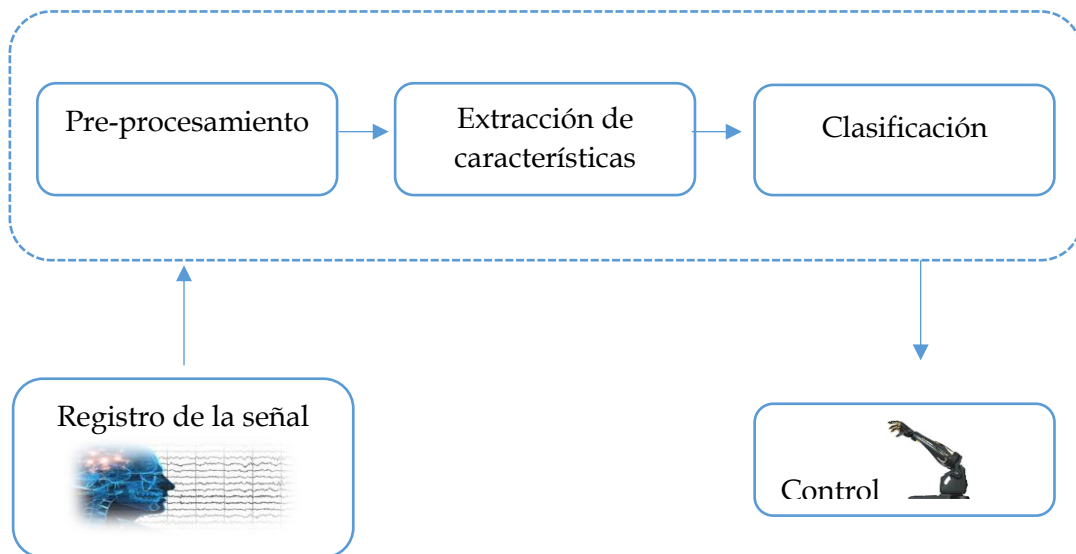


Figura 1: Esquema genérico de una BCI.

Los algoritmos enfocados a la extracción de características basan su análisis en el dominio del tiempo o de la frecuencia [1]. Los algoritmos basados en el dominio del tiempo dependen de la variación temporal de la señal, para buscar cambios en la actividad cerebral producidos por cierto evento. En el dominio de la frecuencia, por lo general se analiza la potencia en distintas bandas de frecuencia. También existen análisis espaciales, en donde los algoritmos generalmente ponderan las aportaciones de distintas señales según la posición donde están siendo registradas [1,2].

Por otra parte, se ha demostrado que la estimación de parámetros en modelos autorregresivos es un método útil para describir la actividad de EEG, lo que lo hace útil para aplicaciones de BCI [8].

1.1. Antecedentes y motivaciones

El cambio en la actividad cerebral utilizada para aplicaciones BCI puede generarse de manera voluntaria o involuntaria. De manera involuntaria, el cambio se genera por la percepción de algún estímulo que puede ser auditivo, sensitivo o visual, o por un evento determinado (por ejemplo, iniciar un movimiento). De aquí surgen los *potenciales relacionados a eventos*, los cuales refieren a cambios en la amplitud de la actividad cerebral que se presentan sincronizados a un evento determinado [9]. Las BCI que utilizan este tipo de potenciales se conocen como BCI basados en potenciales relacionados a eventos (ERP, por sus siglas en inglés).

La *actividad cerebral modulada* voluntariamente, se refiere a las oscilaciones cerebrales que están siempre presentes y varían su amplitud dependiendo del estado mental del sujeto, de sus pensamientos o de determinadas acciones (por ejemplo, la realización de un movimiento provoca que disminuya la potencia espectral de la señal eléctrica cerebral en la banda de frecuencia μ). Por esta

razón, una BCI basada en actividad modulada ejecutará la acción para la que esté destinada cuando el usuario así lo decida. La frecuencia es el parámetro clave para llevar a cabo la interpretación fisiológica [10]. Históricamente, los ritmos cerebrales se han dividido en cinco bandas de frecuencia: α (que incluye al ritmo μ), β , γ , δ y θ . Los más utilizados para aplicaciones BCI son los ritmos *sensoriomotores* μ y β , los cuales se describen a continuación:

- **Ritmo μ :** Se encuentra en la banda de frecuencia de 8-13 Hz y está relacionado con las funciones motoras del cerebro. Su registro se realiza en la corteza motora, en el lado contra-lateral al miembro en movimiento. Tiende a disminuir su amplitud cuando una persona realiza un movimiento, por lo que se le denomina como un evento relacionado a desincronización (*event-related desynchronization* o ERD) de la banda μ . Se ha demostrado que se presenta un efecto similar de desincronización de la onda μ cuando se imagina el movimiento. Esta característica la hace útil como señal de control de un sistema BCI [11,12].
- **Ritmo β :** Se encuentra en la banda de frecuencia de 14-30Hz. Es común dividirlo en varias sub-bandas. Una de ellas, la central (alrededor de los 18-26 Hz), se ve afectada por la imaginación o ejecución de movimientos. Se ha demostrado que este ritmo incrementa su amplitud después de la imaginación o ejecución de un movimiento, a lo que se denomina como un evento relacionado a sincronización (*event-related synchronization* o ERS) de la banda β [13].

Se han propuesto diferentes procedimientos para la extracción de características, tales como el filtrado espacial, el análisis espectral o la separación de las componentes independientes [9]. Un compendio de

diferentes algoritmos, se encuentra en [14]. Muchos algoritmos de clasificación, tales como redes neuronales artificiales, inducen clasificadores con desempeños superiores al umbral funcional de una BCI. Sin embargo, no dan una idea del proceso real que se oculta detrás del problema. En la práctica una buena clasificación sin una explicación del fenómeno involucrado es poco útil [15].

Recientemente se propuso un método de extracción de características y clasificación de señales EEG basado en la coherencia [16]. Este método selecciona un conjunto óptimo de electrodos para cada usuario, relacionado con la tarea mental desarrollada. La coherencia proporciona un sentido de conectividad del cerebro, pues es una métrica que indica el grado de correlación de la potencia espectral de dos señales (e.g., la señal de EEG adquirida en dos distintos electrodos) para una frecuencia específica. Su valor está dentro del intervalo de cero a uno. Valores cercanos a uno indican que existe correlación entre las señales.

En [16] se alcanzó una efectividad de hasta 73.6% en la clasificación, destacando el hecho de que este nivel se obtuvo utilizando únicamente tres electrodos. Estos electrodos fueron seleccionados en función de los valores de coherencia para cada clase. Sin embargo, al hacer una evaluación de todas las combinaciones posibles y seleccionar las que ofrecen mayor certidumbre en la clasificación, hay casos en los que se obtiene más de una combinación posible, existiendo electrodos comunes entre las diferentes combinaciones. Esto lleva a pensar que el empleo de la coherencia puede estar brindando información redundante.

Partiendo del hecho de que la coherencia indica solamente el grado de correlación de las señales EEG, en este trabajo se propone evaluar la direccionalidad (interacciones causales, es decir, los efectos direccionales entre

las distintas unidades neuronales) en la conectividad. De esa manera se podrá obtener características más detalladas que describan de una mejor manera la actividad mental desarrollada. La métrica que proporciona dicha información de direccionalidad es la coherencia parcialmente dirigida (partial directed coherence, o PDC) [17].

Antecedentes sobre el uso de la PDC en el estudio de la conectividad cerebral se encuentran en [18]. Allí se utilizó para describir interacciones entre conjuntos neuronales para caracterizar estados de comportamiento bien definidos. En [19] se propone la aplicación de la PDC para el análisis de la conectividad de datos de resonancia magnética funcional utilizando bootstrap multivariante. Por otro lado, en [20] se estimaron los patrones de conectividad de EEG en pacientes con epilepsia fotosensible, esto para investigar si la red neuronal sufría cambios dinámicos antes y durante la transición a una descarga epiléptica. De igual modo, en [21] la PDC se utilizó como característica para la clasificación de señales de EEG.

Respecto al número de clases utilizadas en la clasificación, un número elevado de tareas permite un control más fino, ya que facilita la toma de decisiones cuando se dispone de más comandos. Sin embargo, existen estudios que demuestran que al aumentar el número de clases a clasificar, disminuye la probabilidad de acierto en la clasificación [22-24]. En [23] se llega a la conclusión de que el número óptimo depende del sujeto y del tipo de aplicación usada. En general, apoyándose en otros estudios que ahí se referencian, es posible establecer que el número óptimo es de tres a cuatro tareas. Sin embargo, la mayor exactitud en la clasificación se obtiene cuando sólo dos tareas son discriminadas.

Por otro lado, una cuestión crucial en el diseño de experimentos de BCI basados en EEG, es la selección de electrodos. Si bien contar con muchos

electrodos puede brindar un mejor desempeño en la clasificación, puede traer consigo una alta carga computacional. Además consideraciones prácticas como la fácil instrumentación y la comodidad del sujeto, sugieren la necesidad de trabajar con un número reducido de electrodos. En [25] se pueden consultar algunos algoritmos utilizados para la selección de electrodos usando EEG. Estos algoritmos buscan mejorar el rendimiento y la comodidad del usuario, así como reducir el costo computacional. Sin embargo, reducir demasiado el número de electrodos puede ocasionar pérdida de información, por lo que se debe buscar un balance adecuado [26-28].

1.2. Hipótesis

En función de lo expuesto anteriormente, este trabajo se plantea la siguiente hipótesis:

Evaluar la direccionalidad de las interacciones entre diferentes áreas cerebrales en función a una tarea mental permitirá seleccionar un conjunto **óptimo** de electrodos relacionados con dicha tarea. Dicha interacción podrá ser utilizada como característica para la clasificación de señales de EEG, además de brindar información fisiológica del proceso en estudio.

1.3. Objetivos

Para comprobar la hipótesis, en este trabajo se desarrollaron los siguientes objetivos:

1.3.1. Objetivo general

Desarrollar un método de extracción de características y clasificación de señales de EEG basado en la coherencia parcialmente dirigida y enfocado al control de una BCI.

1.3.2. Objetivos particulares

- 1.- Establecer redes de interconexión en los procesos mentales utilizando la coherencia parcialmente dirigida.
- 2.- Analizar la información de direccionalidad para discriminar entre diferentes procesos mentales.

1.4. Estructura de la tesis

En el Capítulo 2 se introducen conceptos básicos que ayudarán a la mejor comprensión del trabajo. Por ejemplo, se describe a groso modo la anatomía del cerebro, se habla de la técnica de EEG y algunos conceptos de conectividad cerebral.

Dentro del Capítulo 3 se desarrolla el método propuesto para seleccionar un conjunto reducido de electrodos adecuado para cada usuario. El conjunto seleccionado se emplea para discriminar entre dos tareas mentales mediante el estudio de la conectividad entre diferentes áreas cerebrales.

En el Capítulo 4 se demuestra la aplicabilidad del método propuesto. Para esto se realizan una serie de ejemplos numéricos que emplean una base de datos de EEG proveniente de la tercera competencia internacional de BCI.

En el Capítulo 5 se muestran los resultados obtenidos tras aplicar el método propuesto. Igualmente, en este capítulo se incluyen otros análisis de la conectividad que resultaron de interés. Estos incluyen: la conectividad en estado de reposo, la dirección de conectividad con mayor frecuencia de aparición entre todas las redes y la evaluación de la conectividad usando una red de nueve electrodos.

Finalmente en el Capítulo 6 se enlistan comentarios finales, conclusiones y trabajo a futuro.

Capítulo 2

Fundamentos

Este apartado presenta los fundamentos teóricos necesarios para tener una mejor comprensión del método propuesto. Así, en este capítulo se hace una breve descripción de la anatomía del cerebro, de la técnica de EEG y se introducen conceptos de conectividad cerebral. La información e imágenes relativas a la anatomía cerebral fueron extraídas de [29].

2.1. Actividad cerebral

El sistema nervioso está compuesto por millones de células llamadas neuronas que se interconectan formando redes complejas. Estas células interactúan entre sí mediante impulsos eléctricos a través de las dendritas y los axones (Figura 2). Las dendritas son prolongaciones delgadas y ramificadas que se extienden desde el citoplasma del cuerpo celular. Éstas proporcionan un área receptiva que transmite impulsos electroquímicos graduados hacia el cuerpo celular. El axón es una prolongación más larga que conduce impulsos, llamados *potenciales de acción* desde el cuerpo celular hacia la periferia.

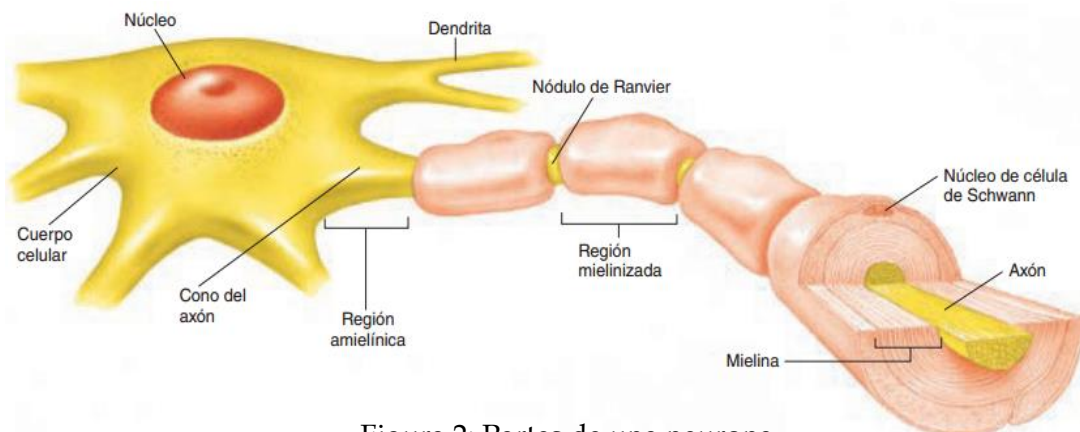


Figura 2: Partes de una neurona.

Los axones terminan cerca de otra célula o en algunos casos en algún punto de contacto. Una vez que los potenciales de acción llegan al final de un axón, estimulan o inhiben de manera directa o indirecta a la otra célula. Los potenciales de acción casi siempre se detienen en la terminal del axón donde estimulan la liberación de un neurotransmisor que afecta la siguiente célula. A esta conexión se le llama *sinapsis*.

El sistema nervioso central (SNC) está formado por el encéfalo y la médula espinal (Figura 3). El SNC recibe aferencias provenientes de neuronas sensoriales y dirige la actividad de neuronas motoras que inervan músculos y glándulas.




Figura 3: Sistema nervioso central

La mayor porción del encéfalo es el cerebro, el cual desempeña casi todo lo que se considera como funciones superiores del encéfalo (como el aprendizaje y la memoria). El cerebro consta de dos hemisferios, derecho e izquierdo, conectados internamente por un tracto grande de fibras llamado cuerpo caloso. El cuerpo caloso es el principal tracto de axones que interconecta funcionalmente ambos hemisferios cerebrales. Los dos hemisferios cerebrales muestran cierta especialización de función, fenómeno llamado *lateralización cerebral*.

Cada hemisferio está subdividido por surcos profundos, o cisuras, formando cinco lóbulos, cuatro de los cuales son visibles desde la superficie (Figura 4). Estos lóbulos son el frontal, parietal, temporal y occipital, y la ínsula. Ésta última se encuentra en planos profundos, cubierta por porciones de los lóbulos frontal, parietal y temporal. Las funciones de los lóbulos cerebrales se resumen en la Tabla 1.




Figura 4: Diagrama del encéfalo mostrado desde a) plano sagital y b) plano horizontal. Los colores indican los lóbulos cerebrales. En amarillo el lóbulo frontal, en azul el parietal, en verde el occipital y en rosa el temporal.

El lóbulo frontal es la porción anterior de cada hemisferio cerebral. Una cisura profunda, llamada *surco central*, separa el lóbulo frontal del lóbulo parietal. La *circunvolución precentral* (Figuras 4 y 5), involucrada en el control motor, está ubicada en el lóbulo frontal justo enfrente del surco central. Los cuerpos celulares de las interneuronas allí localizadas se llaman *neuronas motoras superiores* debido a su papel en la regulación muscular. La *circunvolución poscentral* está localizada justo detrás del surco central en el lóbulo parietal, y es el área primaria de la corteza de la cual depende la percepción de la *sensación somatoestésica*. Este tipo de sensación surge a partir de receptores cutáneos, musculares, tendinosos y articulares.




Figura 5: Principales áreas motoras y sensoriales de la corteza cerebral.

<i>Lóbulo</i>	<i>Funciones</i>
<i>Frontal</i>	Control motor voluntario de músculos esqueléticos; personalidad; procesos intelectuales superiores (concentración, planeación y toma de decisiones); comunicación verbal.
<i>Parietal</i>	Interpretación somatoestésica (e.g., sensaciones cutáneas y musculares); entendimiento del habla y formulación de palabras para expresar pensamientos y emociones; interpretación de texturas y formas.
<i>Temporal</i>	Interpretación de sensaciones auditivas; almacenamiento de experiencias auditivas y visuales.
<i>Occipital</i>	Integración de movimientos en el enfoque de los ojos; correlación de imágenes visuales con experiencias visuales previas y otros estímulos sensoriales; percepción consciente de la visión.
<i>Ínsula</i>	Memoria; integración sensorial (principalmente dolor) y visceral

Tabla 1: Funciones de los lóbulos cerebrales.

Las circunvoluciones precentral (motora) y poscentral (sensitiva) se han mapeado en pacientes conscientes en quienes se practica intervención quirúrgica del encéfalo. La estimulación eléctrica de áreas específicas de la circunvolución precentral causa movimientos específicos, mientras que la estimulación de diferentes áreas de la circunvolución poscentral evoca sensaciones en partes específicas del cuerpo. Los mapas típicos de estas regiones muestran una imagen del cuerpo cabeza abajo esquematizado en la Figura 6.




Figura 6: Áreas motoras y sensoriales de la corteza cerebral.

2.2. Electroencefalograma

Los potenciales sinápticos crean corrientes eléctricas que pueden medirse mediante electrodos colocados en el cuero cabelludo. El registro de estas corrientes eléctricas se llama electroencefalograma (EEG). La intensidad de las ondas cerebrales obtenidas en la superficie del cuero cabelludo varía de 0 a 200 μV , y su frecuencia oscila desde una vez cada varios segundos hasta 50 o más por segundo. El carácter de las ondas depende del grado de actividad en las porciones respectivas de la corteza cerebral, con sensibles variaciones entre los estados de vigilia, de sueño y coma.

En circunstancias normales hay cuatro tipos de patrones en el EEG:

Las *ondas α* se registran mejor en las regiones parietal y occipital mientras una persona está despierta y relajada pero con los ojos cerrados. Estas ondas son oscilaciones rítmicas de 8 a 12 Hz.

Las *ondas β* son más intensas en los lóbulos frontales, especialmente en el área cerca de la circunvolución precentral. Estas ondas se producen por estímulos visuales y actividad mental. Dado que muestran respuesta a estímulos provenientes de receptores y están superpuestas sobre los patrones de actividad continuos, constituyen actividad evocada. Las ondas β ocurren a una frecuencia de 13 a 25 Hz.

Las *ondas θ* provienen de los lóbulos temporal y occipital. Tienen una frecuencia de 5 a 8 Hz, y son comunes en recién nacidos y en adultos que están durmiendo. El registro de las ondas θ en adultos despiertos por lo general indica estrés emocional intenso, y puede ser un precursor de una crisis nerviosa.

Las *ondas δ* al parecer se emiten en un patrón general a partir de la corteza cerebral. Estas ondas tienen una frecuencia de 1 a 5 Hz, y son comunes durante el sueño y en un lactante despierto.

2.2.1. Sistema internacional 10-20

Con el fin de estandarizar la ubicación de los sensores en EEG, se define el sistema internacional 10-20 que, para estudios clínicos, usualmente emplea 21 electrodos. El sistema 10-20 toma como referencia la distancia entre el nasion (intersección del hueso frontal y los dos huesos nasales) y el inion (la mayor protuberancia del hueso occipital) sobre el vértice en la línea media [30].

A lo largo de la línea media se marcan cinco puntos, designados como: polo frontal (Fp), frontal (F), central (C), parietal (P) y occipital (O). El primer punto Fp, es colocado al 10% de la distancia nasión-inión por encima del nasión; el segundo punto F es colocado al 20% de esta distancia a partir del punto Fp, y así sucesivamente en un 20% hacia atrás para los puntos C, P y O.

Las mediciones laterales se basan en la distancia existente entre los puntos preauriculares pasando por el vértex. El 10% de esta distancia se toma para el punto temporal desde el preauricular en ambos lados. Los puntos centrales se marcan 20% de la distancia por encima de los puntos temporales.

El resto de los electrodos medio-frontales (F3 y F4) y medio-parietales (P3 y P4) se colocan a lo largo de las líneas coronales frontal y parietal, respectivamente, a medio camino entre la línea media y la línea temporal de los electrodos a cada lado. La disposición final de todos los electrodos se esquematiza en la Figura 7.




Figura 7: Ubicación de electrodos acorde al sistema internacional 10-20 para los planos sagital (izquierda) y horizontal (derecha). Figura tomada de [31].

2.3 Conectividad cerebral

La comprensión y el modelado de la función cerebral no solo se basan en la identificación correcta de las regiones activas del cerebro, sino que también se consideran las interacciones funcionales entre los conjuntos neuronales distribuidos en diferentes regiones del cerebro [32]. Estos conceptos se denominan en neurociencias como *segregación funcional*, que se refiere a la activación de regiones especializadas del cerebro, e *integración*, lo que está relacionado con la activación coordinada de un gran número de conjuntos neuronales distribuidos en diferentes áreas corticales que constituyen los sistemas distribuidos a gran escala de la cerebral corteza [33-35].

La integración de las áreas cerebrales se puede medir evaluando la conectividad cerebral, la cual se ha dividido principalmente en dos tipos: funcional y efectiva [35,36]. Sin embargo, en [34] se sugiere una nueva división agregando a las antes mencionadas la conectividad neuroanatómica.

La *conectividad neuroanatómica* es difícil de definir debido a la escala microscópica de las neuronas. Las nuevas conexiones sinápticas o eliminación de las existentes ocurren dinámicamente y dependen en gran medida de la función ejecutada [37].

La *conectividad funcional* se define como la correlación temporal (en términos de dependencia estadísticamente significativa) de la actividad neurofisiológica entre regiones del cerebro que podrían estar anatómicamente distantes [34,36].

La *conectividad efectiva* se define como la influencia que un sistema neuronal ejerce sobre otro [38]. Describe las interacciones dinámicas de direccionalidad entre diferentes regiones del cerebro y puede verse como la unión de conectividad neuroanatómica y la funcional, pues describe las interacciones causales, es decir, los efectos direccionales entre las distintas unidades neuronales.

Por otro lado, en [32] se propone un cambio en la forma de clasificar las interacciones y proponen distinguir entre conexiones activas e inactivas, además de que se precise si la conectividad es *directa* (porque se lleva a cabo sin la intervención de estructuras intermedias) o *indirecta* (porque se lleva a cabo a través de estructuras intermedias).

2.4. Causalidad de Granger

El registro simultáneo de señales provenientes de diferentes sitios de medición (canales) puede verse como un conjunto de datos multivariable. Así, la actividad registrada en un canal puede ser fuente de actividad para otros canales o puede ser transmitida desde la fuente de actividad cortical hasta el canal de destino directamente o través de otros canales. Para conocer estas

relaciones, puede realizarse un análisis de las series temporales que conforman este conjunto multivariable.

En el análisis de series temporales, la predicción es uno de los principales objetivos. Es decir, en la predicción se pretende utilizar las observaciones anteriores para proporcionar la mejor estimación posible de lo que va a ocurrir a continuación. En [39] se introdujo un concepto conocido popularmente como causalidad de Granger (G causalidad). Por definición, una serie de tiempo observada $x_j(n)$ es Granger causal de otra serie $x_i(n)$, si el conocimiento del comportamiento de $x_j(n)$ en el pasado es útil en la predicción de $x_i(n)$. Una de las propiedades interesantes de la G causalidad es que es inherentemente direccional, es decir: $G: x_j(n) \rightarrow x_i(n)$ no implica que $G: x_i(n) \rightarrow x_j(n)$.

Esto puede interpretarse como una indicación de cómo fluye la información a partir de una variable observada a otra, lo que condujo al término *interacción dirigida*. Una métrica que permite conocer las relaciones causales directas en el dominio de la frecuencia es la PDC, la cual es descrita a continuación.

2.5. Coherencia parcialmente dirigida

Una manera sencilla de describir el comportamiento dinámico de un conjunto de M series temporales multivariantes es a través de vectores de modelos autoregresivos:

$$\begin{bmatrix} x_1(n) \\ \vdots \\ x_N(n) \end{bmatrix} = \sum_r A_r \begin{bmatrix} x_1(n-r) \\ \vdots \\ x_N(n-r) \end{bmatrix} + \begin{bmatrix} w_1(n) \\ \vdots \\ w_N(n) \end{bmatrix}, \quad (1)$$

donde $w_i(n)$ representa ruido blanco, y la matriz de coeficientes para el tiempo anterior r está dada por:

$$A_r = \begin{bmatrix} a_{11}(r) & a_{12}(r) & \dots & a_{1N}(r) \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & a_{ij}(r) & \vdots \\ a_{N1}(r) & \dots & \dots & a_{NN}(r) \end{bmatrix}, \quad (2)$$

La cual a su vez está formada por los coeficientes $a_{ij}(r)$ que representan el efecto de interacción lineal de $x_j(n-r)$ en $x_i(n)$. Por otro lado, los coeficientes $w_i(n)$ representan los procesos de innovación estocásticos, esto es, la parte del comportamiento dinámico que no se puede predecir a partir de observaciones pasadas de los procesos. Entonces, los coeficientes $w_i(n)$ no están correlacionados en el tiempo pero pueden exhibir correlaciones instantáneas entre sí, que se describen por su matriz de covarianza.

La ecuación (2) resume una primera aproximación lineal para describir las interacciones entre las $x_i(n)$ series de tiempo. Los coeficientes $a_{ij}(r)$ se pueden obtener mediante la minimización adecuada del error cuadrático medio de predicción:

$$E \left[\left| x(n) - \hat{x}(n) \right|^2 \right], \quad (3)$$

donde $x(n) = [x_1(n), \dots, x_N(n)]^T$ son las observaciones y $\hat{x}(n) = \sum_{r=1}^p A_r x(n-r)$ es el predictor lineal de $x(n)$, dado su pasado (hasta el tiempo p , donde p define el orden del modelo). Es posible expresar la matriz de coeficientes en el dominio de la frecuencia mediante la siguiente transformación:

$$A(f) = \sum_{r=1}^p A_r z^{-r} \Big|_{z=e^{-2\pi jf}}, \quad (4)$$

donde $i = \sqrt{-1}$ y $|f| \leq 0.5$ es la frecuencia normalizada, de manera que $f=0.5$ representa la mitad de la frecuencia de muestreo F_s .

Así pues, la PDC se define como una medida en el dominio de la frecuencia de las relaciones causales directas [17,32], y matemáticamente se expresa como:

$$\pi_{i \leftarrow j}(f) = \frac{\bar{A}_{ij}(f)}{\sqrt{\bar{\alpha}_j(f)\alpha_j(f)}} \quad , \quad (5)$$

donde $\bar{A}_{ij}(f)$ es el i,j -ésimo elemento de la matriz $\bar{A}(f) = I - A(f)$ y $\alpha_j(f)$ es la j -ésima columna. Es importante notar que:

$$\bar{A}_{ij}(f) = \begin{cases} 1 - \sum_{r=1}^p a_{ij} e^{-i2\pi fr} & \text{si } i = j \\ - \sum_{r=1}^p a_{ij} e^{-i2\pi fr} & \text{otro caso} \end{cases} \quad , \quad (6)$$

de manera que la nulidad de $\pi_{i \leftarrow j}(f)$ se rige por la nulidad de coeficientes $a_{ij}(r)$, que sumaliza la influencia de las observaciones pasadas $x_j(n-r)$ ($r=1, \dots, p$) en la variable observada, $x_i(n)$.

La PDC es una cantidad normalizada que describe una relación entre el flujo que envía el canal j a i . Debido a su definición tiene las siguientes propiedades de normalización:

$$0 \leq |\pi_{ij}(f)|^2 \leq 1 \quad , \quad (7)$$

$$\sum_{i=1}^N |\pi_{ij}(f)|^2 = 1 \quad . \quad (8)$$

Capítulo 3

Metodología

En este capítulo se describe el método propuesto, así como el procedimiento para la elección de la combinación que brinda más certidumbre en la clasificación.

3.1. Descripción del método propuesto

Partiendo de un conjunto de K mediciones de EEG, tomadas con M electrodos $S = \{S_1, S_2, \dots, S_M\}$, hagamos la suposición de que existe un conjunto de L electrodos, $S' = \{S'_1, S'_2, \dots, S'_L\} \subset S$ con $L \ll M$, en donde existe al menos una conectividad dirigida significativa asociada a una tarea mental determinada. El objetivo del método propuesto es hallar dicho conjunto de L electrodos.

En primera instancia, se analizarán todas las posibles redes de L electrodos, obteniendo un total de $\binom{M}{L}$ combinaciones. Para cada una de las combinaciones se calcula la PDC mediante (5) en cada una de sus L permutaciones tomadas en grupos de dos (denotado como ${}_L P_2$) direcciones de interconexión en un rango de frecuencia de interés para las K mediciones de cada una de las I tareas mentales (clases).

El siguiente paso del método propuesto consiste en evaluar la significancia estadística de la PDC en las ${}_L P_2$ direcciones, mediante el umbral establecido por [40,41] en el rango de frecuencias a evaluar. Más detalles de este proceso se dan en la Sección 3.2.1, y a través de él se garantiza que el valor de PDC expresa una verdadera conectividad y no es fruto del azar. Dicha

evaluación se realiza en cada una de las $\binom{M}{L}$ combinaciones para las K mediciones, y para cada una de las I clases.

A partir de esta información, se elige la combinación de L electrodos que contenga al menos una conectividad significativa y que presente las mayores diferencias entre clases en una banda de frecuencias determinada. El criterio de selección está basado en el número de mediciones significativas resultantes. Adicionalmente, a fin de corroborar que la combinación seleccionada también exhibe diferencias en la magnitud de la PDC, se realiza la prueba estadística de Wilcoxon para comparar los valores de PDC de las clases implicadas.

3.2. Selección de la combinación de alta certidumbre

En esta sección se describen las herramientas utilizadas para elegir la combinación que brinda más certidumbre en la clasificación.

3.2.1. Significancia estadística de la PDC

Con el fin de garantizar que el valor de la PDC exprese una verdadera conectividad, se requiere evaluar su significancia estadística. En el presente trabajo se hace uso del método propuesto en [40,41], en el cual se demuestra que bajo la hipótesis nula de $H_0 : |A_{kj}(w)|^2 = 0$, para $w=2\pi f$, el umbral H a un nivel de significancia η para $\pi_{i \leftarrow j}(w)$ se puede aproximar por:

$$H = \left(\frac{C_{ij}(w) \chi_{1,1-\eta}^2}{N \sum_k |A_{kj}(w)|^2} \right)^{1/2}, \quad (9)$$

con

$$C_{ij}(w) = \left[\sum_{k,l=1}^p H_{jj}(k,l) (\cos(kw)\cos(lw) + \sin(kw)\sin(lw)) \right], \quad (10)$$

donde $\chi_{1,1-\eta}^2$ es el 1- η cuantil de la distribución χ^2 con un grado de libertad y A_{kj} es el ij -ésimo elemento de la matriz que contiene los coeficientes del modelado autoregresivo multivariable de las señales en la frecuencia w . Entonces, se considera que existe una PDC significativa siempre y cuando su magnitud supere al umbral definido en (9).

3.2.2. Prueba de Wilcoxon

Teniendo un conjunto de valores de PDC correspondientes a distintas mediciones para $I=2$ clases diferentes, se desea saber si provienen de distribuciones distintas, de modo que las señales de EEG puedan ser discriminadas. Dado que la distribución generada por estos valores no es Gaussiana, se aplica una prueba no paramétrica denominada prueba de los rangos con signo de Wilcoxon. Esta prueba opera bajo la hipótesis nula de que las medianas son iguales y la hipótesis alternativa que son diferentes. Esto queda expresado matemáticamente de la siguiente manera:

$$H_0 : \tilde{X}_{c1} = \tilde{X}_{c2} \quad , \quad (11)$$

$$H_a : \tilde{X}_{c1} \neq \tilde{X}_{c2} \quad , \quad (12)$$

donde $\tilde{X}_{(*)}$ indica la mediana correspondiente a una de las clases.

Por lo tanto, la combinación seleccionada es aquella que contiene al menos una conectividad dirigida, en determinada banda de frecuencia, que rechaza la hipótesis nula con un valor de significancia preestablecido.

3.3. Clasificación

Una vez que ha sido seleccionada alguna combinación de electrodos, la clasificación consiste en asignar un nuevo dato (medición cuya actividad mental de origen se desconoce) a una clase determinada. Para ello, se lleva a cabo un proceso de entrenamiento del algoritmo de clasificación. El entrenamiento puede ser supervisado o no supervisado.

En el presente trabajo se realiza un entrenamiento supervisado. Este genera, a partir de un juego de datos del que se conoce *a-priori* la clase a la que pertenecen, un modelo específico para cada clase, que permite discriminar a qué clase corresponde un nuevo dato. De esta manera, un nuevo dato de entrada es asignado a la clase de donde proviene el modelo con el que existe mayor semejanza.

Entonces, partamos de que se tiene identificada la red de electrodos que contiene la conectividad o conectividades dirigidas que ofrecen mayor diferencia entre clases y un rango de frecuencias determinado. De los datos de entrenamiento, se calcula el valor promedio de la PDC para cada frecuencia en el rango seleccionado, y para cada una de las $I=2$ clases. De esta manera se obtiene un *vector plantilla* para cada clase.

Para un nuevo dato, se obtiene el valor de PDC en cada uno de los campos de frecuencia y posteriormente se obtiene un *vector diferencia* para cada clase. La manera de discriminar a qué clase corresponde el nuevo dato es aplicando un sistema de votos: este consiste en que la clase I gana un voto cada vez que la diferencia entre el valor de PDC del nuevo dato y el valor promedio para esa clase es la mínima, en comparación con las otras clases. Así, el nuevo dato es asignado a la clase que haya obtenido el mayor número de votos.

Capítulo 4

Ejemplos numéricos

Las mediciones reales de EEG utilizadas para validar el método propuesto provienen de bases de datos de dominio público. Dichas bases han sido empleadas en el desarrollo de múltiples métodos, lo que permite comparar el desempeño de nuevas técnicas. Los datos provienen de [42] y corresponden a la base de datos IVa de la tercera competencia internacional “BCI Competition III” (<http://www.bbc.de/competition/iii/>). Las mediciones están relacionadas con eventos motrices y contienen registro de cinco sujetos sanos, denominados como *aa*, *al*, *av*, *aw* y *ay*.

Las tareas solicitadas fueron imaginación del movimiento (MI) de la mano derecha (denominado en este trabajo como *clase 1*) e imaginación del movimiento del pie derecho (*clase 2*). El sujeto debía imaginar el movimiento durante 3.5 segundos a partir de la indicación mediante una pantalla posicionada frente a él o ella. El tiempo entre cada indicación fue aleatorio entre 1.75 y 2.25 segundos, tiempo durante el cual el sujeto podía relajarse.

Las bases de datos utilizadas cuentan con un total de 280 mediciones independientes para cada sujeto (140 mediciones por clase), registradas con un arreglo de 118 electrodos a una frecuencia de muestreo de 1000 Hz. Como prueba de concepto, en este trabajo se comenzó la búsqueda a partir de nueve electrodos $M = F3, Fz, F4, C3, Cz, C4, P3, POz, P4$, esquematizados en la Figura 8, esto debido que son los electrodos que maneja el equipo de electroencefalografía B-ALERT X10 y se desea realizar futuras comparaciones con experimentos realizados utilizando este equipo.

Como parte del preprocesamiento, la señal fue submuestreada a 250 Hz. Se aplicó un filtro digital paso banda tipo Butterworth de cuarto orden, con frecuencia de corte inferior de 5 Hz y superior de 100 Hz. Igualmente se aplicó un filtro notch a 50 Hz específico para la interferencia de las líneas de transmisión eléctrica. Todo el procesamiento se realizó en los dos segundos intermedios del intervalo total disponible de 3.5 segundos.

Con respecto a la influencia del volumen de conducción (corrientes volumétricas debidas a las diferencias de conductividad entre los tejidos), una característica de la PDC es que no es sensible a este, ya que se basa en la detección de la diferencia de fase entre las señales. El volumen de conducción presenta una propagación de fase cero, por lo que no influye en esta métrica [32,34,43] y no se hace necesario utilizar procedimientos que realicen la proyección de los potenciales del cuero cabelludo en la corteza cerebral. Por el contrario, en nuestro caso realizar ese procedimiento podría causar una pérdida de las relaciones de causalidad.




Figura 8: Distribución de los electrodos de EEG utilizados, resaltados en verde.

Hay que hacer notar que, para el cálculo de la PDC y su significancia, el orden p del modelo autoregresivo multivariable implicado en dicho cálculo, se determinó mediante el criterio Bayesiano de Schwarz [32] resultando en modelos con un orden óptimo $p=16$ para los cinco voluntarios.

A fin de trabajar con el mínimo número de electrodos posibles, se formaron redes de $L=3$ electrodos, teniendo así, $\binom{9}{3} = 84$ combinaciones posibles (enlistadas en la Tabla 4). Para cada combinación, se calculó la PDC en sus 3P2 direcciones de interconexión tomadas en el orden que se muestra en la Figura 9, y en el rango de frecuencias de 1 a 20 Hz. Posteriormente se aplicó la prueba de significancia descrita en la Sección 3.2.1, con un nivel de significancia de $\eta=0.05$ para cada una de las 140 mediciones. Este proceso se llevó a cabo de manera independiente para cada una de las $I=2$ clases.

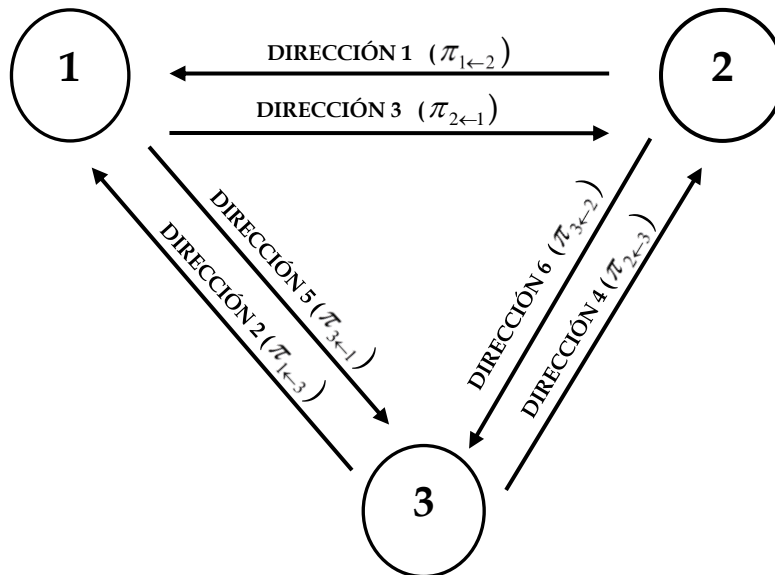


Figura 9: Direcciones de interconexión en una red de tres electrodos.

El siguiente paso fue realizar la comparación entre clases para seleccionar la combinación de electrodos que permitiera una mejor discriminación. Para ello se aplicaron los procedimientos descritos en la Sección 3.2. Posteriormente con la combinación elegida se aplicó el proceso de clasificación descrito en la Sección 3.3.

COMBINACIÓN	RED		
1	'F3'	'Fz'	'F4'
2	'F3'	'Fz'	'C3'
3	'F3'	'Fz'	'Cz'
4	'F3'	'Fz'	'C4'
5	'F3'	'Fz'	'P3'
6	'F3'	'Fz'	'POz'
7	'F3'	'Fz'	'P4'
8	'F3'	'F4'	'C3'
9	'F3'	'F4'	'Cz'
10	'F3'	'F4'	'C4'
11	'F3'	'F4'	'P3'
12	'F3'	'F4'	'POz'
13	'F3'	'F4'	'P4'
14	'F3'	'C3'	'Cz'
15	'F3'	'C3'	'C4'
16	'F3'	'C3'	'P3'
17	'F3'	'C3'	'POz'
18	'F3'	'C3'	'P4'
19	'F3'	'Cz'	'C4'
20	'F3'	'Cz'	'P3'
21	'F3'	'Cz'	'POz'
22	'F3'	'Cz'	'P4'
23	'F3'	'C4'	'P3'
24	'F3'	'C4'	'POz'
25	'F3'	'C4'	'P4'
26	'F3'	'P3'	'POz'
27	'F3'	'P3'	'P4'
28	'F3'	'POz'	'P4'
29	'Fz'	'F4'	'C3'
30	'Fz'	'F4'	'Cz'
31	'Fz'	'F4'	'C4'
32	'Fz'	'F4'	'P3'
33	'Fz'	'F4'	'POz'
34	'Fz'	'F4'	'P4'
35	'Fz'	'C3'	'Cz'
36	'Fz'	'C3'	'C4'
37	'Fz'	'C3'	'P3'
38	'Fz'	'C3'	'POz'
39	'Fz'	'C3'	'P4'
40	'Fz'	'Cz'	'C4'
41	'Fz'	'Cz'	'P3'
42	'Fz'	'Cz'	'POz'
43	'Fz'	'Cz'	'P4'
44	'Fz'	'C4'	'P3'
45	'Fz'	'C4'	'POz'
46	'Fz'	'C4'	'P4'
47	'Fz'	'P3'	'POz'
48	'Fz'	'P3'	'P4'
49	'Fz'	'POz'	'P4'
50	'F4'	'C3'	'Cz'
51	'F4'	'C3'	'C4'
52	'F4'	'C3'	'P3'
53	'F4'	'C3'	'POz'
54	'F4'	'C3'	'P4'
55	'F4'	'Cz'	'C4'
56	'F4'	'Cz'	'P3'
57	'F4'	'Cz'	'POz'
58	'F4'	'Cz'	'P4'
59	'F4'	'C4'	'P3'
60	'F4'	'C4'	'POz'
61	'F4'	'C4'	'P4'
62	'F4'	'P3'	'POz'
63	'F4'	'P3'	'P4'
64	'F4'	'POz'	'P4'
65	'C3'	'Cz'	'C4'
66	'C3'	'Cz'	'P3'
67	'C3'	'Cz'	'POz'
68	'C3'	'Cz'	'P4'
69	'C3'	'C4'	'P3'
70	'C3'	'C4'	'POz'
71	'C3'	'C4'	'P4'
72	'C3'	'P3'	'POz'
73	'C3'	'P3'	'P4'
74	'C3'	'POz'	'P4'
75	'Cz'	'C4'	'P3'
76	'Cz'	'C4'	'POz'
77	'Cz'	'C4'	'P4'
78	'Cz'	'P3'	'POz'
79	'Cz'	'P3'	'P4'
80	'Cz'	'POz'	'P4'
81	'C4'	'P3'	'POz'
82	'C4'	'P3'	'P4'
83	'C4'	'POz'	'P4'
84	'P3'	'POz'	'P4'

Tabla 2: Combinaciones posibles formadas a partir de los electrodos

{F3, Fz, F4, C3, Cz, C4, P3, POz, P4}.

Capítulo 5

Resultados

A continuación se muestran a detalle los resultados y la discusión de los mismos, con los datos del sujeto *al*. Al final de la sección se muestran los resultados para el resto de los sujetos.

5.1. Selección

La Figura 10 muestra los resultados de aplicar la prueba de significancia descrita en la Sección 3.2.1 a las 140 mediciones de cada clase para el sujeto *al*. Para cada recuadro, a lo largo del eje de las abscisas se tiene la frecuencia, y en el eje de las ordenadas a las 84 combinaciones evaluadas. Cada recuadro muestra el resultado para cada una de las dos clases en las seis direcciones de interconexión. La barra de colores indica la cantidad de mediciones que resultaron significativas normalizada con respecto al número de mediciones totales.

Si recordamos, la finalidad es identificar la combinación, dirección y frecuencia donde se presente la mayor diferencia entre clases, todo esto en función del número de mediciones con un valor significativo de PDC. Analizando la Figura 10 se observa que para $\pi_{1\leftarrow 2}$ las combinaciones 29, 30, 33 y 34 en la banda de frecuencia de 1-9 Hz presentan un alto número de mediciones significativas en ambas clases, por lo que esas combinaciones en ese rango de frecuencia no serían útiles para la discriminación de tareas mentales. Por el contrario, la combinación 37 para $\pi_{2\leftarrow 1}$, dentro del rango de frecuencias de 12-15 Hz, puede observarse que aproximadamente un 90% de las mediciones resultaron significativas para la clase 2 y cerca del 5% para la

clase 1. Como este caso, se pueden observar otros más en donde alguna dirección presenta diferencia entre clases.

En la Figura 11 se muestra el resultado, en valor absoluto, de la diferencia entre las dos clases para cada una de las seis direcciones. Nuevamente, el eje de las abscisas corresponde a la frecuencia y el eje de las ordenadas a las 84 combinaciones evaluadas. En cada uno de los recuadros se muestra el resultado para cada una de las seis direcciones de interconexión. La barra de colores expresa una cantidad normalizada con respecto al número de mediciones totales.

En dicha figura se observa que existen diversas bandas de frecuencia donde se presenta notable diferencia entre clases. Por ejemplo, para $\pi_{2\leftarrow 1}$ las combinaciones 37 y 16 en la banda de frecuencia de 12-16 Hz y para $\pi_{1\leftarrow 2}$ la combinación 66 en el rango de 12-18 Hz. Sin embargo no fue posible encontrar una red completamente interconectada, pues como se observa, estas bandas pertenecen a diferentes combinaciones de electrodos.

Como ya se mencionó anteriormente, se busca la combinación que presente la mayor diferencia entre clases, a fin de obtener una mejor discriminación. Con base en esto, para el sujeto *al* la combinación elegida es la 37, para $\pi_{2\leftarrow 1}$ para el rango de frecuencias de 12-14 Hz (ver Figura 11).

La combinación 37 está formada por los electrodos {Fz, C3, P3} y la dirección $\pi_{2\leftarrow 1}$ va de Fz a C3. Esto está en concordancia con el conocimiento fisiológico previo de que la zona frontal interviene en mecanismos de control motor. Más aún, el electrodo estimulado es un electrodo de la zona central, lo que refuerza dicha interpretación fisiológica. Este mismo análisis fue aplicado para el resto de los sujetos *aw, al, ay* y *av*. Las diferencias entre clases obtenidas para estos sujetos se muestran en las Figuras 12-14.

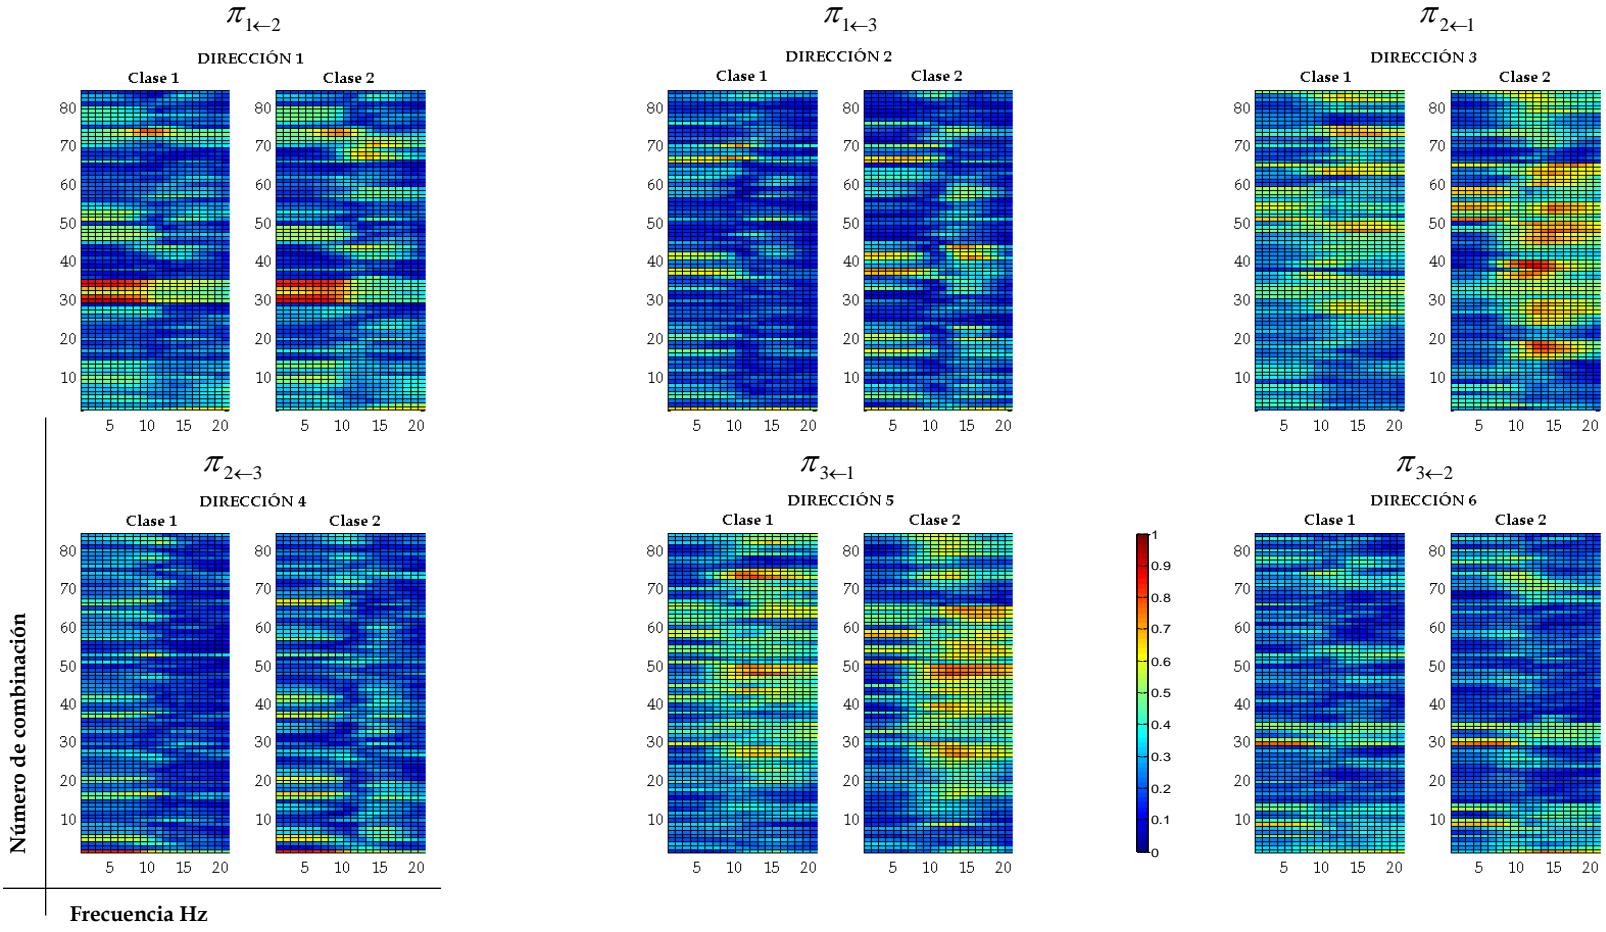


Figura 10: Total de mediciones significativas de cada clase en las seis direcciones de interconexión para cada una de las 84 combinaciones del sujeto *al* durante movimiento imaginado.

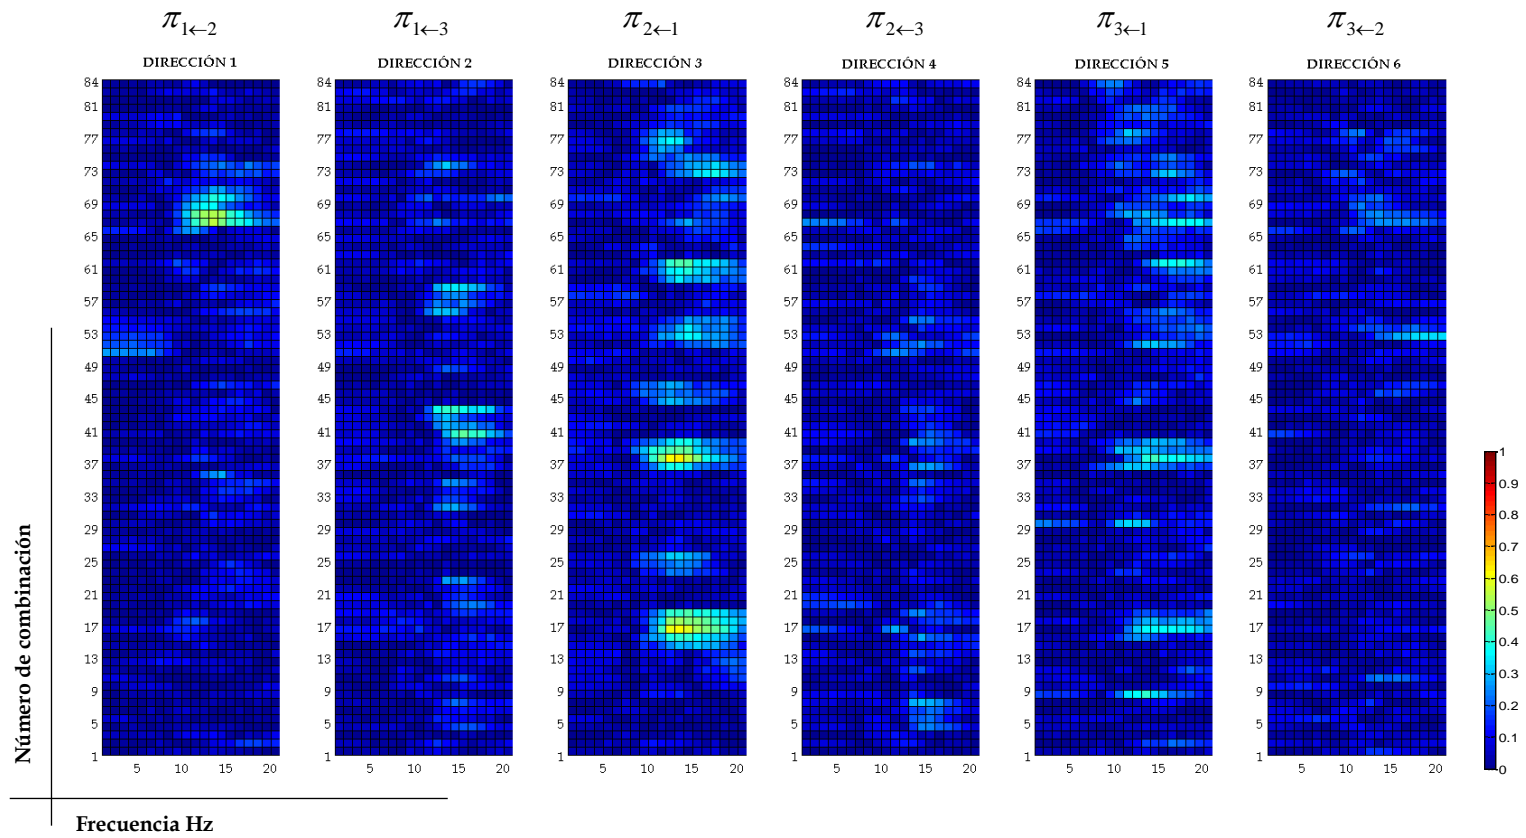


Figura 11: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto *al*

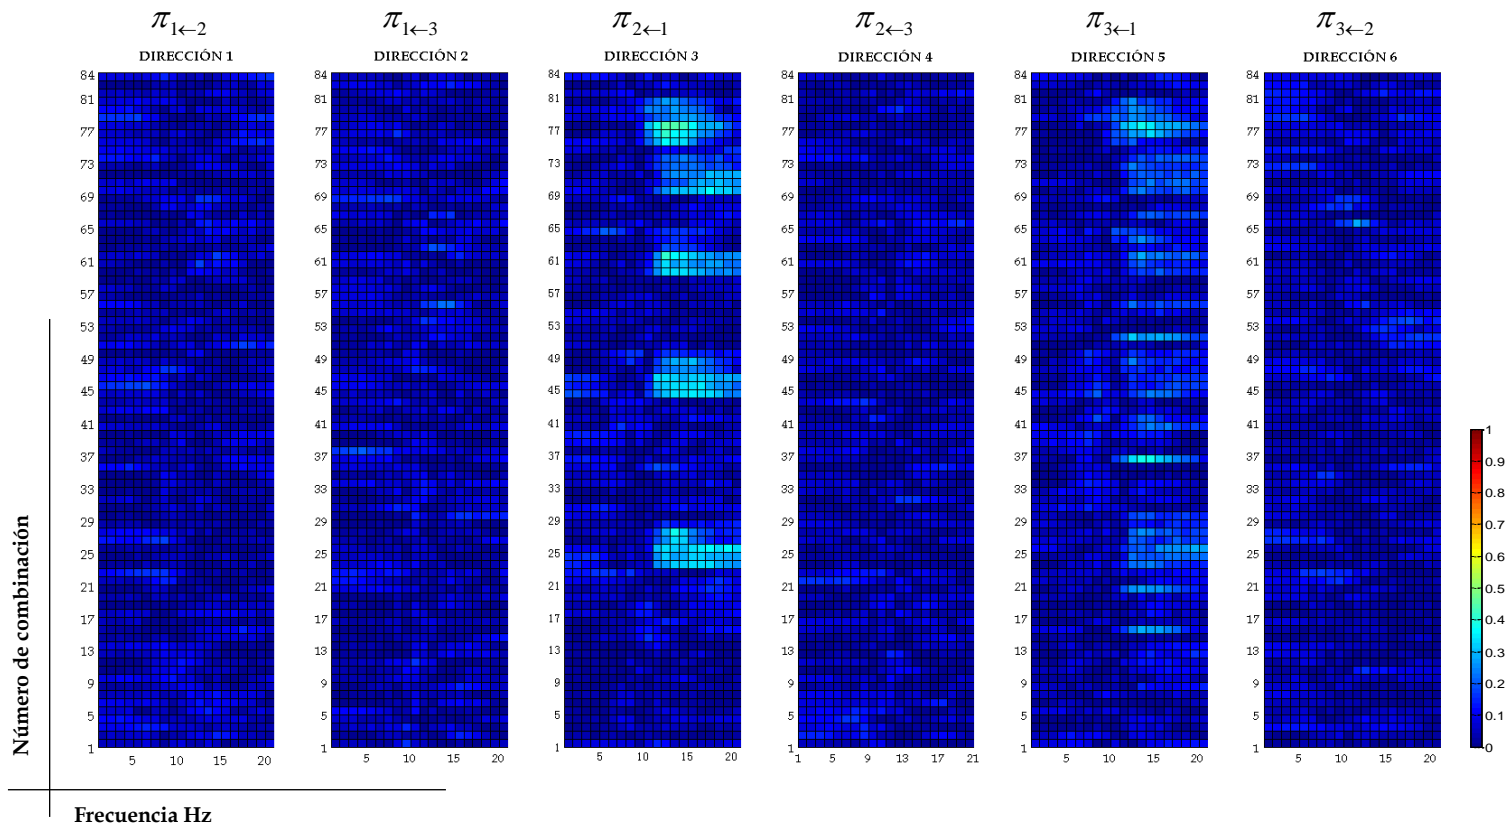


Figura 12: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto αw

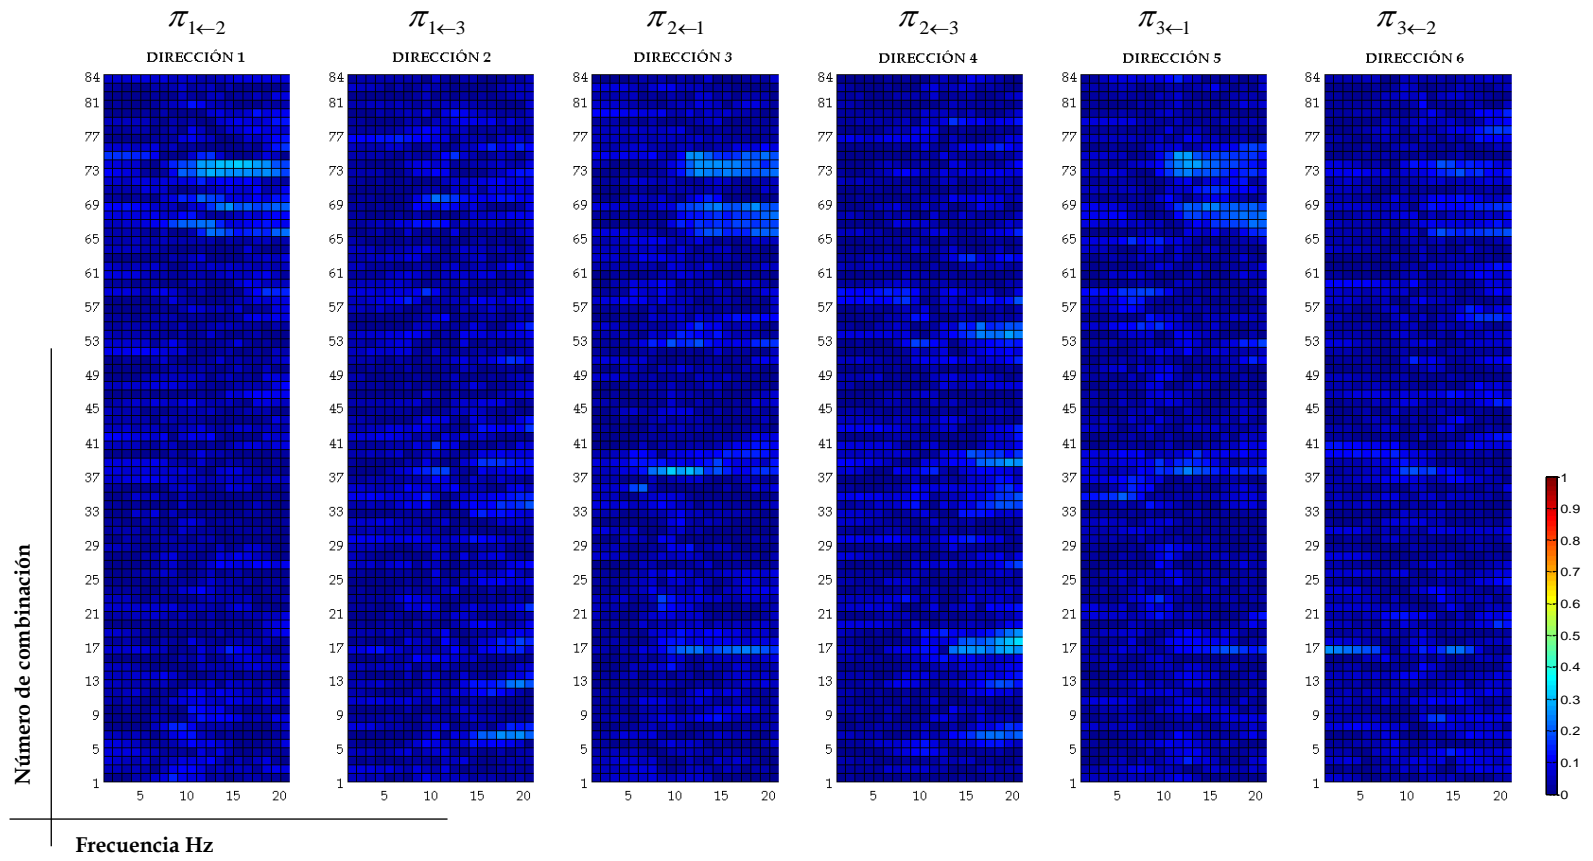


Figura 13: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto *ay*

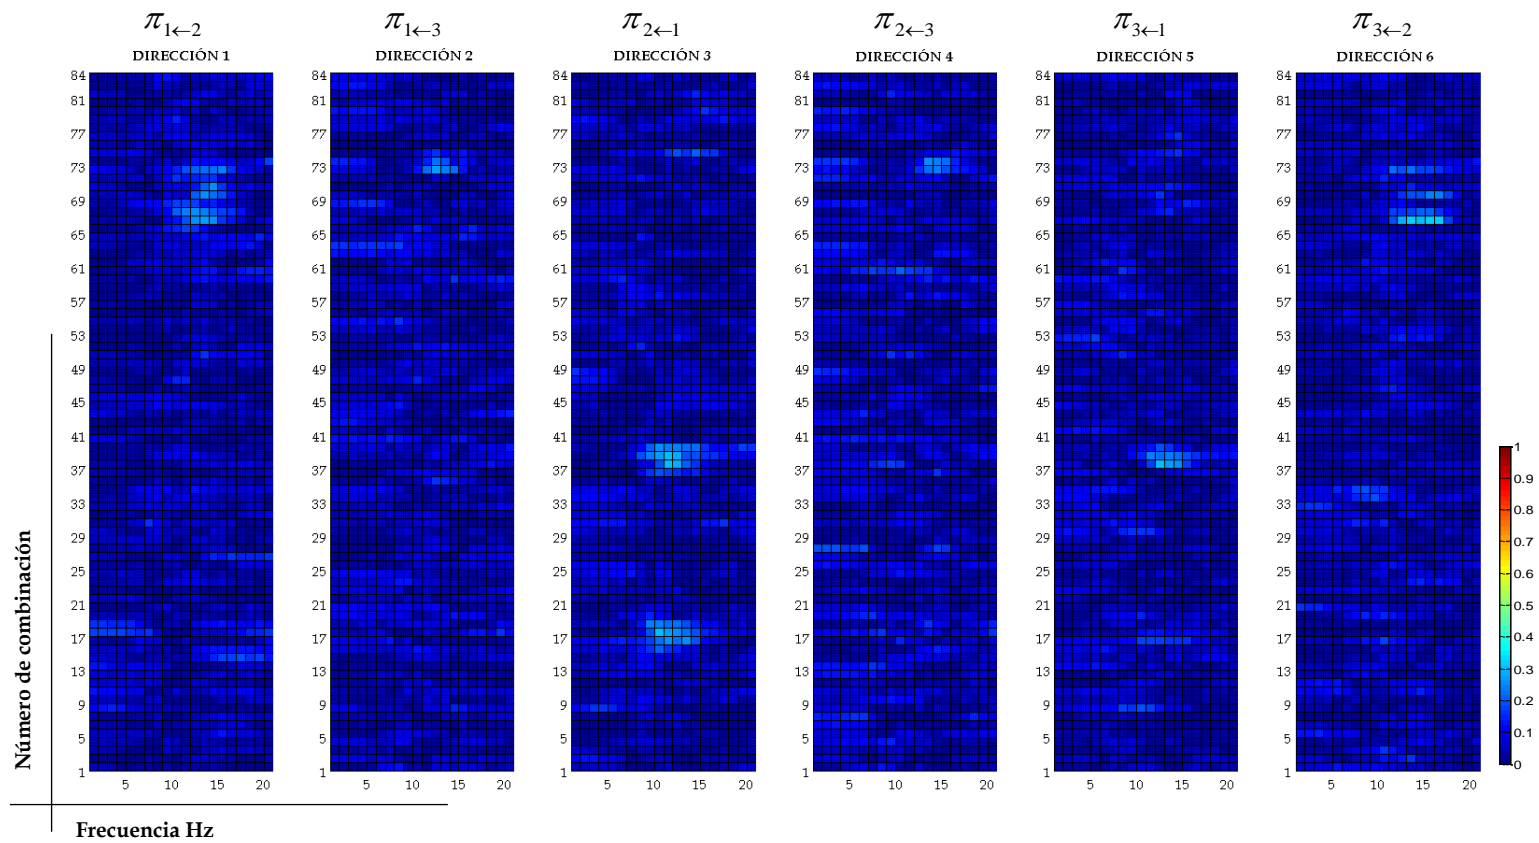


Figura 14: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto *aa*




Figura 15: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones. Sujeto *av*

Hasta ahora, el criterio de selección considera únicamente la diferencia entre el número de mediciones con un valor de PDC significativo. Para asegurar que también existe diferencia en cuestión de magnitud de la PDC, se aplicó la prueba no paramétrica de Wilcoxon, con un nivel de significancia de $\eta=0.05$. Los resultados de esta prueba para la combinación elegida en la dirección seleccionada para el sujeto *al* se muestran en la Figura 16. El eje de las abscisas corresponde a la frecuencia y el eje de las ordenadas al valor p con el que se acepta o rechaza la hipótesis nula.

Se puede observar que en el rango de frecuencias elegido de 12-14 Hz se encuentran los valores p más pequeños, es decir, en donde se tiene mayor certidumbre de que las medianas de ambas clases son diferentes y por tanto los datos de ambas clases provienen de diferentes distribuciones. Los resultados de esta prueba sostienen la elección de esta combinación, dirección y rango de frecuencias. Así se comprueba que también en términos de la magnitud de la PDC la combinación elegida presenta la mayor diferencia entre clases.





Figura 16: Valores p en escala logarítmica para la dirección Fz \rightarrow C3 de la combinación {Fz, C3, P3} del usuario *al*.

Tras realizar el proceso de identificación de redes para todos los sujetos, la Tabla 3 resume la combinación de electrodos seleccionada para cada sujeto, así como la dirección y la banda de frecuencia elegidas. A partir de los resultados obtenidos, se puede observar que para cada uno de los sujetos existe al menos un electrodo central involucrado. Esto es concordante con el conocimiento previo de que los eventos motrices activan la zona central de la corteza cerebral. Más aún, el electrodo mayormente seleccionado es C3, posicionado en el hemisferio izquierdo, lo que está acorde con el fenómeno evaluado: imaginación de movimiento de extremidades derechas.


De manera gráfica, se observan estos resultados en la Figura 17. Se puede notar que para los sujetos *al*, *aa* y *ay*, existe un patrón de conectividad que parte de un electrodo posicionado en la línea media cerebral hacia un electrodo posicionado en el hemisferio izquierdo. Dicho fenómeno no sucede con el sujeto *av*, donde un electrodo de la zona parietal derecha pareciera estimular a la zona central del hemisferio izquierdo. Curiosamente este sujeto es el que alcanzó menor tasa de clasificación. Además, los sujetos *al*, *aa* y *aw* presentan la mayor diferencia en bandas cercanas a la banda μ , mientras que los usuarios *av* y *ay* en frecuencias superiores. Todo lo anterior, puede sugerir que estos sujetos no están teniendo un control adecuado de la tarea mental indicada, sin embargo, para corroborar esto es necesario realizar un estudio más profundo de la conectividad cerebral que desencadena cada tarea mental.

SUJETO	COMBINACIÓN	FRECUENCIAS [HZ]
<i>al</i>	Fz → C3 P3	12-14
<i>aa</i>	C3 Cz → P3	13-15
<i>ay</i>	F3 POz → C3	18-20
<i>av</i>	F3 P4 → C3	18-20
<i>aw</i>	Cz → C4 P4	12-14


Tabla 3: Combinación, dirección y banda de frecuencias elegidas para cada sujeto.




Sujeto *al*
12-14 Hz




Sujeto *aa*
13-15 Hz



Sujeto *ay*
18-20 Hz



Sujeto *av*
18-20 Hz



Sujeto *aw*
12-14 Hz

Figura 17: Combinaciones elegidas para cada voluntario.

5.2. Clasificación

Con el fin de garantizar que los porcentajes de clasificación son independientes del conjunto de datos de entrenamiento y de prueba, se realizó un esquema de *validación cruzada aleatoria*. Dicho esquema consiste en dividir aleatoriamente el conjunto de datos de entrenamiento y de prueba, para cada división se ajusta un modelo a partir de los datos de entrenamiento y se clasifica con los datos de prueba. El resultado final se compone de la media aritmética de los porcentajes de clasificación obtenidos para las diferentes divisiones o iteraciones.

En la Tabla 4 se muestra el porcentaje de clasificación promedio al aplicar el procedimiento descrito en la Sección 3.3 para cada voluntario. Este valor promedio es obtenido tras aplicar un esquema de validación cruzada aleatoria de 100 iteraciones.

Cabe hacer notar que los porcentajes de clasificación obtenidos con este método son superiores a los que se obtendrían por producto del azar (50%). Además en cuatro de los casos son superiores al 70%, es decir, están por arriba del umbral que indica que una BCI es funcional, teniendo la ventaja de hacer uso solo de tres electrodos elegidos automáticamente. El porcentaje de clasificación promedio con el método propuesto fue de 75.75%. Este resultado coloca al método propuesto en la quinta posición de la BCI Competition III, como puede corroborarse en la Tabla 5. Hay que destacar que dicho porcentaje se alcanzó comenzando la búsqueda a partir de nueve electrodos y utilizando sólo tres, seleccionados sin conocimiento *a-priori* de la actividad cerebral desencadenada por las tareas mentales solicitadas al usuario.

SUJETO	COMBINACION	FRECUENCIA [HZ]	% ACIERTOS	STD
al	Fz → C3 P3	12-14	89.28	3
aa	C3 Cz → P3	13-15	74.49	3
ay	F3 POz → C3	18-20	71.94	4
av	F3 P4 → C3	18-20	65.61	3
aw	Cz → C4 P4	12-14	77.45	3
PROMEDIO			75.75	

Tabla 4: Porcentajes de clasificación obtenidos al aplicar el método propuesto.

#	AUTOR	% Clasificación	aa	al	av	aw	ay
1	Yijun Wang	94.74	95.5	100	80.6	100	97.6
2	Yuanqing Li	87.4	89.3	98.2	76.5	92.4	80.6
3	Liu Yang	84.54	82.1	94.6	70.4	87.5	88.1
4	Zhou Zongtan	77.24	83.9	100	63.3	50.9	88.1
5	Gaxiola et. al	75.75	74.4	89.2	65.6	77.4	71.9
6	Michael Bensch	74.14	73.2	96.4	70.4	79.9	50.8
7	Cedric Simon	73.28	83.0	91.1	50	87.9	54.4
8	Elly Gysels	72.36	69.6	96.4	64.3	69.6	61.9
9	Carmen Viduarre	69.62	66.1	92.9	67.3	68.3	50.4
10	Le Song	69	66.1	100	63.3	64.3	54.4
11	Ehsan Arbabi	68.26	70.5	94.6	56.1	63.8	56.3
12	Cyrus Shahabi	61.98	57.1	76.8	57.7	64.3	54
PROMEDIO			75.9	94.18	65.45	75.5	67.3

Tabla 5: Resultados de la BCI competition III.

5.3. Conectividad en reposo

Con el fin de evaluar la conectividad en el periodo de reposo se analizaron los 1.75 segundos previos al inicio del movimiento imaginado, ya que se tienen periodos aleatorios de reposo entre 2 y 1.75 segundos entre cada medición. Aunque en este caso los datos pertenecen a la misma tarea mental (reposo), fueron separados en dos *pseudo-clases*, según el evento mental que precedían. Los resultados de este análisis para el sujeto *al* se presentan en la Figura 18.

Se observa que el número de mediciones que resultaron significativas para ambas *pseudo-clases* es muy similar en todo el rango de frecuencias y para todas las combinaciones, es decir, existe la misma conectividad para ambas clases. Con base en estos resultados, se puede conjeturar que la conectividad presentada es debida a los procesos fisiológicos basales que se presentan en periodo de reposo. Esta característica fue observada también en el resto de los sujetos *aa*, *aw*, *ay* y *av*.

También es de interés comparar la conectividad en movimiento imaginado contra la que se presenta en estado de reposo. En la Figura 19 se muestran las diferencias obtenidas para las tareas de movimiento imaginado y las obtenidas para reposo del sujeto *al*. Cada recuadro corresponde a una dirección, y de manera particular, en cada recuadro se tienen las diferencias para las tareas de movimiento imaginado y para reposo. Como se describió anteriormente durante la imaginación del movimiento, para ciertas combinaciones existen direcciones y frecuencias que presentan diferencias entre ambas clases.

Por el contrario, como era de esperarse, en reposo las diferencias entre las dos *pseudo-clases* son muy cercanas a cero, reforzando la conjetura de que la

conectividad existente en estado de reposo se debe a procesos fisiológicos basales. Entonces, al realizarse una tarea mental determinada, se generan patrones de conexión propios de dicha tarea.

De manera similar, analizando para el sujeto con peor desempeño, *av*, en la Figura 20 se muestran las diferencias de los resultados obtenidos. Se observa que por el contrario al sujeto *al*, para *av* la conectividad en ambos estados es muy parecida. El no existir conexiones nuevas podría sugerir que el usuario no está teniendo un buen control de la tarea mental que se está imaginando.

5.4. Dirección que más se repite

También fue de interés evaluar qué dirección aparece mayormente independientemente de la red a la que pertenezca. Esto se realizó con el objetivo de garantizar que esa dirección efectivamente representa una conectividad distintiva de la tarea mental. Para tal fin se evaluaron todas las posibles direcciones que se pueden formar usando los electrodos {F3,Fz,F4,C3,Cz,C4,P3,POz,P4}, las cuales se pueden consultar en la Tabla 6.

Los resultados nuevamente, de manera esquematizada, se muestran para el sujeto *al* en la Figura 21. Para cada recuadro a lo largo del eje de las abscisas se tiene la frecuencia, y en el eje de las ordenadas las 72 direcciones evaluadas. El primer recuadro muestra el resultado para la clase 1, el segundo para la clase 2 y el tercero muestra la diferencia entre clases. La barra de colores indica una cantidad normalizada con respecto al número total de veces que puede aparecer una dirección en las 140 mediciones.

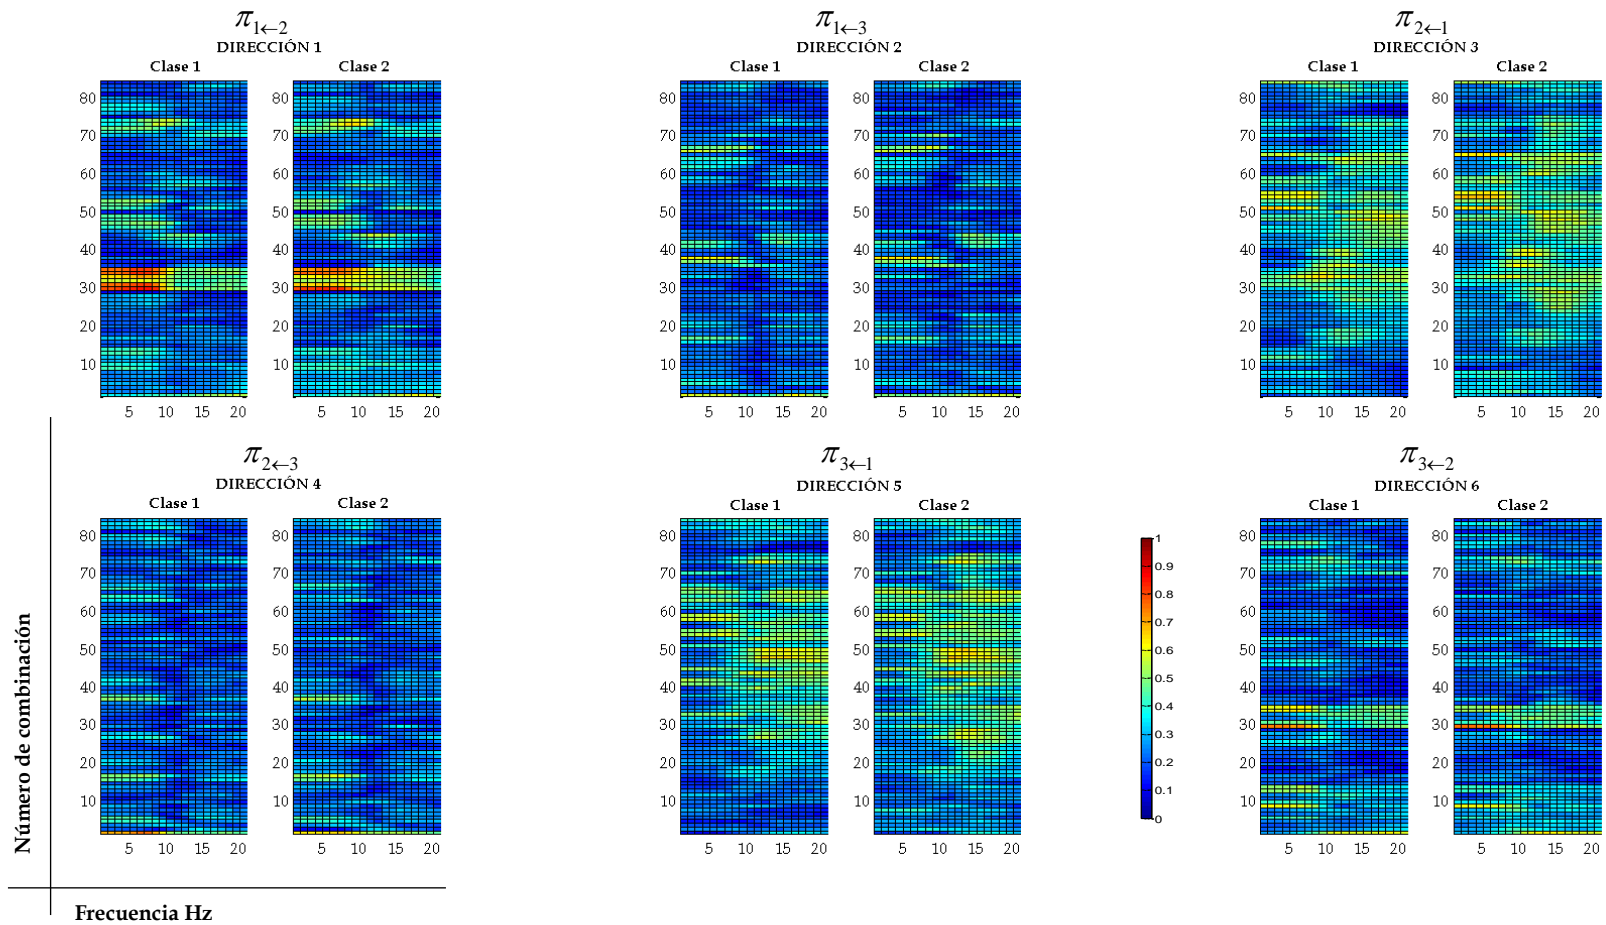


Figura 18: Total de mediciones significativas de cada clase en las seis direcciones de interconexión, para cada una de las 84 combinaciones del sujeto *al* durante el reposo.

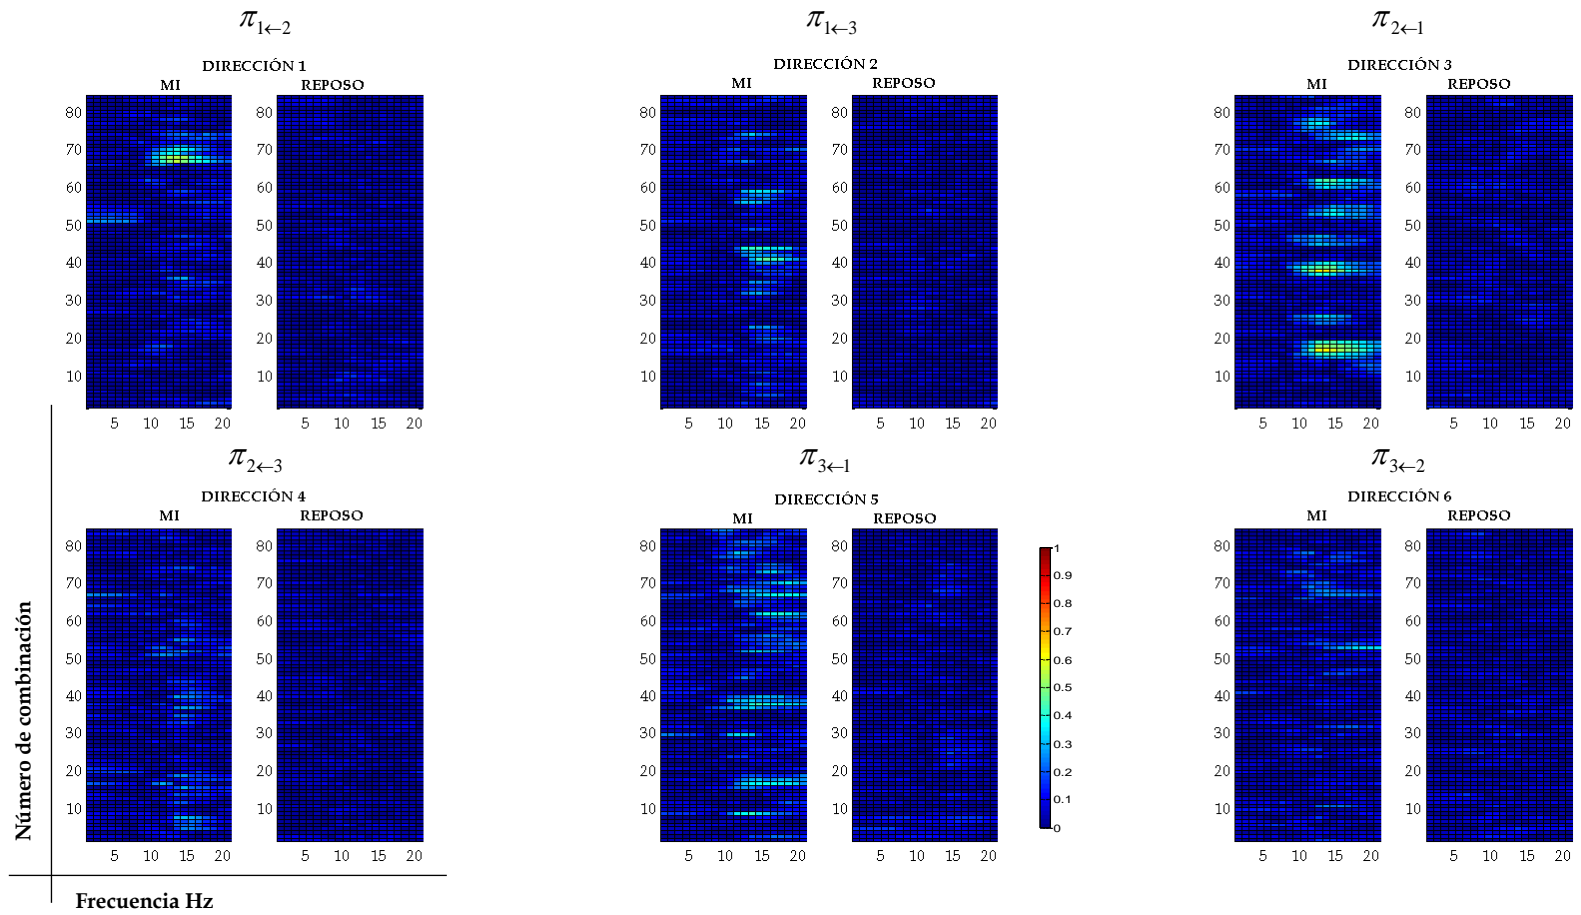


Figura 19: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones en los periodos de MI y reposo. Sujeto *al*.

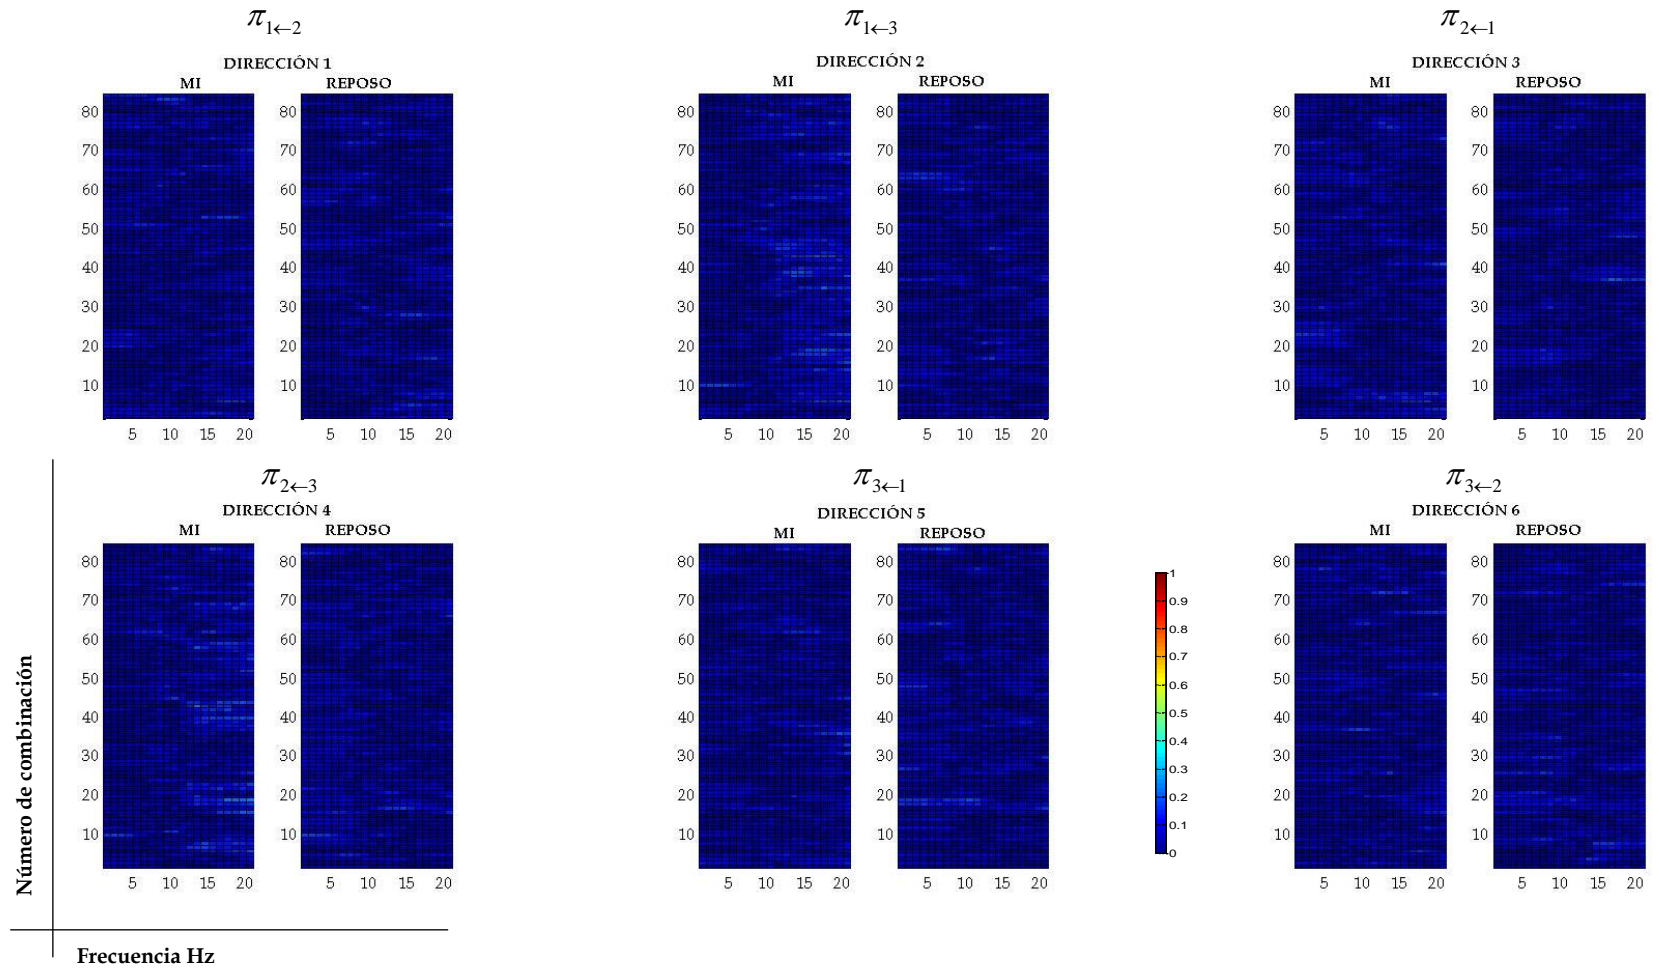


Figura 20: Diferencias entre clases en las seis direcciones de interconexión para las 84 combinaciones en los periodos de MI y reposo. Sujeto *av*.

NÚMERO	EMISOR	RECEPTOR
1	'Fz'	'F3'
2	'F4'	'F3'
3	'C3'	'F3'
4	'Cz'	'F3'
5	'C4'	'F3'
6	'P3'	'F3'
7	'POz'	'F3'
8	'P4'	'F3'
9	'F4'	'Fz'
10	'C3'	'Fz'
11	'Cz'	'Fz'
12	'C4'	'Fz'
13	'P3'	'Fz'
14	'POz'	'Fz'
15	'P4'	'Fz'
16	'C3'	'F4'
17	'Cz'	'F4'
18	'C4'	'F4'
19	'P3'	'F4'
20	'POz'	'F4'
21	'P4'	'F4'
22	'Cz'	'C3'
23	'C4'	'C3'
24	'P3'	'C3'
25	'POz'	'C3'
26	'P4'	'C3'
27	'C4'	'CZ'
28	'P3'	'CZ'
29	'POz'	'CZ'
30	'P4'	'CZ'
31	'P3'	'C4'
32	'POz'	'C4'
33	'P4'	'C4'
34	'POz'	'P3'
35	'P4'	'P3'
37	'POz'	'P4'
38	'P3'	'P4'
39	'C4'	'P4'
40	'Cz'	'P4'
41	'C3'	'P4'
42	'F4'	'P4'
43	'Fz'	'P4'
44	'F3'	'P4'
45	'P3'	'POZ'
46	'C4'	'POZ'
47	'Cz'	'POZ'
48	'C3'	'POZ'
49	'F4'	'POZ'
50	'Fz'	'POZ'
51	'F3'	'POZ'
52	'C4'	'P3'
53	'Cz'	'P3'
54	'C3'	'P3'
55	'F4'	'P3'
56	'Fz'	'P3'
57	'F3'	'P3'
58	'Cz'	'C4'
59	'C3'	'C4'
60	'F4'	'C4'
61	'Fz'	'C4'
62	'F3'	'C4'
63	'C3'	'CZ'
64	'F4'	'CZ'
65	'Fz'	'CZ'
66	'F3'	'CZ'
67	'F4'	'C3'
68	'Fz'	'C3'
69	'F3'	'C3'
70	'Fz'	'F4'
71	'F3'	'F4'
72	'F3'	'FZ'

Tabla 6: Direcciones formadas al utilizar los electrodos {F3,Fz,F4,C3,Cz,C4,P3,POz,P4}.

Para dichos resultados se observa que las direcciones que aparecen mayormente para una clase y no para la otra son la 22 (Cz→C3, 11-13Hz), 54(C3→P3, 15-19Hz), 60 (F4→C4, 12-17Hz), 68 (Fz→C3, 10-14 Hz) y la 69(F3→C3, 11-18Hz). Tal hecho concuerda con los resultados mostrados en la selección de la combinación para cada usuario los cuales se pueden consultar en la Tabla 3.

Los resultados para el resto de los sujetos se muestran en la Figura 22. Nuevamente puede observarse que para los sujetos con mejores tasas de clasificación (*al*, *aw* y *aa*), existen mayores diferencias en la frecuencia de aparición para las dos clases. Por el contrario para los sujetos *ay* y *av* estas diferencias no son destacables. Todo esto reafirma la idea de que estos sujetos no lograron un control total en las tareas solicitadas.

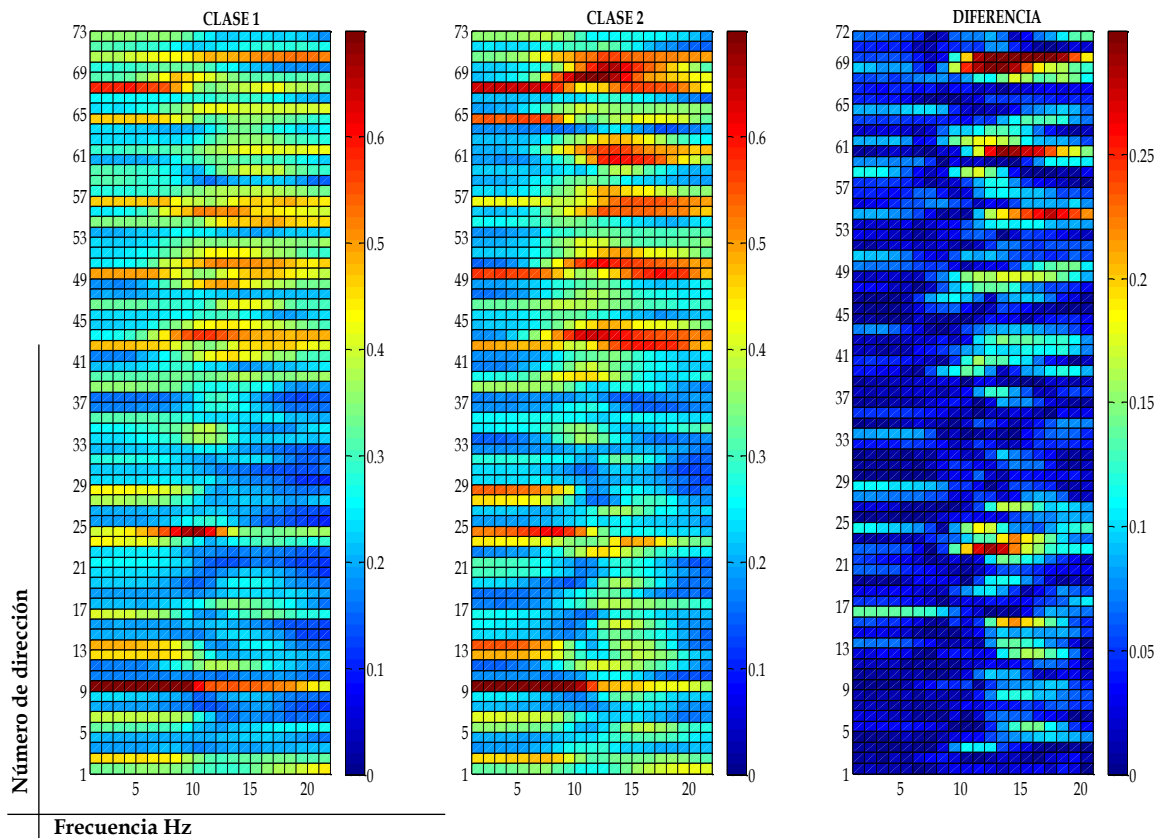


Figura 21: Evaluación de la aparición de las 72 direcciones posibles en cada una de las tareas mentales y en la diferencia entre ellas. Sujeto *al*

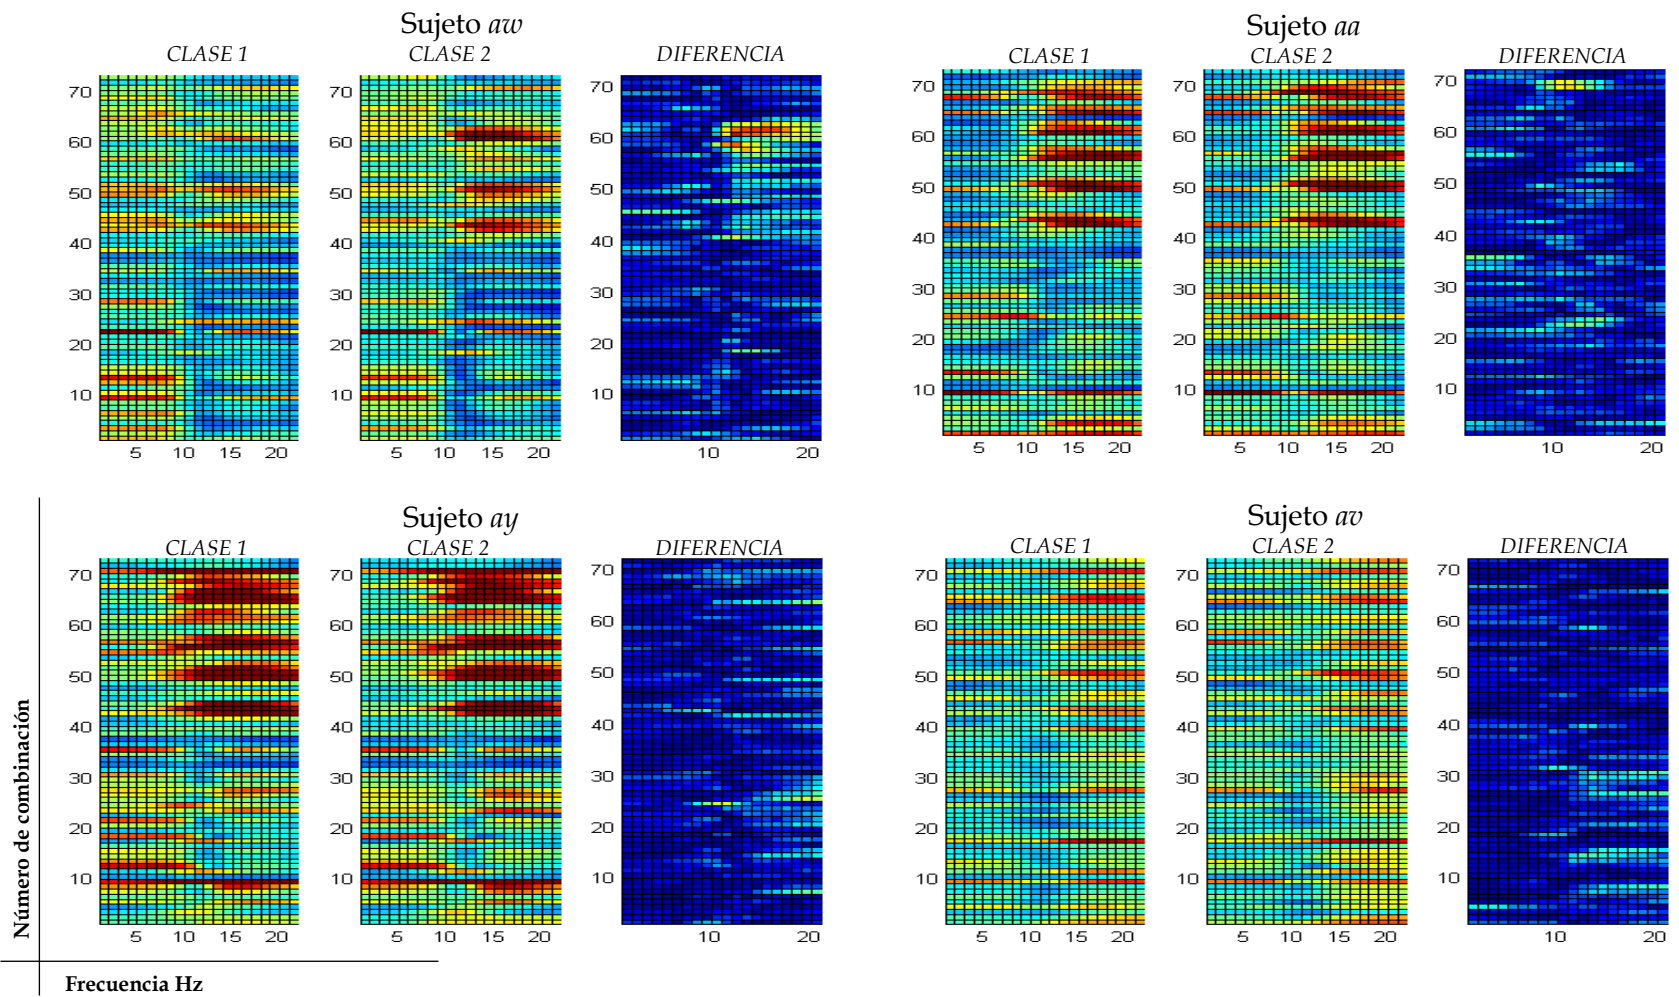


Figura 22: Evaluación de la aparición de las 72 direcciones posibles en cada una de las tareas mentales y en la diferencia entre ellas para cada sujeto

En la Tabla 7 se resumen las tres direcciones que más aparecen para cada uno de los sujetos en cada una de las clases. En la última columna se presenta la dirección que da mayor diferencia entre clases en cuanto a frecuencia de aparición. En negritas se muestra la dirección que se utilizó para la clasificación (de acuerdo a lo anteriormente mostrado en la Tabla 3).

<i>Sujeto</i>	<i>Clase 1</i>		<i>Clase 2</i>		<i>Mayor diferencia</i>	
	<i>Dirección</i>	<i>Frecuencia (Hz)</i>	<i>Dirección</i>	<i>Frecuencia (Hz)</i>	<i>Dirección</i>	<i>Frecuencia (Hz)</i>
<i>al</i>	<i>F4->Fz</i>	3	<i>F4->Fz</i>	7	<i>F3->C3</i>	13
	<i>P3->C3</i>	10	<i>Fz->C3</i>	11	<i>Fz->C3</i>	12
	<i>F4->C3</i>	4	<i>F3->C3</i>	13	<i>F4->C4</i>	13
<i>aa</i>	<i>F4->C4</i>	14	<i>F4->P3</i>	15	<i>Fz->C3</i>	11
	<i>F4->P3</i>	15	<i>Fz->P4</i>	13	<i>F3->C3</i>	10
	<i>F4->POz</i>	16	<i>Fz->POz</i>	14	<i>Cz->C3</i>	12
<i>ay</i>	<i>Fz->F4</i>	20	<i>F4->Fz</i>	17	<i>POz->C3</i>	19
	<i>F4->Fz</i>	18	<i>Fz->F4</i>	21	<i>P3->C3</i>	11
	<i>F4->Cz</i>	14	<i>F4->P3</i>	12	<i>C3->Cz</i>	20
<i>av</i>	<i>Cz->F4</i>	18	<i>Cz->F4</i>	18	<i>P4->C3</i>	20
	<i>Fz->Cz</i>	17	<i>Fz->POz</i>	15	<i>P4->Cz</i>	19
	<i>F4->Cz</i>	18	<i>F4->Cz</i>	19	<i>POz->Fz</i>	12
<i>aw</i>	<i>Cz->C3</i>	3	<i>F4->C4</i>	14	<i>F4->C4</i>	12
	<i>P3->Fz</i>	6	<i>Fz->C4</i>	13	<i>Fz->C4</i>	15
	<i>F4->Fz</i>	6	<i>Cz->C3</i>	3	<i>Cz->C4</i>	12

Tabla 7: Direcciones más recurrentes para cada sujeto.

5.5. *Evaluación de la conectividad usando red de nueve electrodos*

Con el fin de analizar si la selección de redes de tres electrodos trae consigo pérdida de información en términos de conectividad, se evaluaron las interacciones existentes utilizando los nueve electrodos {F3,Fz,F4,C3,Cz,C4,P3,POz,P4}. Así mismo, esto permitió evaluar si la información obtenida al utilizar redes de tres electrodos es consistente al incrementar el número de electrodos y por lo tanto describe realmente el proceso en estudio o es propio de la red elegida. Este análisis se llevó a cabo con un modelo de orden $p=4$, con los 2 segundos intermedios para las 140 mediciones de cada clase. Los resultados para el sujeto *al*, se muestran en la Figura 23.

Para cada recuadro, a lo largo del eje de las abscisas se tienen los canales emisores, y en el eje de las ordenadas los receptores. La barra de colores indica la cantidad de mediciones que resultaron significativas normalizada con respecto al número de mediciones totales. Igualmente en la figura se muestran los resultados para cada clase y la diferencia. En este caso se trabajó en el rango de frecuencia de 12-14 Hz ya que se desea comparar con los resultados obtenidos previamente para el sujeto *al*.

Así pues, la dirección elegida para el sujeto *al* fue $Fz \rightarrow C3$, la cual fue característica de la clase 2, esto utilizando la combinación de electrodos {Fz, C3, P3}. Al analizar los resultados utilizando nueve canales, se puede observar que esta dirección aparece predominantemente en la clase 2. Lo anterior sugiere que efectivamente, la dirección $Fz \rightarrow C3$ es una dirección descriptiva de la tarea mental y no es influencia por la red elegida. Lo mismo se observó para la dirección elegida para el resto de los sujetos.

Cabe mencionar que haciendo un análisis más profundo, aparecen otras direcciones que presentan mayor diferencia como: $F3 \rightarrow C3$, $F4 \rightarrow C4$, $F4 \rightarrow Cz$ y $C4 \rightarrow Fz$. Eso era de esperarse ya que se están agregando más canales al sistema. Sin embargo, estas direcciones aparecen también en mayor o menor medida en el análisis utilizando redes de tres electrodos.




Figura 23 : Evaluación de la conectividad usando una red de {F3,Fz,F4,C3,Cz,C4,P3,POz,P4} electrodos. Sujeto *al*

Capítulo 6

Conclusiones y trabajo futuro

Evaluar la direccionalidad en la conectividad entre áreas cerebrales, permite seleccionar un conjunto óptimo de electrodos (en nuestro caso de tres) para discriminar entre tareas mentales. Esta selección se lleva a cabo de manera automática y personalizada para cada sujeto, sin conocimiento *a-priori* de la actividad cerebral desencadenada, y los electrodos están relacionados con la tarea mental que se ejecuta. Además el uso de la PDC como método de extracción de características, permite obtener tasas de clasificación superiores al umbral para uso en BCI, usando solo tres electrodos.

El trabajo desarrollado en esta tesis aporta un método de procesamiento basado en la PDC, orientado a la extracción de características de señales de EEG. Este método realiza la selección de un conjunto óptimo de electrodos para la clasificación de dichas señales. Debido a que opera con un número reducido de electrodos, el método propuesto resulta atractivo para aplicaciones realistas de BCI. A pesar de que el método trabaja con vectores de características reducidos, fue posible obtener niveles de clasificación por arriba del umbral funcional para una BCI y comparables con los reportados en la literatura.

El método propuesto no sólo considera la conectividad entre electrodos, sino también la direccionalidad en dicha conectividad mientras se ejecuta cierta tarea mental. Esta característica permite tener un conocimiento detallado acerca del evento neuronal desencadenado por la tarea mental solicitada al usuario.

Mediante este método puede explicarse la variabilidad entre sujetos y plantear conjeturas referentes a la diferencia en las tasas de acierto. Esto lo

sugiere el hecho de que al realizarse la selección de electrodos en función de aquellos que brindan mayor diferencia en cuanto a significancia en la conectividad, se hacen inferencias acerca de qué zonas cerebrales se interconectan para cada sujeto al realizar cierta tarea.

Todo lo anterior puede ser el preámbulo para aplicar la PDC en estudios de *analfabetismo* en BCI (i.e., incapacidad para operar el sistema). Esto lo sugiere la observación de que para los sujetos que obtuvieron mayores tasas de clasificación existen diferentes patrones de conectividad durante el reposo y el movimiento imaginado. Por el contrario, para el sujeto que alcanzo menor tasa de clasificación, prácticamente no existen diferencias entre dichos estados. Esto sugiere que tal sujeto no está teniendo control de la actividad mental que se le solicitó.

Buscando darle continuidad a la investigación desarrollada, es de interés realizar experimentos propios en lugar de depender de bases de datos públicas, esto a fin de evaluar el método en un mayor número de sujetos, utilizando otro tipo de eventos (e.g., eventos cognitivos), y en condiciones reales.

También es deseable contar con un mayor número de mediciones que permita identificar la morfología de la red característica para cada clase. Esto no fue posible con sólo 140 mediciones de cada clase. Y es que, partiendo de un conjunto de nueve electrodos y formando redes de tres, al considerar todos los casos posibles con al menos tres direcciones significativas, surgen 42 morfologías distintas. Esto representa casi el 30% de las mediciones, con lo cual no es posible realizar un análisis estadístico que permita esclarecer la morfología característica de una tarea mental.

Otro punto de interés es analizar las redes que se forman para cada tarea mental por separado, esto para obtener información acerca de las redes funcionales que surgen en cada tarea y con ello caracterizar cada estado mental. Finalmente, es de interés hacer un estudio generalizado de conectividad cerebral en diferentes bandas de frecuencia (reposo contra MI) y asociar los resultados a fenómenos fisiológicos que pudieran sugerir analfabetismo.

Bibliografía

- [1] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., & Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767-791.
- [2] Guger, C., Edlinger, G., Harkam, W., Niedermayer, I., & Pfurtscheller, G. (2003). How many people are able to operate an EEG-based brain-computer interface (BCI)? *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), 145-147.
- [3] Blankertz, B., Dornhege, G., Krauledat, M., Schröder, M., Williamson, J., Murray-Smith, R., & Müller, K. R. (2006). The Berlin Brain-Computer Interface presents the novel mental typewriter Hex-o-Spell. Proceedings of the 3rd International Brain-Computer Interface Workshop and Training Course 2006. Verlag der Technischen Universität Graz, 108-109.
- [4] Rebsamen, B., Guan, C., Zhang, H., Wang, C., Teo, C., Ang, M. H., & Burdet, E. (2010). A brain controlled wheelchair to navigate in familiar environments. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(6), 590-598.
- [5] Galán, F., Nuttin, M., Lew, E., Ferrez, P. W., Vanacker, G., Philips, J., & Millán, J. D. R. (2008). A brain-actuated wheelchair: asynchronous and non-invasive brain-computer interfaces for continuous control of robots. *Clinical Neurophysiology*, 119(9), 2159-2169.
- [6] Gutiérrez, D., & Ramírez-Moreno, M. A. (2016). Assessing a learning process with functional ANOVA estimators of EEG power spectral densities. *Cognitive Neurodynamics*, 10(2), 175-183.
- [7] Angulo-Sherman, I. N., & Gutiérrez, D. (2015). A link between the increase in electroencephalographic coherence and performance improvement in

operating a brain-computer interface. *Computational intelligence and Neuroscience*, 2015, 67.

[8] Penny, W. D., Roberts, S. J., Curran, E. A., & Stokes, M. J. (2000). EEG-based communication: a pattern recognition approach. *IEEE Transactions on Rehabilitation Engineering*, 8(2), 214-215.

[9] Gutiérrez-Martínez, J., Cantillo-Negrete, J., Cariño-Escobar, R. I., & Elías-Viñas, D. (2013). Los sistemas de interfaz cerebro-computadora: una herramienta para apoyar la rehabilitación de pacientes con discapacidad motora. *Investigación en Discapacidad*, 2(2), 62-69.

[10] Pfurtscheller, G., & Da Silva, F. L. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 110(11), 1842-1857.

[11] Jeon, Y., Nam, C. S., Kim, Y. J., & Whang, M. C. (2011). Event-related (De) synchronization (ERD/ERS) during motor imagery tasks: Implications for brain-computer interfaces. *International Journal of Industrial Ergonomics*, 41(5), 428-436.

[12] Pineda, J. A., Allison, B. Z., & Vankov, A. (2000). The effects of self-movement, observation, and imagination on μ rhythms and readiness potentials (RP's): toward a brain-computer interface (BCI). *IEEE Transactions on Rehabilitation Engineering*, 8(2), 219-222.

[13] Pfurtscheller, G., Stancak, A., & Neuper, C. (1996). Post-movement beta synchronization. A correlate of an idling motor area?. *Electroencephalography and Clinical Neurophysiology*, 98(4), 281-293.

[14] McFarland, D. J., Anderson, C. W., Muller, K., Schlögl, A., & Krusienski, D. J. (2006). BCI meeting 2005-workshop on BCI signal processing: feature extraction and translation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(2), 135.

[15] Jakuczun, W. (2006). Classifying signals with local classifiers. *Journal of Machine Learning Research*. Disponible en <http://arxiv.org/pdf/cs/0602031v1.pdf>

- [16] Salazar-Varas, R., & Gutiérrez, D. (2015). An optimized feature selection and classification method for using electroencephalographic coherence in brain-computer interfaces. *Biomedical Signal Processing and Control*, 18, 11-18.
- [17] Baccalá, L. A., & Sameshima, K. (2001). Partial directed coherence: a new concept in neural structure determination. *Biological Cybernetics*, 84(6), 463-474.
- [18] Sameshima, K., & Baccalá, L. A. (1999). Using partial directed coherence to describe neuronal ensemble interactions. *Journal of Neuroscience Methods*, 94(1), 93-103.
- [19] Sato, J. R., Takahashi, D. Y., Arcuri, S. M., Sameshima, K., Morettin, P. A., & Baccalá, L. A. (2009). Frequency domain connectivity identification: an application of partial directed coherence in fMRI. *Human Brain Mapping*, 30(2), 452-461.
- [20] Varotto, G., Visani, E., Canafoglia, L., Franceschetti, S., Avanzini, G., & Panzica, F. (2012). Enhanced frontocentral EEG connectivity in photosensitive generalized epilepsies: a partial directed coherence study. *Epilepsia*, 53(2), 359-367.
- [21] Billinger, M., Brunner, C., & Müller-Putz, G. R. (2013). Single-trial connectivity estimation for classification of motor imagery data. *Journal of Neural Engineering*, 10(4), 046006.
- [22] Velasco Álvarez, F. (2012). *Interfaz cerebro-computadora: paradigmas de navegación basados en una tarea de imaginación motora*. Tesis de doctorado. Universidad de Málaga.
- [23] Kronegg, J., Chanel, G., Voloshynovskiy, S., & Pun, T. (2007). EEG-based synchronized brain-computer interfaces: A model for optimizing the number of mental tasks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 15(1), 50-58.
- [24] Obermaier, B., Neuper, C., Guger, C., & Pfurtscheller, G. (2001). Information transfer rate in a five-classes brain-computer interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 9(3), 283-288.

- [25] Alotaiby, T., El-Samie, F. E. A., Alshebeili, S. A., & Ahmad, I. (2015). A review of channel selection algorithms for EEG signal processing. *EURASIP Journal on Advances in Signal Processing*, 2015(1), 1.
- [26] Sannelli, C., Dickhaus, T., Halder, S., Hammer, E. M., Müller, K. R., & Blankertz, B. (2010). On optimal channel configurations for SMR-based brain-computer interfaces. *Brain Topography*, 23(2), 186-193.
- [27] Arvaneh, M., Guan, C., Ang, K. K., & Quek, C. (2011). Optimizing the channel selection and classification accuracy in EEG-based BCI. *IEEE Transactions on Biomedical Engineering*, 58(6), 1865-1873.
- [28] Lan, T., Erdogmus, D., Adami, A., Pavel, M., & Mathan, S. (2006, January). Salient EEG channel selection in brain computer interfaces by mutual information maximization. In *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference* (pp. 7064-7067). IEEE.
- [29] Fox, S. I. (2003). *Fisiología humana*. McGraw-Hill Interamericana de España.
- [30] Klem, G. H., Lüders, H. O., Jasper, H. H., & Elger, C. (1999). The ten-twenty electrode system of the International Federation. *Electroencephalography and Clinical Neurophysiology*, 52(3).
- [31] S. Sanei y J. A. Chambers, EEG signal processing. John Wiley & Sons, 2013.
- [32] Sameshima, K., & Baccala, L. A. (Eds.). (2014). *Methods in brain connectivity inference through multivariate time series analysis*. CRC press.
- [33] Friston, K. J. (2009). Modalities, modes, and models in functional neuroimaging. *Science*, 326(5951), 399-403.
- [34] Sakkalis, V. (2011). Review of advanced techniques for the estimation of brain connectivity measured with EEG/MEG. *Computers in Biology and Medicine*, 41(12), 1110-1117.
- [35] Friston, K. J. (2011). Functional and effective connectivity: a review. *Brain Connectivity*, 1(1), 13-36.
- [36] Friston, K. J. (1994). Functional and effective connectivity in neuroimaging: a synthesis. *Human Brain Mapping*, 2(1-2), 56-78.

- [37] Koch, M. A., Norris, D. G., & Hund-Georgiadis, M. (2002). An investigation of functional and anatomical connectivity using magnetic resonance imaging. *Neuroimage*, 16(1), 241-250.
- [38] Horwitz, B. (2003). The elusive concept of brain connectivity. *Neuroimage*, 19(2), 466-470.
- [39] Granger, C. W. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica: Journal of the Econometric Society*, 424-438.
- [40] Schelter, B., Winterhalder, M., Eichler, M., Peifer, M., Hellwig, B., Guschlbauer, B., ... & Timmer, J. (2006). Testing for directed influences among neural signals using partial directed coherence. *Journal of Neuroscience Methods*, 152(1), 210-219.
- [41] D. Y. Takahashi, L. A. Baccalá, and K. Sameshima. Connectivity inference between neural structures via partial directed coherence. *Journal of Applied Statistics*, 34(10): 1259-1273, 2007.
- [42] G. Dornhege, B. Blankertz, G. Curio, and K. R. Müller. Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms. *IEEE Transactions on Biomedical Engineering*, 51(6): 993-1002, 2004.
- [43] Kaminski, M., & Blinowska, K. J. (2014). Directed transfer function is not influenced by volume conduction—inexpedient pre-processing should be avoided. *Frontiers in Computational Neuroscience*, 8, 61.